DIEGO LUÍS DE ANDRADE BERNERT

ABORDAGENS DE CONTROLE UTILIZANDO OTIMIZAÇÃO COM INSPIRAÇÃO QUÂNTICA APLICADAS A SISTEMAS NÃO LINEARES

CURITIBA 2010

DIEGO LUÍS DE ANDRADE BERNERT

ABORDAGENS DE CONTROLE UTILIZANDO OTIMIZAÇÃO COM INSPIRAÇÃO QUÂNTICA APLICADAS A SISTEMAS NÃO LINEARES

Dissertação apresentada ao Curso de Pós Graduação em Engenharia de Produção e Sistemas da Pontificia Universidade Católica do Paraná PUC-PR, como requerimento parcial para obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Área de Concentração: Identificação e Controle de Sistemas

Orientador: Prof. Dr. Leandro dos Santos Coelho

CURITIBA 2010

À minha família e a todos que de alguma maneira ajudaram.

AGRADECIMENTOS

Começo por agradecer à minha família, Rossano, Vilma e Guilherme, por sempre estarem presentes ao meu lado dando apoio, sempre disponíveis, independente de horário.

Agradeço também à minha querida namorada Karine, que me ajudou muito com sua paciência e compreensão, principalmente nas horas difíceis no decorrer destes anos. Também à minha segunda família, Carmen, Odyr e Erica, por suportarem as inacabáveis visitas no fim de todas as noites.

Ao meu professor orientador Dr. Leandro Coelho, agradeço pelas críticas e sugestões, pela disponibilidade e pelo acompanhamento regular com que sempre orientou este trabalho, sendo assim uma grande fonte de motivação.

Agradeço à TSK do Brasil pela flexibilidade no horário de trabalho, sem a qual não seria possível a realização dessa dissertação.

À PUC-PR, agradeço pela oportunidade concedida através da bolsa de estudos Marcelino Champagnat.

RESUMO

O estudo da teoria de controle tem cada dia mais desempenhado um papel fundamental na área tecnológica, contribuindo sempre para os avanços em engenharia. Por outro lado, os processos a serem controlados estão cada vez mais desafiadores no meio industrial, com características não-lineares, e a garantia de um controle de bom desempenho é essencial. Para tanto, essa dissertação propõe o estudo de diversas técnicas de controle, tais quais os controladores preditivos GPC (Generalized Predictive Control), GMV (Generalized Minimum Variance) e DMC (Dynamic Matrix Control), o controlador PID (Proporcional-Integral-Derivativo) e o PI (Proporcional-Integrativo) adaptativo. Todas essas técnicas possuem alguns parâmetros diferenciados de sintonia, que são cruciais no seu desempenho final e suas sintonias sempre ficam a critério do projetista e sua experiência e conhecimento do modelo. Para tentar resolver o problema da sintonia desses controladores, será utilizada uma nova versão do algoritmo de otimização QEA (Quantum Inspired Evolutionary Algorithm), inspirado em computação quântica. Essa nova área vem sendo estudada e aplicada em problemas de otimização e resultados satisfatórios relacionados ao tempo de processamento e desempenho das respostas vem sendo obtidos, devido à propriedade de superposição de estados, decorrente da mecânica quântica. Para quantificar e analisar o desempenho do algoritmo, os controladores foram aplicados em três sistemas não-lineares teóricos: uma coluna de destilação, um tanque de neutralização de pH e um trocador de calor. A sintonia dos parâmetros foi realizada via QEA modificado (MQEA - Modified Quantum Inspired Evolutionary Algorithm). Os valores encontrados para os índices de desempenho, ITSE (Integral Time Squared Error) e médias de convergências, foram comparados aos valores dos controladores sintonizados via AGs (Algoritmos Genéticos). Na maioria dos casos o MQEA apresentou um desempenho superior ao AG, obtendo melhores resultados para o controle dos processos.

Palavras-Chave: Controle Preditivo, Computação Quântica, Controle Adaptativo, Controle PID, Otimização, Algoritmos Evolutivos com Inspiração Quântica, Algoritmos Genéticos.

ABSTRACT

The study of the control theory has played each day a more fundamental role in the technological area, always contributing for advances in engineering. On the other hand, the controlled industrial processes are becoming more challenging, with nonlinear characteristics, wherein the guarantee of a good performance is essential. For this purpose, this dissertation proposes the study of several control techniques, as predictive controllers GPC (Generalized Predictive Control), GMV (Generalized Minimum Variance) and DMC (Dynamic Matrix Control), the PID (Proportional-Integral-Derivative) controller and an adaptive PI (Proportional-Integrative) controller. All of these techniques require different tuning parameters, whose fine tuning is crucial on their performance, and in most cases are defined based on the designer's experience and model prior knowledge. Trying to solve this problem, the QEA (Quantum Inspired Evolutionary Algorithm), an optimization algorithm with a quantum computation inspiration will be improved and applied. This new area is being studied and applied to optimization problems and satisfactory results, in terms of performance, are being obtained, due to the states superposition property, in quantum mechanics. To quantify and analyze the performances, the tuned controllers were applied to three nonlinear processes: a distillation column, a pH neutralization tank and a heat exchanger, with the parameters tuning realized by MQEA (Improved Quantum Inspired Evolutionary Algorithm). The obtained results were compared to those obtained by a GA (Genetic Algorithm) approach, by means of performance indicators, as ITSE (Integral Time Squared Error) and convergence and standard deviation means. In most cases, the MQEA presented a superior performance compared to GA, obtaining better results for the processes control.

Keywords: Predictive Control, Quantum Computation, Adaptive Control, PID Control, Optimization, *Quantum Inspired Evolutionary Algorithm*, Genetic Algorithms.

SUMÁRIO

LISTA D	DE FIGURAS	VIII
LISTA D	DE TABELAS	XI
LISTA D	DE SÍMBOLOS	XIII
LISTA D	DE ABREVIATURAS E SIGLAS	XIV
1 IN	IRODUÇÃO	1
1.1	APRESENTAÇÃO DO CONTEXTO	1
1.1.	.1 Controle Proporcional, Integral e Derivativo (PID)	1
1.1.	2 Controle Preditivo	
1.1.	.3 Controle Adaptativo	4
1.1.	.4 Computação Evolutiva	
1.1.	.5 Computação Quântica	7
1.2	OBJETIVO DA PESQUISA	9
1.2.	.1 Objetivo Geral	9
1.2.	2 Objetivos Específicos	9
1.3	JUSTIFICATIVA DA PESQUISA	
1.4	ORGANIZAÇÃO DA DISSERTAÇÃO	
2 FO	RMULAÇÃO CLÁSSICA DOS CONTROLADORES	
2.1	INTRODUÇÃO	
2.2	CONTROLE PID	
2.2.	.1 Controlador PID	
2.2.	.2 Ação Proporcional	
2.2.	.3 Ação Integral	
2.2.	.4 Ação Derivativa	
2.2.	.5 Controlador PID discreto	
2.2.	.6 Sintonia dos Parâmetros de Controladores PID	
2.3	CONTROLE PREDITIVO	
2.3.	.1 GMV – Generalized Minimum Variance Control	
2.3.	2 DMC – Dynamic Matrix Control	
2.3.	.3 GPC – Generalized Predictive Control	
2.4	CONTROLE ADAPTATIVO	
2.4.	.1 Controlador PI Adaptativo de Camacho e outros	
3 AL	GORITMOS GENÉTICOS	
3.1	INTRODUÇÃO	

3.1.	1 Codificação ou Representação	47
3.1.	2 Estratégias de seleção	
3	3.1.2.1 Roleta	48
3	3.1.2.2 Seleção por Torneio	49
3	3.1.2.3 Elitismo	50
3.1.	<i>3 Operadores de reprodução</i>	50
2	3.1.3.1 Operadores de mutação	51
3	3.1.3.2 Operadores de recombinação	51
4 CO	PMPUTAÇÃO QUÂNTICA	
4.1	INTRODUÇÃO	53
4.2	BITS QUÂNTICOS	53
4.3	Q-BITS COMPOSTOS	54
4.4	PORTAS QUÂNTICAS	57
4.4.	1 Porta NOT quântica	58
4.4.	2 Porta CNOT quântica	58
4.4.	3 Porta Hadamard ou porta H	59
4.4.	4 Porta de Rotação	60
5 AL	GORITMOS EVOLUTIVOS INSPIRADOS NA COMPUTAÇÃO QUÂNTICA	61
5.1	REPRESENTAÇÃO	61
5.2	ESTRUTURA DO ALGORITMO	
5.3	PORTA QUÂNTICA DE ROTAÇÃO	64
5.4	MODIFICAÇÃO PROPOSTA	66
6 DE	SCRIÇÃO DOS ESTUDOS DE CASO	68
6.1	INTRODUÇÃO	
6.2	TROCADOR DE CALOR	68
6.3	NEUTRALIZAÇÃO DE PH	72
6.4	COLUNA DE DESTILAÇÃO	75
7 IM	PLEMENTAÇÃO DOS CONTROLADORES	
7.1	PARÂMETROS E CONSIDERAÇÕES INICIAIS	79
7.2	TROCADOR DE CALOR	
7.2.	1 Controle PID	81
7.2.	2 GMV	83
7.2.	3 DMC	85
7.2.	4 GPC	88
7.2.	5 PI Adaptativo	
7.2.	6 Resultados	
7.3	NEUTRALIZAÇÃO DE PH	93
7.3.	.1 Controle PID	

7.3	3.2 GMV	
7.3	3.3 DMC	
7.3	3.4 GPC	
7.3	3.5 PI Adaptativo	
7.3	3.6 Resultados	
7.4	COLUNA DE DESTILAÇÃO	
7.4	4.1 Controle PID	
7.4	4.2 GMV	
7.4	4.3 DMC	
7.4	4.4 GPC	
7.4	4.5 PI Adaptativo	
7.4	4.6 Resultados	
8 CC	ONCLUSÃO	
8.1	PRÓXIMOS TRABALHOS	
9 RI	EFERÊNCIAS BIBLIOGRÁFICAS	

LISTA DE FIGURAS

FIGURA 2.1 – ESTRUTURA DE REALIMENTAÇÃO11
FIGURA 2.2 – ESTRUTURA DE UM CONTROLADOR PID 13
FIGURA 2.3 – CONCEITO DE HORIZONTE DESLIZANTE17
FIGURA 2.4 – ESTRUTURA BÁSICA DE UM MPC18
FIGURA 2.5 – SAÍDA GENERALIZADA DE UM PROCESSO PARA PROJETO DO CONTROLADOR GMV 20
FIGURA 2.6 – DIAGRAMA DE BLOCOS DO CONTROLADOR GMV EM MALHA FECHADA. RETIRADO DE SANTOS (1998)
FIGURA 2.7 – ESTRUTURA DO CONTROLADOR GPC
FIGURA 2.8 – DIAGRAMA DE BLOCOS DE UM CONTROLADOR ADAPTATIVO
FIGURA 2.9 – ESTRUTURA DE ESCALONAMENTO DE GANHOS 39
FIGURA 2.10 – ESTRUTURA MRAS
FIGURA 2.11 - ESTRUTURA STR 41
FIGURA 3.1 – FLUXOGRAMA DOS ALGORITMOS GENÉTICOS 46
FIGURA 3.2 – EXEMPLO DE APLICAÇÃO DO MÉTODO DA ROLETA
FIGURA 3.3 – EXEMPLO DE APLICAÇÃO DO MÉTODO DO TORNEIO
FIGURA 3.4 – EXEMPLO DE UMA MUTAÇÃO 51
FIGURA 3.5 – EXEMPLOS TÍPICOS DE <i>CROSSOVER</i>
FIGURA 5.1 – DIAGRAMA DO FLUXO DO QEA (HAN E KIM, 2002)62
FIGURA 5.2 – PROCEDIMENTOS PARA IMPLEMENTAÇÃO DO QEA (HAN E KIM, 2002)
FIGURA 5.3 – ROTAÇÃO DE UM ¢-BIT NO PLANO POLAR (HAN E KIM, 2002)65
FIGURA 5.4 – ESTRUTURA DO MQEA
FIGURA 6.1 – TROCADOR DE CALOR

FIGURA 6.2 – CURVA ESTÁTICA DO PROCESSO 1
FIGURA 6.3 – REGIÃO A SER CONTROLADA DA CURVA ESTÁTICA DO PROCESSO 1
FIGURA 6.4 – PROCESSO DE NEUTRALIZAÇÃO DE PH72
FIGURA 6.5 – CARACTERÍSTICA NÃO-LINEAR ESTIMADA DO PROCESSO DE NEUTRALIZAÇÃO DE PH
FIGURA 6.6 – CURVA ESTÁTICA DA APROXIMAÇÃO LINEAR DO PROCESSO 2
FIGURA 6.7 – CURVA ESTÁTICA DO PROCESSO 3
FIGURA 6.8 – REGIÃO A SER CONTROLADA DA CURVA ESTÁTICA DO PROCESSO 378
FIGURA 7.1 – (A) AÇÃO DE CONTROLE PID E (B) REFERÊNCIA E SAÍDA DO PROCESSO 1 82
FIGURA 7.2 – VARIAÇÃO DA AÇÃO DE CONTROLE PID PARA O PROCESSO 1
FIGURA 7.3 – (A) AÇÃO DE CONTROLE GMV E (B) REFERÊNCIA E SAÍDA DO PROCESSO 1 84
FIGURA 7.4 – VARIAÇÃO DA AÇÃO DE CONTROLE GMV PARA O PROCESSO 1
FIGURA 7.5 – RESPOSTA DO PROCESSO 1 AO DEGRAU UNITÁRIO
FIGURA 7.6 – (A) AÇÃO DE CONTROLE DMC E (B) REFERÊNCIA E SAÍDA DO PROCESSO 1 87
FIGURA 7.7 – VARIAÇÃO DA AÇÃO DE CONTROLE DMC PARA O PROCESSO 1
FIGURA 7.8 – (A) AÇÃO DE CONTROLE GPC E (B) REFERÊNCIA E SAÍDA DO PROCESSO 1 89
FIGURA 7.9 – VARIAÇÃO DA AÇÃO DE CONTROLE GPC PARA O PROCESSO 1
FIGURA 7.10 – (A) AÇÃO DE CONTROLE PI ADAPTATIVO E (B) REFERÊNCIA E SAÍDA DO PROCESSO 1
FIGURA 7.11 – VARIAÇÃO DA AÇÃO DE CONTROLE PI ADAPTATIVO PARA O PROCESSO 191
FIGURA 7.12 – CONVERGÊNCIA DA MÉDIA DOS MELHORES <i>FITNESS</i> PARA O PROCESSO 1.93
FIGURA 7.13 – (A) AÇÃO DE CONTROLE PID E (B) REFERÊNCIA E SAÍDA DO PROCESSO 2 95
FIGURA 7.14 – VARIAÇÃO DA AÇÃO DE CONTROLE PID PARA O PROCESSO 2
FIGURA 7.15 – (A) AÇÃO DE CONTROLE GMV E (B) REFERÊNCIA E SAÍDA DO PROCESSO 297
FIGURA 7.16 – VARIAÇÃO DA AÇÃO DE CONTROLE GMV PARA O PROCESSO 2

FIGURA 7.17 – RESPOSTA DO PROCESSO 2 AO DEGRAU UNITÁRIO
FIGURA 7.18 – (A) AÇÃO DE CONTROLE DMC E (B) REFERÊNCIA E SAÍDA DO PROCESSO 2.100
FIGURA 7.19 – VARIAÇÃO DA AÇÃO DE CONTROLE DMC PARA O PROCESSO 2 100
FIGURA 7.20 – (A) AÇÃO DE CONTROLE GPC E (B) REFERÊNCIA E SAÍDA DO PROCESSO 2. 102
FIGURA 7.21 – VARIAÇÃO DA AÇÃO DE CONTROLE GPC PARA O PROCESSO 2 102
FIGURA 7.22 – (A) AÇÃO DE CONTROLE PI ADAPTATIVO E (B) REFERÊNCIA E SAÍDA DO PROCESSO 2
FIGURA 7.23 – VARIAÇÃO DA AÇÃO DE CONTROLE PI ADAPTATIVO PARA O PROCESSO 2.
FIGURA 7.24 – CONVERGÊNCIA DA MÉDIA DOS MELHORES <i>FITNESS</i> PARA O PROCESSO 2.
FIGURA 7.25 – (A) AÇÃO DE CONTROLE PID E (B) REFERÊNCIA E SAÍDA DO PROCESSO 3 108
FIGURA 7.26 – VARIAÇÃO DA AÇÃO DE CONTROLE PID PARA O PROCESSO 3 108
FIGURA 7.27 – (A) AÇÃO DE CONTROLE GMV E (B) REFERÊNCIA E SAÍDA DO PROCESSO 3.
FIGURA 7.28 – VARIAÇÃO DA AÇÃO DE CONTROLE GMV PARA O PROCESSO 3 110
FIGURA 7.29 – RESPOSTA DO PROCESSO 3 AO DEGRAU UNITÁRIO 112
FIGURA 7.30 – (A) AÇÃO DE CONTROLE DMC E (B) REFERÊNCIA E SAÍDA DO PROCESSO 3.113
FIGURA 7.31 – VARIAÇÃO DA AÇÃO DE CONTROLE DMC PARA O PROCESSO 3 113
FIGURA 7.32 – (A) AÇÃO DE CONTROLE GPC E (B) REFERÊNCIA E SAÍDA DO PROCESSO 3. 115
FIGURA 7.33 – VARIAÇÃO DA AÇÃO DE CONTROLE GPC PARA O PROCESSO 3 115
FIGURA 7.34 – (A) AÇÃO DE CONTROLE PI ADAPTATIVO E (B) REFERÊNCIA E SAÍDA DO PROCESSO 3
FIGURA 7.35 – VARIAÇÃO DA AÇÃO DE CONTROLE PI ADAPTATIVO PARA O PROCESSO 3.

LISTA DE TABELAS

TABELA 2.1 – EFEITOS DA RESPOSTA DAS AÇÕES P, I E D EM MALHA FECHADA	13
TABELA 5.1 – ÂNGULOS DE ROTAÇÃO DOS q -BIT	65
TABELA 6.1 – CONDIÇÕES DE ESTADO ESTACIONÁRIO (TROCADOR DE CALOR)	69
TABELA 6.2 – CONDIÇÕES NORMAIS DE OPERAÇÃO (NEUTRALIZAÇÃO DE PH)	73
TABELA 6.3 – CONDIÇÕES NORMAIS DE OPERAÇÃO (COLUNA DE DESTILAÇÃO)	76
TABELA 7.1 – RESULTADO PID PARA O PROCESSO 1	81
TABELA 7.2 – RESULTADO GMV PARA O PROCESSO 1	84
TABELA 7.3 – RESULTADO DMC PARA O PROCESSO 1	86
TABELA 7.4 – RESULTADO GPC PARA O PROCESSO 1	88
TABELA 7.5 – RESULTADO PI ADAPTATIVO PARA O PROCESSO 1	90
TABELA 7.6 – RESUMO DE RESULTADOS PARA O PROCESSO 1	92
TABELA 7.7 – RESULTADO DO CONTROLE PID PARA O PROCESSO 2	94
TABELA 7.8 – RESULTADO GMV PARA O PROCESSO 2	96
TABELA 7.9 – RESULTADO DMC PARA O PROCESSO 2	98
TABELA 7.10 – RESULTADO GPC PARA O PROCESSO 2	101
TABELA 7.11 – RESULTADO PI ADAPTATIVO PARA O PROCESSO 2	103
TABELA 7.12 – RESUMO DE RESULTADOS PARA O PROCESSO 2	105
TABELA 7.13 – RESULTADO DO CONTROLE PID PARA O PROCESSO 3	107
TABELA 7.14 – RESULTADO GMV PARA O PROCESSO 3	109
TABELA 7.15 – RESULTADO DMC PARA O PROCESSO 3	111
TABELA 7.16 – RESULTADO GPC PARA O PROCESSO 3	114
TABELA 7.17 – RESULTADO PI ADAPTATIVO PARA O PROCESSO 3	116

TABELA 7.18 - RESUMO DE RESULTADOS PARA O PROCESSO 3.	118
TABELA 8.1 – PERCENTUAL DE MELHORES RESULTADOS ENCONTRADOS	121

LISTA DE SÍMBOLOS

- $|0\rangle$ e $|1\rangle$ Estados quânticos de um q-bit
- $\Gamma(q^{-1})$ Ponderação do Sinal de Referência no Controlador GMV
- ε Esperança Matemática
- $\xi(t)$ Ruído Branco, com Variância igual a 1 e Média Nula
- $\phi(t+d)$ Saída Generalizada do Controlador GMV
- H Porta Quântica de Hadamard
- K_d Ação derivativa em Controladores PID
- K_i Ação integral em Controladores PID
- K_p Ação proporcional em Controladores PID
- λ Ponderação do Sinal de Controle nos Controladores DMC e GPC
- $\lambda(q^{-1})$ Ponderação do Sinal de Controle no Controlador GMV
- N_1 Horizonte de Previsão Inicial para os Controladores DMC e GPC
- N_{u} Horizonte de Previsão de Controle para os Controladores DMC e GPC
- Ny Horizonte de Previsão Final para os Controladores DMC e GPC
- $P(q^{-1})$ Ponderação do Sinal de Saída no Controlador GMV
- y(t) Saída Real do Processo
- $\hat{y}(t)$ Saída Estimada do Processo
- $y_r(t)$ Trajetória de Referência do Processo
- $\boldsymbol{U}_{\scriptscriptstyle CNOT}\,$ Porta Quântica CNOT
- $U(\Delta \theta_i)$ Porta Quântica de Rotação
- u(t) Sinal de Entrada do Processo (Sinal de controle)
- X Porta Quântica NOT
- \otimes Produto Tensorial
- $|\psi\rangle$ q-bit genérico

LISTA DE ABREVIATURAS E SIGLAS

AEICQ	- Algoritmo Evolucionário Inspirado na Computação Quântica
QEA-R	- Algoritmo Evolutivo com Inspiração Quântica usando representação
	Real
AE	- Algoritmo Evolucionário
AG	- Algoritmo Genético
ARX	- Auto-Regressive with eXogenous inputs
CARMA	- Controlled Auto-Regressive Moving Average
CARIMA	- Controlled Auto-Regressive Integrated Moving Average
CE	- Computação Evolutiva ou Evolucionária
CLP	- Controlador Lógico Programável
DMC	- Dynamic Matrix Control
GA	- Genetic Algorithm
GPC	- Generalized Predictive Control
GMV	- Generalized Minimum Variance
GS	- Gain Scheduling
IHS	- Improved Harmony Search
ISE	- Integral Squared Error
ITSE	- Integral Time Squared Error
MIMO	- Multiple-Inputs Multiple-Outputs
MPC	- Model Predictive Control
MQEA	- Modified Quantum Evolutionary Algorithm
MQR	- Mínimos Quadrados Recursivo
MRAS	- Model-Reference Adaptive Control
MRPC	- Model-Reference Predictive Control
MSA	- Multi-Step-Ahead
MSE	- Mean Squared Error
MTRIBES	- Modified Tribes
MV	- Minimum Variance
PID	- Proportional-Integral-Derivative
SISO	- Single-Input Single-Output
SSA	- Single-Step-Ahead

STR	-	Self-Tuning Regulator
q-bit	-	Bit quântico
QEA	-	Quantum Evolutionary Algorithm
QPSO	-	Quantum Particle Swarm Optimization

1 INTRODUÇÃO

1.1 APRESENTAÇÃO DO CONTEXTO

Para que o objetivo principal dessa dissertação seja compreendido, serão apresentados na seqüência, separadamente, os principais conceitos dos diferentes tipos de controle que serão abordados.

1.1.1 Controle Proporcional, Integral e Derivativo (PID)

O controle proporcional, integral e derivativo (PID) é uma das técnicas de controle mais usada na indústria, sendo utilizada em cerca de 95% dos casos (Åström e Hägglund, 1995, 2001; Takatsu e Itoh, 1999; Ogata, 1993), principalmente pelo seu desempenho robusto e facilidade de implementação.

Segundo Faccin (2004), o primeiro controlador proporcional foi desenvolvido em 1914, por E. H. Bristol, patenteando um amplificador bocal palheta, sendo comercializado em 1919 e o primeiro controlador proporcional-integral (PI) foi desenvolvido e patenteado por M. E. Leeds em 1920, sendo comercializado apenas em 1929. Os controladores PID começaram a ser o foco das atenções para aplicações industriais a partir do ano de 1942, quando J. G. Ziegler e N. B. Nichols publicaram o artigo *Optimum Settings for Automatic Controllers*, apresentando regras simples para ajuste dos parâmetros baseado em determinadas características dinâmicas do processo.

O conceito principal na utilização dos controladores PID é a utilização da realimentação do sinal de saída do processo, que, quando subtraído do sinal de entrada, ou referência, gera um erro. Esse erro é o sinal base enviado para o controlador, que o trata de

três formas: proporcionalmente, integralmente e derivativamente. Esse tratamento gera um sinal de controle, que é então enviado aos atuadores do processo para obter uma nova saída.

Diversas aplicações, descritas nos próximos parágrafos, foram realizadas, tanto teórica quanto praticamente com a utilização de controladores PID. São três os parâmetros que devem ser sintonizados em um controlador PID clássico, o ganho proporcional, o ganho integral e o ganho derivativo, para um correto funcionamento do mesmo, ou seja, uma resposta suficientemente rápida com pouco sobre-sinal.

Silva (2005) propôs a utilização de um algoritmo conhecido como *Simulated Annealing*, onde se utiliza um conceito análogo ao do recozimento de metais, para a sintonia de controladores PID, obtendo um bom resultado. Já Fernandes Júnior (2006) desenvolveu um *software* para a re-sintonia de controladores PID, para processos de primeira e segunda ordem, implementado em processos que utilizam o controlador em um controlador lógico programável (CLP), também obtendo resultados satisfatórios.

Salamanca (2007) propôs a sintonia e projeto de controladores PID através da utilização do conceito de dois outros controladores, o *Generalized Predictive Control* (GPC) e o *Generalized Minimum Variance Control* (GMV). Já Caon Júnior (1999) propôs um método de sintonia automática que utiliza realimentação a relês. Lakshminarayanan e Agrawal (2003) propuseram uma metodologia para a sintonia desse tipo de controlador baseado na utilização das informações de entrada e saída do processo em malha fechada para estimar o comportamento servo e de distúrbios do sistema, chegando a um controlador ótimo.

Foram propostos também métodos para a sintonia de controladores PID na sincronização de sistemas caóticos, onde foram utilizados métodos de otimização tais como MTribes (*Modified Tribes*) (Coelho e Bernert, 2009b) e IHS (*Improved Harmony Search*) (Coelho e Bernert, 2009a).

1.1.2 Controle Preditivo

O Controle Preditivo Baseado em Modelos (*Model Predictive Control*, MPC) é um método de controle de processos que vem sendo utilizado principalmente em indústrias petroquímicas e refinarias desde a década de 1980 (Camacho e Bordons, 1997, 2003). A definição de um controlador preditivo é baseada no modelo matemático do processo desejado, obtido através de um dos métodos existentes para a identificação de sistemas, e sua ação tem por objetivo a minimização de uma função objetivo, gerando sinais que atuem de forma a

evitar ou pelo menos diminuir comportamentos indesejáveis aos requisitos de projeto impostos pelo projetista.

Atualmente, abordagens de controle preditivo têm várias aplicações conhecidas na indústria (Qin e Badgwell, 1997). Originalmente, ele foi desenvolvido para as petroquímicas e de geração de energia, mas já é utilizado em áreas como a irrigação de canais (Eklund e Tufvesson, 2001), plantas solares de climatização (Dutra, 2003), reatores de pirólise (Muniz, 2004), regulagem de temperatura de vapor (Arroyo-Figueroa *et al.*, 2004), processo bombatanque (Guiamba e Mulholland, 2004), estufas (Piñón *et al.*, 2002) e colunas de destilação (Karacan, 2003).

Existem alguns tipos de algoritmos já desenvolvidos para a aplicação desse tipo de controlador. Entre eles pode-se citar o DMC - *Dynamic Matrix Control* (Cutler e Ramaker, 1980), o GPC - *Generalized Predictive Control* (Clarke *et al.*, 1987a, Clarke *et al.*, 1987b), o GMV – *Generalized Minimum Variance* (Clarke e Gawthrop, 1975), o MAC – *Model Algorithm Control* (Richalet *et al.* 1976), o EPSAC - *Extended Prediction Self-Adaptive Control* (De Keyser, 1985) e o EHAC - *Extended Horizon Adaptive Control* (Ydstie, 1984). Nesta dissertação serão abordados três desses citados (DMC, GMV, GPC).

Para tentar controlar processos que possuíam não-linearidade, foram propostos alguns algoritmos MPC baseados em modelos não lineares (Wang *et al.*, 2000; Santos, 2007). A desvantagem na utilização desses é a necessidade de técnicas de programação não-lineares, cuja aplicação resulta na resolução de uma quantidade excessiva de cálculos, prejudicando o desempenho do sistema em tempo real.

O controlador DMC foi utilizado por Houk (1996) para realizar o controle de um processo multivariável na refinaria Chevron El Segundo na Califórnia, Estados Unidos da América. Algumas das melhorias resultantes são: a qualidade do produto maior, um menor tempo de processo, redução no gasto de combustível e menor tempo de parada.

Rodrigues e Maciel Filho (1999) descreveram a aplicação de um controlador DMC a um processo de alimentação-batelada de penicilina com restrições operacionais, a fim de se otimizar o processo de produção. O resultado da combinação do controlador com o otimizador foi satisfatório, pois gerou uma resposta suave às restrições criticas mesmo quando o sistema apresentava vários distúrbios.

Maiti e Saraf (1995) propuseram um algoritmo de identificação do processo *online*, utilizando pseudo-impulsos. Para ilustrar isso é aplicado um controlador DMC adaptativo a uma coluna de destilação, tanto no problema servo quanto no regulatório. O algoritmo

automaticamente detecta variações significativas no degrau de entrada e modifica o controlador de forma a que este se adapte ao novo modelo e o resultado seja coerente.

Salamanca (2007) propôs a sintonia e projeto de controladores PID através da utilização do conceito dos controladores GPC e GMV.

O controlador GPC foi aplicado por Altinten (2007) em um processo de neutralização de pH. Foi utilizado um reator tubular Armfield para a realização prática do experimento. Para a sintonia dos parâmetros de controle, foi utilizado um algoritmo genético, visando à minimização de uma função objetivo. O resultado de tal aplicação foi então dado em termos de *Integral Squared Error* (ISE) e *Integral Absolute Error* (IAE).

Lu e Tsai (2007) propõem a utilização de uma rede neuro-nebulosa recorrente para identificação de modelos não lineares que serão aplicados ao controlador GPC com critérios da função objetivo modificados. Essa técnica é aplicada em dois processos, um não-linear teórico e uma máquina de resfriamento de óleo para demonstrar a eficiência da mesma.

Xu e Li (2007) desenvolveram um método simplificado para a aplicação prática do GPC a processos com entradas múltiplas e saídas múltiplas (*Multiple-Inputs Multiple-Outputs* - MIMO). Ele consiste no desacoplamento dos processos em individuais para identificação e aplica um GPC simplificado a eles, com base em uma estrutura PID. O desempenho é avaliado na aplicação do novo conceito à uma unidade de condicionamento de ar.

Todos os controladores preditivos possuem diversos parâmetros para a sintonia, como por exemplo o horizonte de controle, o horizonte de previsão e a ponderação sobre o sinal de controle, os quais são cruciais na resposta satisfatória do sistema e têm sido objeto de estudo de diversos pesquisadores na área, conforme descrito anteriormente.

1.1.3 Controle Adaptativo

O início das pesquisas na área do controle adaptativo data dos anos 1950, com aplicações voltadas principalmente para o desenvolvimento dos sistemas de piloto automático para aeronaves de alto desempenho (Åström e Wittenmark, 1995). As principais dificuldades para tanto, segundo (Åström, 1983), era que havia muito entusiasmo, pouco *hardware* e teoria não existente. A década de 1960, nesta área, foi caracterizada pelo desenvolvimento de conceitos mais sólidos da teoria de controle em geral, como espaço de estados e a teoria de estabilidade. A década de 1970 trouxe mais alguns incrementos teóricos para o controlador

adaptativo como sistemas auto-ajustáveis e a disponibilidade de *hardwares* baratos para o controle digital, mas mesmo assim os resultados teóricos eram limitados.

Os sistemas de controle adaptativo começaram a surgir na indústria, assim como o controle preditivo, no final da década de 1970 e começo da década de 1980. Impulsionados pela corrida industrial da época, e também pelo avanço significativo do desenvolvimento dos *hardwares*, pesquisadores como K. J. Åström, B. Wittenmark, D. W. Clarke e P. J. Gawthrop entre outros começaram a aplicar conceitos desenvolvidos na teoria e controladores como o MV – *Minimum Variance* (Åström e Wittenmark, 1973), o GMV – *Generalized Minimum Variance* (Clarke e Gawthrop, 1975), que é considerado um controlador preditivo adaptativo um passo à frente, os conceitos de MRAS (*Model-Reference Adaptive System*), STC (*Self Tuning Controller*), GS (*Gain Scheduling*), *Auto Tuning*, entre outros, foram inicialmente apresentados.

Diversas aplicações industriais, algumas das quais serão apresentadas nos próximos parágrafos, já foram realizadas na prática com a utilização dos controladores adaptativos, como o controle de motores, o piloto automático de navios, controle de disco rígido, trocadores de calor, geradores de energia solar, entre outros (Åström e Wittenmark, 1995b). Foram descritos nesse mesmo apanhado três aplicações em detalhes.

Ho *et al.* (1999) propuseram a comparação de três controladores adaptativos, com suas respectivas aplicações ao VVS-400, um sistema de ventilação e aquecimento. Os três controladores comparados foram o GPC adaptativo – variação do GPC que utiliza identificação recursiva dos parâmetros da planta, o PID adaptativo baseado no algoritmo de Dahlin e o controlador FUJI da planta VVS-400 – um PID *Auto-tuning*. Os dois primeiros obtiveram resultados satisfatórios em aplicação à planta, com respostas rápidas e com pouco sobre-sinal em comparação com o terceiro.

Sastry e Bodson (1989) apresentaram as diversas estruturas de controle adaptativo existentes, bem como uma análise a respeito da robustez dessas técnicas e melhorias na convergência dos parâmetros.

Camacho *et al.* (1992) propuseram a aplicação de um controlador PI adaptativo a uma planta geradora de energia solar, com campo de coletores distribuídos. Foram comparadas as compensações de distúrbios em série e em paralelo, e no geral, um controle apropriado foi obtido, com um desempenho superior ao PI que era anteriormente aplicado.

Åström e Hägglund (1995) propuseram algumas técnicas auto-tuning para controladores PID, tais quais sintonia em malha fechada, em malha aberta, sintonia por relé,

estimação de parâmetros, sintonia baseada em regras, entre outras. Apresentaram também controladores industriais que utilizam tais métodos de sintonia automática.

Bobál *et al.* (2005) apresentavam diversas técnicas adaptativas para a utilização de controladores PID. Entre elas figuram o PID adaptativo baseados em abordagens Dahlin, Ziegler-Nichols, Bányász e Keviczky e em alocação de pólos.

Os controladores adaptativos não possuem muitos parâmetros para sintonia devido à sua estrutura de controle, mas apresentam vários deles no que diz respeito à subárea de identificação do processo em seus algoritmos.

1.1.4 Computação Evolutiva

A computação evolutiva, como o próprio nome propõe, consiste em métodos de otimização, busca estocástica e projeto em diversas áreas do conhecimento, baseados nos princípios biológicos da evolução natural. Em comparação aos métodos tradicionais de otimização, tais como alguns baseados em cálculo (derivativos) e estratégias enumerativas, os algoritmos evolutivos (AE) são robustos, globais e podem ser aplicados sem a heurística de recursos específicos ao domínio (Han e Kim, 2002). Os algoritmos evolutivos podem ser considerados máquinas de aprendizado inspiradas em mecanismos de seleção natural.

Os principais modelos de algoritmos evolutivos difundidos no decorrer dos últimos 50 anos são os algoritmos genéticos (AG) desenvolvidos por Holland (1975), programação evolucionária (PE) desenvolvida por Fogel, Owens e Walsh (1966), as estratégias evolutivas (EE) desenvolvidas por Rechenberg (1973) e Schwefel (1977) e a programação genética (PG) desenvolvida por Koza (1992).

Os algoritmos evolucionários são caracterizados pela representação de soluções potenciais, que são denotadas por indivíduos, utilizando o seu valor de *fitness*, ou seja, sua adequabilidade em relação à função objetivo para permitir a sobrevivência, ou permanência, dos mais aptos, visando melhores aproximações para a solução do problema proposto. A cada geração, ou seja, a cada iteração do algoritmo, existe uma seleção dos indivíduos que continuarão a ser utilizados, de acordo com o seu nível de aptidão, ou adequabilidade, ao problema.

Os algoritmos genéticos foram inicialmente desenvolvidos por Holland (1975), com o objetivo original de projetar sistemas de decisão inteligentes que possuíssem um autoaprendizado. Para tanto, foi utilizada a base biológica análoga à evolução natural e à genética populacional, englobando os conceitos de seleção natural, cruzamento e mutação. Desde sua introdução, e subseqüente popularização por Goldberg (1989), os algoritmos genéticos vem sendo utilizados como uma ferramenta alternativa de otimização de sistemas (Fleming e Purshouse, 2001).

Os algoritmos genéticos já foram usados como base de otimização para controladores. Oliveira *et al.* (1991) utilizaram o AG padrão para determinar as estimativas iniciais para os valores de um controlador PID. O desempenho do algoritmo foi melhorado de forma a identificar quais os cromossomos-pai utilizados, para não reutilizá-los. Porter e Jones (1992) propuseram uma técnica simples baseada em AG para a sintonia de parâmetros PID.

Vlachos *et al.* (1999) aplicaram a otimização com AG a controladores PI descentralizados. Já Osman *et al.* (2005) e Fleming e Purshouse (2001) utilizaram o algoritmo genético para otimização da resposta de controladores *fuzzy*. Onnen *et al.* (1997) propuseram a utilização do algoritmo para a otimização de um controlador preditivo aplicado a um processo de fermentação em batelada e compararam com resultados existentes, obtendo melhorias.

1.1.5 Computação Quântica

Uma outra maneira de se resolver o problema de sintonia dos parâmetros de todos esses conceitos de controlador citados pode ser a computação quântica.

A computação quântica é um tópico que vem sendo estudado mais freqüentemente nos últimos 15 anos (Narayanan, 1999; Han e Kim, 2002, 2006; Khorsand *et al.*, 2006; Mikki e Kishk, 2006; Cruz, 2007; Araújo, 2008), e consiste na aplicação dos conceitos existentes na teoria de mecânica quântica na área da computação, a fim de se obter um desempenho melhor em termos computacionais.

Para que seja possível entender o funcionamento teórico de um computador quântico e sua grande velocidade de processamento, propõe-se o seguinte exemplo (Oliveira *et al.*, 2003): Ao se jogar duas moedas para cima, cada uma representando um bit de informação, denotando "0" para cara e "1" para coroa, segundo a mecânica clássica, são possíveis 4 resultados, "00", "01", "10" e "11". Cada moeda só exibe uma face de cada vez. Pensando na mecânica quântica, cada uma dessas moedas poderia representar uma situação inimaginável para os padrões clássicos, onde poderiam ao mesmo tempo apresentar a face "cara" e a "coroa".

Essa propriedade da mecânica quântica é conhecida por "superposição de estados", ou seja, podem ser colocados como combinações de outros estados. Isso resulta na análise simultânea de todos os estados possíveis. Em computadores clássicos, apesar dos estados estados estarem superpostos na teoria quântica, o ato de observar esse estado o transforma em um bit clássico, destruindo essa superposição.

Para representar essa superposição são utilizados os bits quânticos, ou q-bits, que podem possuir o valor "0", "1"ou qualquer combinação entre eles. Essa característica dos q-bits gera um paralelismo importante na busca de parâmetros ou valores para otimização, havendo um ganho importante de tempo em comparação com os métodos clássicos, como por exemplo em um algoritmo de fatoração, onde se deseja encontrar quais os dois números primos multiplicados que resultam em um valor X. Com os computadores clássicos e a utilização dos algoritmos sofisticados para a busca, levaria anos para que a solução fosse encontrada, e no computador quântico seria questão de segundos (Oliveira *et al.*, 2003; Cruz, 2007).

A maioria das aplicações relativas a esse conceito de computação quântica retrata a otimização de parâmetros de algoritmos evolutivos. Han e Kim propuseram um algoritmo evolucionário-quântico para a resolução de problemas de otimização combinatorial (Han e Kim, 2002) e realizaram diversas análises (Han e Kim, 2006).

Khorsand *et al.* (2006), desenvolveram um algoritmo genético-quântico para o projeto de padrões de atuadores piezos-elétricos. O resultado obtido para a síntese desses atuadores utilizando a *Quantum Genetic Algorithm* (QAG) foi satisfatório, sendo mais rápida que os métodos existentes e gerando um erro menor.

Para diversas aplicações eletromagnéticas na área de síntese de antenas, foi proposto um algoritmo de enxame de partículas quântico (QPSO), em Mikki e Kishk (2006). A implementação do método proposto superou o método clássico de enxame em todos as aplicações realizadas.

Cruz (2007) propõe um novo algoritmo evolutivo com inspiração quântica usando representação real para problemas de otimização numérica, chamado de Algoritmo Evolutivo com Inspiração Quântica usando Representação Real (QEA-R). O trabalho apresenta a modelagem deste algoritmo para a solução de problemas teste de otimização numérica, assim como no treinamento de redes neurais recorrentes em problemas de aprendizado supervisionado de séries temporais e em aprendizado por reforço em tarefas de controle. Os resultados obtidos demonstraram a eficiência desse algoritmo proposto.

Araújo (2008), desenvolveu um algoritmo evolucionário inspirado na computação quântica (AEICQ) para a otimização de projetos de circuitos eletrônicos na etapa de atribuição de estados e também na de síntese de lógica. Os resultados mostraram que as atribuições de estados obtidas pelo AEICQ conduzem a implementação de circuitos de menor complexidade, sugerindo que existe um potencial de aplicação desta classe de algoritmos no projeto de circuitos eletrônicos.

1.2 OBJETIVO DA PESQUISA

1.2.1 Objetivo Geral

O objetivo geral dessa dissertação é o desenvolvimento de uma abordagem de sintonia dos parâmetros de cinco algoritmos de controle, incluindo o controle PID, o controle preditivo, abrangendo o GMV, o DMC e o GPC, e o controle adaptativo, com a adoção do controlador adaptativo de Camacho *et al.* (1992). A técnica de sintonia a ser desenvolvida utilizará como base a inspiração no conceito de computação quântica.

1.2.2 Objetivos Específicos

Como objetivos específicos nessa dissertação, a abordagem de sintonia dos controladores com inspiração quântica utilizada será aplicada aos controladores, assim como os algoritmos genéticos, que realizarão o controle de três processos não lineares, o trocador de calor, o processo de neutralização de pH e a coluna de destilação, com o intuito de comparar o desempenho dos controladores quando sintonizados via algoritmos genéticos e via *Modified Quantum Inspired Evolutive Algorithm* (MQEA) proposto. Tal comparação será realizada por meio de critérios de desempenho, tais como o *Integral Time Squared Error* (ITSE), desvio padrão e convergência.

1.3 JUSTIFICATIVA DA PESQUISA

Como justificativa aos objetivos propostos, devem ser salientadas as aplicações do conceito de computação quântica com algoritmos evolutivos, apresentada em diversos trabalhos, tais quais Narayanan (1999), Han e Kim (2002, 2006), Khorsand *et al.* (2006), Mikki e Kishk (2006), Cruz (2007) e Araújo (2008).

Todas essas aplicações citadas foram bem sucedidas na aplicação desse conceito inovador, o que, combinado com o conhecimento das dificuldades apresentadas na sintonia de controladores lineares em processos não-lineares, motiva o estudo para o desenvolvimento de controladores que utilizem a computação evolucionária inspirada na computação quântica como um algoritmo de sintonia dos seus parâmetros.

1.4 ORGANIZAÇÃO DA DISSERTAÇÃO

O restante da dissertação está organizado da seguinte forma. No capítulo 2 são apresentadas as formulações necessárias dos controladores para o posterior desenvolvimento do projeto. O capítulo 3 contém a teoria e conceitos a respeito da computação evolutiva e algoritmos genéticos. O capítulo 4 possui as explanações teóricas a respeito do conceito de computação quântica. No capítulo 5 está descrito o algoritmo evolutivo baseado em inspiração quântica. Já no capítulo 6 são descritos os três processos que serão analisados e testados com os controladores como estudo de caso e, por fim, os capítulos 7 e 8 apresentam a aplicação dos algoritmos de otimização aos controladores, os resultados e conclusões.

2 FORMULAÇÃO CLÁSSICA DOS CONTROLADORES

2.1 INTRODUÇÃO

Neste capítulo são formalizadas determinadas estratégias de controle, abordando diversos modelos de controladores, de forma que os conceitos necessários para a implementação dos seus algoritmos sejam apresentados. Serão abordadas nessa dissertação três estratégias: PID, controle adaptativo e controle preditivo.

2.2 CONTROLE PID

O controle PID é um termo usualmente usado para denotar o controle com as ações Proporcional, Integral e Derivativa. Apesar do acentuado desenvolvimento na teoria de controle, a maioria dos processos industriais ainda são controlados por PIDs bem sintonizados (Åström e Hägglund, 1995; Ogata, 2003). A popularidade desse controlador pode ser atribuída a sua simplicidade, em termos de projeto e sintonia de parâmetros, e por seu desempenho em uma ampla gama de condições de operação (Coelho e Bernert, 2009b).

O conceito do controlador PID é baseado na teoria da realimentação, que possui a estrutura apresentada na figura 2.1.



Figura 2.1 – Estrutura de realimentação.

A realimentação foi a base para que os controladores *on-off*, mais simples utilizados na industria (Caon Junior, 1999; Faccin, 2004; Silva, 2005), surgissem, acionando o sinal de controle quando o erro fosse maior que zero e desacionando quando fosse menor. O problema existente nesse conceito de controle é que sempre a ação corretiva máxima, ou seja, o sinal de controle máximo seria utilizado. Para atenuar esse efeito de "força máxima", foi implementado nessa estrutura de controle por realimentação uma região proporcional, onde o controlador reagiria seguindo uma rampa, com variações nos valores do sinal de controle dependendo dos valores de erro encontrados. Um problema vinculado a esse novo controlador é a aparição de um erro estático ou em estado estacionário no sistema (Åström e Hägglund, 1995). Para evitar esse problema, surgiu então a necessidade de um controlador que trabalhasse com outras ações além da proporcional, o que deu origem ao PID.

2.2.1 Controlador PID

O controlador PID teve sua fórmula descoberta empiricamente (Åström e Hägglund, 1995), inicialmente com controle apenas proporcional com Edgar Bristol na década de 1910 e nas duas décadas seguintes com Morris Leeds utilizando a ação integral e com Ralph Clarridge utilizando as três ações de controle juntas pela primeira vez (Faccin, 2004). A equação que representa esse novo controlador, no domínio *s*-contínuo (operadores de Laplace), é dada por:

$$G_{PID}(s) = P + I + D = \frac{U(s)}{E(s)} = K_p + \frac{K_i}{s} + K_d \cdot s , \qquad (2.1)$$

onde U(s) e E(s) são a ação de controle (saída do controlador) e o sinal de erro relativo à referência no domínio *s*, respectivamente; K_p é o ganho proporcional, K_i é o ganho integral e K_d é o ganho derivativo. A equação (2.1) pode ser escrita como (2.2).

$$G_{PID}(s) = K_p \cdot \left(1 + \frac{1}{T_i \cdot s} + T_d \cdot s\right), \tag{2.2}$$

onde K_p é o ganho proporcional, T_i é o tempo de ação integral ou tempo de *reset* e T_d é o tempo da ação derivativa.

Neste contexto, um controlador PID no domínio do tempo pode ser escrito como:

$$u(t) = K_p \cdot e(t) + K_i \int_0^t e(\tau) d\tau + K_d \cdot \frac{de(t)}{dt}, \qquad (2.3)$$

onde $u(t) \in e(t)$ são os sinais de controle e erro em relação à referência no domínio do tempo, respectivamente.

A estrutura de um controlador PID em paralelo pode ser verificada na figura 2.2.



Figura 2.2 – Estrutura de um controlador PID.

No PID, cada ação tem efeitos diferentes sobre a resposta final do sistema quando da aplicação de um controlador ao processo. Tais reflexos sobre a resposta final podem ser conferidos na tabela 2.1, esta proveniente de Fernandes Junior (2005).

Resposte MF	Tempo de	Sobre elevação	Tempo de	Erro
Resposta MIT	Subida	5001 C-CIC vaça0	Estabilização	Estacionário
Proporcional	Diminuição	Aumento	Sem alteração	Diminuição
Integral	Diminuição	Aumento	Aumento	Eliminação
Derivativo	Sem alteração	Diminuição	Diminuição	Sem alteração

Tabela 2.1 – Efeitos da resposta das ações P, I e D em Malha Fechada

2.2.2 Ação Proporcional

Quando se deseja utilizar apenas a ação proporcional de um PID, a equação (2.3) se reduz a:

$$u(t) = K_p \cdot e(t) \,. \tag{2.4}$$

Pode-se verificar que a ação de controle u(t) é simplesmente proporcional ao erro de controle e(t). A utilização desse controle P, como é denominado, pode resultar em um erro de estado estacionário, onde o valor da saída não chega à referência, impossibilitando o erro nulo.

2.2.3 Ação Integral

A principal função do termo integral em um controlador PID é garantir que o sistema alcance a estabilidade em malha fechada. Para sua implementação, a saída do controlador é dada em função do erro e também da integral do erro, conforme demonstrado em (2.5), tal que

$$u(t) = K_p \cdot e(t) + K_i \int_0^t e(\tau) d\tau .$$
(2.5)

onde K_p , K_i , u(t) e e(t) são o ganho proporcional, o ganho integral, o sinal de controle e erro no domínio de tempo, respectivamente.

A componente integral adiciona um pólo na origem da função de transferência do controlador, eliminando dessa forma, se o sistema for estável em malha fechada, o erro estacionário de posição. Como apresentado na tabela 2.1, o aumento do ganho integral eleva o tempo de estabilidade e o sobre-sinal, piorando a estabilidade relativa. Como conseqüência, o ganho da ação proporcional deve ser reduzido, sempre que esta esteja combinada com a ação integral.

2.2.4 Ação Derivativa

A principal função do termo derivativo em um controlador PID é reduzir as oscilações na reposta e diminuir a sua sobre-elevação. Em sua formulação, a saída do controlador será dada em função do erro, da integral do erro e também da sua derivada, de forma que

$$u(t) = K_{p} \cdot e(t) + K_{i} \int_{0}^{t} e(\tau) d\tau + K_{d} \cdot \frac{de(t)}{dt}, \qquad (2.6)$$

onde u(t) e e(t) são o sinal de controle e erro no domínio de tempo, respectivamente.

Para um processo de segunda ordem, um ganho proporcional elevado tem o efeito de reduzir o tempo de subida e o erro estacionário, sem que haja sua eliminação. Por outro lado, a adição do ganho integral resultará na eliminação desse erro estacionário, mas tornará a saída mais oscilatória, ou seja, piorará a sua resposta transitória. A utilização do ganho derivativo, então, tem como principal conseqüência uma melhoria da estabilidade do sistema, reduzindo a sobre-elevação e melhorando a resposta transitória do sistema (Ogata, 1993).

2.2.5 Controlador PID discreto

Para que seja possível a implementação prática de um controlador PID descrito no domínio de Laplace ele deve ser convertido para um formato discreto ou digital. Uma das maneiras de se realizar tal procedimento é a utilização de aproximação discreta das derivadas contínuas utilizando aproximação retangular inversa, ou *backward*, aproximação retangular direta, ou *forward* e a aproximação de Tustin ou aproximação trapezoidal (Årzén, 1999; Coelho e Bernert, 2009a, 2009b).

Usando as aproximações trapezoidais na equação (2.3) para a obtenção da lei de controle discreta, tem-se que:

$$u(k) = u(k-1) + K_p \cdot \left[e(k) - e(k-1)\right] + K_i \cdot \frac{T_s}{2} \cdot \left[e(k) - e(k-1)\right] + K_d \cdot \frac{T_s}{2} \cdot \left[e(k) - 2e(k-1) + e(k-2)\right]$$
(2.7)

onde T_s é o período de amostragem e k é a amostra.

2.2.6 Sintonia dos Parâmetros de Controladores PID

Conforme visto anteriormente, são três os parâmetros que devem ser sintonizados em um controlador PID para um correto controle do sistema, ou seja, uma resposta suficientemente rápida com pouco sobre-sinal, acoplado a um sistema, onde K_p é o ganho proporcional, K_i é o ganho integral e K_d é o ganho derivativo.

Vários métodos foram propostos para a correta sintonia deles (Åström e Hägglund, 1995, 2001; Silva, 2005; Salamanca, 2007; Coelho e Bernert, 2009a; Coelho e Bernert, 2009b). Os clássicos são o de Ziegler-Nichols, tanto com a utilização da resposta ao degrau quanto da resposta em freqüência.

2.3 CONTROLE PREDITIVO

No fim dos anos 70, uma nova classe de controladores foi desenvolvida e tem sido consideravelmente aprimorada desde então. Cada controlador possui suas características e elementos diferenciados, mas em termos gerais, a composição de um controlador preditivo baseado em modelos pode ser dividida em três (Camacho e Bordons, 2003):

- Modelo de previsão,
- Função objetivo e
- Lei de controle.

O modelo de previsão é a base de um controlador preditivo, tendo em vista que qualquer controle depende de um procedimento apropriado de identificação do processo para que possa obter resultados satisfatórios. Tais modelos podem ainda serem separados em modelos do processo e modelos de distúrbio.

Os modelos de processo são utilizados pela necessidade de se calcular as saídas previstas em um determinado instante de tempo $\hat{y}(t+k|t)$, relacionando as saídas obtidas com as entradas medidas. Existem diversos modelos de processo utilizados em controladores preditivos, tais quais: resposta ao impulso, resposta ao degrau, modelos de função transferência, modelos no espaço de estados e não lineares. Os modelos de distúrbio são tão importantes quanto os de processo e representam os distúrbios mensuráveis que podem ser encontrados em um sistema real.

Existem dois tipos de controladores preditivos no que se diz respeito à previsão de saída da resposta, os *Single-Step-Ahead* (SSA), que realizam a previsão apenas um passo a frente e os *Multi-Step-Ahead* (MAS), que realizam a previsão *k* passos a frente. Dos controladores que serão abordados nessa dissertação, o GMV pertence à classe dos SSA, enquanto o DMC e o GPC pertencem à classe dos MAS.

Os controladores preditivos, além do conceito de horizonte deslizante apresentado, possuem também o conceito de separação da resposta, no que se diz respeito a dados que são conhecidos no presente e dados futuros, sendo os primeiros denotados por resposta livre e os últimos por resposta forçada, sendo esta, geralmente, o esforço de controle futuro. Esses conceitos são ilustrados na figura 2.3.



Figura 2.3 – Conceito de horizonte deslizante.

A estrutura básica de um MPC é representada na figura 2.4.



Figura 2.4 – Estrutura básica de um MPC.

A função objetivo é utilizada para encontrar a lei de controle, e é diferenciada entre os diversos controladores preditivos baseados em modelo existentes, mas todas se baseiam no mesmo conceito. A idéia principal de tal função é que as saídas futuras y(t) devam seguir uma determinada trajetória de referência $y_r(t)$ minimizando, ao mesmo tempo, o esforço de controle Δu . A função de transferência genérica é dada por:

$$J = \sum_{j=N_1}^{N_y} [\hat{y}(t+k \mid t) - y_r(t+k)]^2 + \sum_{j=1}^{N_u} \lambda [\Delta u(t+k-1)]^2 .$$
(2.8)

Para a obtenção da lei de controle, ou seja, os valores u(t+k|t), é necessária a minimização da função objetivo J. Para que isso seja possível, as saídas previstas $\hat{y}(t+k|t)$ são calculadas em função das entradas e saídas passadas e também dos sinais de controle futuros, fazendo uso do modelo de previsão escolhido. As saídas previstas são então substituídas na função objetiva, que, quando minimizada leva aos valores de controle desejados. A cada iteração é utilizado apenas o primeiro valor encontrado do sinal de controle, recalculando toda a previsão a cada passo do algoritmo, o que é conhecido como horizonte deslizante.

Em resumo, as principais características dos MPCs são:

- Uso de um modelo explícito para a previsão das saídas;
- Cálculo do controle minimizando uma função objetivo;
- Estratégia de horizonte deslizante.

Na seqüência serão apresentados os três conceitos de controle já descritos anteriormente: o GMV, o DMC e o GPC. Todas as deduções e explicações são realizadas para o caso SISO.

2.3.1 GMV – Generalized Minimum Variance Control

O conceito de variância mínima (*Minimum Variance*, MV) foi inicialmente desenvolvido por Åström e Wittenmark em 1973, a fim de minimizar a variância do sinal de saída para o controle da espessura de folhas de papel em uma máquina de papel. A razão principal para a utilização dessa técnica está em sua simplicidade, facilidade na interpretação e implementação (Katebi e Ordys, 1996).

O conceito da MV é baseado na minimização, em cada instante de amostragem, do quadrado da diferença entre a saída y(t) do processo e a referência $y_r(t)$, quando o processo possui um atraso de *d* instantes de tempo, ou seja:

$$J = \varepsilon \{ [y(t+d) - y_r(t)]^2 \},$$
(2.9)

onde ε é a esperança matemática.

O conceito de MV provou não ser eficiente em processos de fase não-mínima e que possam gerar *inter-sampling ripple*, ou seja, o processo pode ser instável e coincidir com os pontos da referência só nos instantes de amostragem (Santos, 1998; Katebi e Ordys, 1996, Salamanca, 2007).

A fim de obter uma solução para esses problemas, Clarke e Gawthrop (1975), propuseram o controlador de mínima variância generalizado, o GMV. Esse novo conceito foi bem explanado nos anos 70 com (Clarke e Gawthrop, 1975, 1979; Gawthrop, 1977). O controlador GMV foi proposto, inicialmente, para ser um controlador adaptativo, pois pode ser realizado com estimador de parâmetros ao invés do modelo explicito do processo.

A saída generalizada, baseada nas variáveis apresentadas, do controlador GMV pode ser observada na figura 2.5:


Figura 2.5 - Saída generalizada de um processo para projeto do controlador GMV.

onde $A(q^{-1})$ é o polinômio auto-regressivo, $B(q^{-1})$ é o polinômio do sinal de entrada, $C(q^{-1})$ é o polinômio da média móvel, $P(q^{-1})$ é o polinômio de ponderação do sinal de saída, $\lambda(q^{-1})$ é o polinômio de ponderação do sinal de controle, $\Gamma(q^{-1})$ é o polinômio de ponderação do sinal de referência, y(t) é a saída do sistema, u(t) é a entrada, $\xi(t)$ é um ruído branco, $y_r(t)$ é a referência e $\phi(t)$ é a saída generalizada.

Modelo do Processo:

Para a realização da previsão do processo, o GMV utiliza um modelo paramétrico do tipo CARMA (*Controlled Auto-Regressive Moving Average*), representado pela seguinte equação a diferenças:

$$A(q^{-1})y(t) = q^{-d}B(q^{-1})u(t) + C(q^{-1})\xi(t), \qquad (2.10)$$

tal que

$$A(q^{-1}) = 1 + a_1 q^{-1} + \dots + a_{na} q^{-na}$$
$$B(q^{-1}) = b_0 + b_1 q^{-1} + \dots + b_{nb} q^{-nb}$$

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

onde u(t) é a entrada do sistema (sinal de controle), y(t) é a saída do sistema, $\xi(t)$ é um ruído branco e d é um atraso de transporte conhecido para efeitos de projeto.

Previsão e Função Objetivo:

O objetivo do controlador GMV é prever uma saída generalizada $\phi(t)$ que possua o mínimo de variância na diferença quadrática entre a saída y(t) e a referência $y_r(t)$, acrescentada de uma ponderação no sinal de controle u(t). Tem-se então:

$$J = \varepsilon \{ [\phi(t+d)]^2 \}, \qquad (2.11)$$

tal que

$$\phi(t+d) = P(q^{-1})y(t+d) + \lambda(q^{-1})u(t) - \Gamma(q^{-1})y_r(t),$$

onde $P(q^{-1})$, $\lambda(q^{-1}) \in \Gamma(q^{-1})$ são polinômios de ponderação da saída, controle e referência, respectivamente.

Multiplicando a equação (2.10) por $E(q^{-1})$, tem-se que:

$$E(q^{-1})A(q^{-1})y(t) = q^{-d}E(q^{-1})B(q^{-1})u(t) + E(q^{-1})C(q^{-1})\xi(t).$$
(2.12)

Seja a seguinte identidade polinomial:

$$P(q^{-1})C(q^{-1}) = A(q^{-1})E(q^{-1}) + q^{-d}S(q^{-1}), \qquad (2.13)$$

onde

$$E(q^{-1}) = 1 + e_1 q^{-1} + \dots + e_{ne} q^{-ne}, \quad n_e = d - 1$$

$$S(q^{-1}) = s_0 + s_1 q^{-1} + \dots + s_{ns} q^{-ns}, \quad n_s = \max(n_a - 1, n_P + n_C - d).$$

Isolando o termo $A(q^{-1})E(q^{-1})$ da equação (2.13) e substituindo na equação (2.12), tem-se

$$[P(q^{-1})C(q^{-1}) - q^{-d}S(q^{-1})]y(t) = q^{-d}E(q^{-1})B(q^{-1})u(t) + E(q^{-1})C(q^{-1})\xi(t)$$

$$P(q^{-1})C(q^{-1})y(t+d) = E(q^{-1})B(q^{-1})u(t) + S(q^{-1})y(t) + E(q^{-1})C(q^{-1})\xi(t+d).$$
(2.14)

A fim de obter a saída generalizada $\phi(t)$ conforme equação (2.9), a ambos os lados da equação (2.14) deve ser adicionado o termo $[\lambda(q^{-1})C(q^{-1})u(t) - \Gamma(q^{-1})(q^{-1})y_r(t)]$, resultando, após simplificações, no seguinte:

$$\phi(t+d) = \frac{\{[E(q^{-1})B(q^{-1}) + \lambda(q^{-1})C(q^{-1})]u(t) - \Gamma(q^{-1})C(q^{-1})y_r(t) + S(q^{-1})y(t)\}}{C(q^{-1})} + E(q^{-1})\xi(t+d)),$$

(2.15)

onde o primeiro termo representa os valores conhecidos no instante t (presente) e o segundo representa valores futuros.

Lei de Controle:

Para a obtenção da lei de controle do GMV, deve-se agir de forma análoga ao processo de minimização da função objetivo do controle de variância mínima, ou seja, o termo com todos os valores conhecidos no instante t da equação (2.15) é igualado a zero, resultando na seguinte equação:

$$[E(q^{-1})B(q^{-1}) + \lambda(q^{-1})C(q^{-1})]u(t) = \Gamma(q^{-1})C(q^{-1})y_r(t) - S(q^{-1})y(t).$$
(2.16)

A lei de controle pode ser obtida no seguinte formato RST, ou seja, utilizando o seguinte conceito de controle:

$$S(q^{-1})y(t) + R(q^{-1})u(t) + T(q^{-1})y_r(t) = 0, \qquad (2.17)$$

onde

$$R(q^{-1}) = E(q^{-1})B(q^{-1}) + \lambda(q^{-1})C(q^{-1})$$
$$T(q^{-1}) = \Gamma(q^{-1})C(q^{-1}).$$

e as ordens dos polinômios $T(q^{-1})$, $S(q^{-1})$ e $R(q^{-1})$ são respectivamente $n_T = n_P + n_C$, $n_s = n_A - 1$ e $n_R = n_B + d - 1$.

A figura 2.6 representa o controlador GMV no formato proposto:



Figura 2.6 – Diagrama de blocos do controlador GMV em malha fechada. Retirado de Santos (1998).

onde $A(q^{-1})$ é o polinômio auto-regressivo, $B(q^{-1})$ é o polinômio do sinal de controle, $C(q^{-1})$ é o polinômio da média móvel, $R(q^{-1})$, $T(q^{-1})$ e $S(q^{-1})$ são os polinômios do controlador, y(t) é a saída do sistema, u(t) é o sinal de controle, $\xi(t)$ é o um ruído branco e $y_r(t)$ é a referência.

Substituindo a equação da lei de controle (2.17) na equação do processo (2.9) é obtida a equação de malha fechada do processo com o controlador:

$$A(q^{-1})y(t) = q^{-d}B(q^{-1})\left(\frac{-T(q^{-1})y_r(t) - S(q^{-1})y(t)}{R(q^{-1})}\right) + C(q^{-1})\xi(t)$$
$$y(t) = \left(\frac{q^{-d}B(q^{-1})\Gamma(q^{-1})}{P(q^{-1})B(q^{-1}) + A(q^{-1})\lambda(q^{-1})}\right)y_r(t) + \left(\frac{B(q^{-1})E(q^{-1}) + \Gamma(q^{-1})C(q^{-1})}{P(q^{-1})B(q^{-1}) + A(q^{-1})\lambda(q^{-1})}\right)\xi(t)$$
(2.18)

Portanto, com base na equação (2.18), a equação característica de um sistema com controlador GMV é:

$$P(q^{-1})B(q^{-1}) + A(q^{-1})\lambda(q^{-1}) = P_{MF}(q^{-1}).$$
(2.19)

Parâmetros para sintonia:

Conforme demonstrado, os parâmetros para a sintonia de um controlador GMV são três: o polinômio de ponderação da saída ($P(q^{-1})$), o polinômio de ponderação da referência ($\Gamma(q^{-1})$) e o polinômio de ponderação do controle ($\lambda(q^{-1})$).

Observações:

Para que o sistema apresente erro nulo em regime permanente, deve-se utilizar como parâmetro de projeto $\lambda(q^{-1}) = \lambda_0(1-q^{-1})$, trabalhando como uma ponderação incremental, ou realizar todas as deduções com a utilização de um modelo CARIMA (*Controlled Auto-Regressive Integrated Moving Average*). Também se pode utilizar, de forma a igualar a saída encontrada da referência, a seguinte equação:

$$\frac{B(q^{-1})\Gamma(q^{-1})}{P(q^{-1})B(q^{-1}) + A(q^{-1})\lambda(q^{-1})}\Big|_{q=1} = 1.$$
(2.20)

Com a utilização do polinômio $\lambda(q^{-1})$, pode-se tratar sistemas de fase não-mínima e instáveis em malha aberta. Com a correta sintonia dos polinômios $P(q^{-1})$ e $\Gamma(q^{-1})$, pode-se eliminar o efeito do sobre-sinal na resposta final do sistema (Santos, 1998).

Se os polinômios $P(q^{-1}) = \Gamma(q^{-1}) = 1$ e $\lambda(q^{-1}) = 0$ a função objetivo se torna a mesma proposta por Åström e Wittenmark (1973) no controlador de variância mínima $(J = \varepsilon \{ [y(t+d) - y_r(t)]^2 \}).$

Passos para Implementação:

Para se realizar a implementação do controlador GMV, deve-se seguir os passos apresentados na seqüência:

- 1. Especificar o modelo: vetor com coeficientes da saída $A(q^{-1})$, vetor com coeficientes de controle $B(q^{-1})$ e vetor de distúrbios $C(q^{-1})$.
- 2. Definir os parâmetros de projeto: o polinômio de ponderação da saída $P(q^{-1})$, o polinômio de ponderação da referência $\Gamma(q^{-1})$ e o polinômio de ponderação do controle $\lambda(q^{-1})$.
- 3. Calcular recursivamente um passo dos vetores $E(q^{-1})$ e $S(q^{-1})$ para obter a resolução da equação diofantina.
- 4. Calcular e aplicar o sinal de controle, através da estrutura RST.
- 5. Voltar para o passo 3.

2.3.2 DMC – Dynamic Matrix Control

O controle DMC foi desenvolvido no final dos anos 70 por Cutler e Ramaker (1980), engenheiros químicos da Shell Oil Co., para aperfeiçoar o controle das plantas de refino, e tem sido aceito amplamente nas indústrias, principalmente petroquímicas (Qin e Badgwell, 1997).

O conceito do algoritmo DMC é modelar a saída do processo, y(t), em um instante de tempo discreto por meio da resposta ao degrau discreto g(i). O processo deve ser assumido estável e causal, pois apenas um número N de amostras é considerado (Camacho e Bordons, 2003).

Como está enquadrado no conceito de horizonte deslizante, possui tanto um horizonte de previsão Ny final, um horizonte de previsão inicial N_1 , quanto um horizonte de controle Nu, que é descartado e recalculado a cada iteração.

Previsão do Modelo:

O modelo matemático do processo utilizado pelos controladores DMC é encontrado com a aplicação de um degrau unitário na planta, considerando o distúrbio constante, ou seja:

$$y(t) = \sum_{i=1}^{\infty} g(i)\Delta u(t-i),$$
 (2.21)

onde g(i) é o elemento da resposta ao degrau no instante *i*.

A previsão ao longo do horizonte se dá então por:

$$\hat{y}(t+k|t) = \sum_{i=1}^{\infty} g(i)\Delta u(t+k-i) + \hat{n}(t+k|t) =$$

$$\sum_{i=1}^{k} g(i)\Delta u(t+k-i) + \sum_{i=k+1}^{\infty} g(i)\Delta u(t+k-i) + \hat{n}(t+k|t),$$
(2.22)

onde $\hat{n}(t+k \mid t)$ é a previsão do distúrbio k instantes adiante no instante t.

Como foi assumido que o distúrbio é constante no horizonte, ou seja, $\hat{n}(t+k \mid t) = \hat{n}(t \mid t) = y_m(t) - \hat{y}(t \mid t)$. Pode-se escrever então que:

$$\hat{y}(t+k|t) = \sum_{i=1}^{k} g(i)\Delta u(t+k-i) + \sum_{i=k+1}^{\infty} g(i)\Delta u(t+k-i) + y_m(t) - \sum_{i=1}^{\infty} g(i)\Delta u(t-i) = \sum_{i=1}^{k} g(i)\Delta u(t+k-i) + \hat{f}(t+k),$$
(2.23)

onde f(t+k) é a resposta livre do sistema, ou seja, a parte que não depende das ações futuras de controle. Tal resposta é dada por:

$$\hat{f}(t+k) = y(t) + \sum_{i=1}^{\infty} [g(k+i) - g(i)] \Delta u(t-i).$$
(2.24)

Assumindo então que o processo é estável e causal, os coeficientes g(i) tendem a um valor constante após N períodos, podendo-se considerar então que $\Delta g(i) = g(k+i) - g(i) \approx 0$, para i > N.

O próximo passo do algoritmo agora é calcular todas as previsões de saída no horizonte de previsão ($k = N_1, ..., N_y$) considerando Nu ações de controle, ou seja:

$$\hat{y}(t+N_{1} \mid t) = g(N_{1})\Delta u(t) + \hat{f}(t+N_{1})$$

$$\hat{y}(t+N_{1}+1 \mid t) = g(N_{1}+1)\Delta u(t) + g(N_{1})\Delta u(t+N_{1}) + \hat{f}(t+N_{1}+1)$$

$$\vdots$$

$$\hat{y}(t+Ny \mid t) = \sum_{i=Ny-Nu+1}^{Ny} g(i)\Delta u(t+Ny-i) + \hat{f}(t+Ny).$$
(2.25)

Partindo das previsões encontradas, pode-se definir a matriz dinâmica G do sistema como:

$$G = \begin{bmatrix} g(N_1) & 0 & \cdots & 0 \\ g(N_1 + 1) & g(N_1) & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ g(Ny) & g(Ny - 1) & \cdots & g(Ny - Nu + 1) \end{bmatrix}.$$
 (2.26)

Pode-se então escrever a previsão em forma vetorial, da seguinte maneira:

$$\hat{Y} = G\Delta u + \hat{f} , \qquad (2.27)$$

onde *G* é a matriz dinâmica do sistema, apresentada em (2.26), $\hat{Y} = [\hat{y}(t+N_1) \ \hat{y}(t+N_1+1) \ \cdots \ \hat{y}(t+Ny)]^T$ é a saída estimada do processo, $\Delta u = [\Delta u(t) \ \Delta u(t+1) \ \cdots \ \Delta u(t+Nu-1)]^T$ é a variação do sinal de controle do processo e $\hat{f} = [\hat{f}(t+N_1) \ \hat{f}(t+N_1+1) \ \cdots \ \hat{f}(t+Ny)]^T$ é a saída livre do processo.

A matriz dinâmica do sistema possui um tamanho de $[Ny - N_1 + 1]xNu$.

Distúrbios Mensuráveis:

Quando da presença de distúrbios mensuráveis no processo, o conceito a ser aplicado é análogo ao de previsão de uma entrada normal, tendo em vista que tal distúrbio pode ser considerado como uma. Tem-se então que:

$$\hat{Y}_d = Dd + \hat{F}_d \,, \tag{2.28}$$

onde D é a matriz dinâmica similar à G, com os coeficientes da resposta do distúrbio ao degrau, \hat{Y}_d é a contribuição do distúrbio mensurável ao sistema, d é o vetor de incremento do distúrbio e \hat{F}_d é a parte da resposta que não depende do distúrbio.

Pode-se considerar como resposta livre de um processo com distúrbio a soma de quatro efeitos: a resposta à entrada N, a resposta ao distúrbio mensurável N, a resposta ao distúrbio não-mensurável e o estado atual do processo, resultando na já conhecida expressão da previsão,

$$\hat{Y} = G\Delta u + \hat{F} , \qquad (2.29)$$

onde a principal diferença é a resposta livre, agora dada por:

$$\hat{F} = f_u + Dd + f_d + f_n.$$
 (2.30)

Função Objetivo:

A função objetivo proposta para minimização no controlador DMC é uma função quadrática, que visa levar a saída estimada $\hat{y}(t+k|t)$ o mais próximo possível a uma trajetória referência $y_r(t+k)$, com a possibilidade de inclusão de coeficientes de penalização a restrições que possam estar presentes no problema. O incremento do sinal de controle também aparece nessa função objetivo, com o intuito de se obter a melhor trajetória estimada com a menor variação possível no sinal de controle.

A função objetivo é dada então por:

$$J = \sum_{j=N_1}^{N_y} [\hat{y}(t+k \mid t) - y_r(t+k)]^2 + \sum_{j=1}^{N_u} \lambda [\Delta u(t+k-1)]^2 , \qquad (2.31)$$

onde λ é a ponderação da penalização a ser aplicada sobre o sinal de controle, Ny é o horizonte de previsão final, N_1 é o horizonte de previsão inicial e Nu é o horizonte de controle.

Em forma vetorial, se não houver restrições, a equação (2.31) pode ser escrita como:

$$J = ee^{T} + \lambda \Delta u \Delta u^{T}, \qquad (2.32)$$

onde *e* é o vetor de erros futuros ao longo do horizonte de previsão e Δu é o vetor de incremento do sinal de controle.

Lei de Controle:

O vetor de incremento do sinal de controle pode ser facilmente obtido a partir da função objetiva apresentada, bastando apenas derivar a equação (2.32), o que resulta em,

$$u = [G^{T}G + \lambda I]^{-1}G^{T}[Y_{r} - \hat{F}].$$
(2.33)

Por estar englobado no conceito de horizonte deslizante, deve-se aplicar ao processo apenas o primeiro sinal de controle obtido no vetor de incremento u. Para isso, denota-se de L a primeira linha da matriz $u = [G^T G + \lambda I]^{-1} G^T [Yr - \hat{F}]$, reduzindo a equação (2.33) para:

$$\Delta u(t) = L[Yr - \hat{F}], \qquad (2.34)$$

onde

$$L = [l_{N_1} \quad l_{N_1+1} \quad \dots \quad l_{N_y}].$$

devendo apenas o sinal de controle $u(t) = u(t-1) + \Delta u(t)$ ser aplicado ao processo. Todo o processo deve ser repetido no próximo passo.

Parâmetros para Sintonia:

Conforme demonstrado, os parâmetros para a sintonia de um controlador DMC são quatro: o horizonte de previsão inicial (N_1) , o horizonte de previsão final (Ny), o horizonte de controle (Nu) e a ponderação de controle (λ) . Uma desvantagem com relação a outros controladores é que o DMC não é capaz de controlar processos instáveis em malha aberta.

- Horizonte de previsão inicial (N₁) Freqüentemente é adotado como valor unitário, com exceção geralmente em processos com atraso, onde se há um ganho, se N₁ ≤ d.
- Horizonte de previsão final (Ny) Geralmente selecionado de forma a ultrapassar o tempo de subida do processo. O aumento desse parâmetro pode levar a instabilidade em malha fechada de sistemas que são instáveis em malha aberta. A dinâmica dos processos em malha fechada se torna mais rápida com sua diminuição (Santos, 1998).
- Horizonte de controle (Nu) O aumento desse parâmetro aumenta o esforço computacional, tendo em vista que a matriz de controle deve ser maior. Por outro lado, há uma maior agressividade no sinal. O valor desse parâmetro deve ser o menor possível, para um melhor desempenho do controle do processo.
- Ponderação de controle (λ) A ponderação de controle na função objetivo tem como principal idéia penalização de uma variação do sinal de controle quando for diferente de zero, melhorando a reposta do sistema.

Lundström *et al.* (1995) apresentaram um artigo com as principais deficiências do método DMC. Segundo os autores elas são:

- Uma resposta aceitável pode necessitar de um acentuado número de coeficientes na resposta ao degrau;
- Desempenho não apropriado pode ser verificado com a aplicação de distúrbios nas entradas da planta;

• Desempenho inaceitável no que se diz respeito à utilização em plantas multivariáveis com forte acoplamento entre as entradas.

Passos para Implementação:

Para se realizar a implementação do controlador DMC, deve-se seguir as etapas apresentadas na seqüência:

- 1. Especificar o modelo: Aplicar um degrau unitário e coletar os coeficientes da resposta.
- 2. Definir os parâmetros de projeto: o horizonte de previsão inicial (N_1) , o horizonte de previsão final (Ny), o horizonte de controle (Nu) e a ponderação de controle (λ) .
- 3. Calcular recursivamente $N_y N_1$ passos os vetores da resposta livre \hat{f} e a previsão \hat{y} .
- 4. Calcula a matriz dinâmica G e o vetor de incremento de controle.
- 5. Calcular e aplicar o sinal de controle, com a utilização da primeira linha do vetor de incremento.
- 6. Retornar à etapa 3.

2.3.3 GPC – Generalized Predictive Control

O GPC é uma técnica de controle proposta por Clarke *et al.* (1987), desenvolvida para suprir diversas necessidades pendentes a outros esquemas de controle existentes quando aplicados a processos complexos, tais quais controlar pressão sanguínea, anestesia, entre outros (Santos, 1998). Essa técnica de controle se tornou um dos métodos MPC mais populares, tanto na área acadêmica quanto na industrial (Camacho e Bordons, 2004). Ela foi aplicada com sucesso em muitos processos industriais (Clarke, 1988).

Como o conceito do GPC engloba o conceito de horizonte deslizante, ele é considerado um MAS (*Multi-Step-Ahead Controller*), sendo sua idéia básica o cálculo de sinais futuros visando a minimização de uma função objetivo multi-estágio em um determinado horizonte de previsão. Tal função a ser utilizada é quadrática, de tal forma a diminuir a diferença entre a saída estimada do sistema com a trajetória desejada, levando em conta o esforço do sinal de controle também em uma forma quadrática.

Conforme poderá ser observado na seqüência, o GPC possui uma solução analítica, quando não existem restrições, é capaz de lidar com processos de fase não-mínima e instáveis e possui parâmetros para definição de ponderações no sinal de controle através da função objetivo.

Modelo do Processo:

Para a realização da previsão do processo, de maneira diferente dos controladores SSA, o GPC utiliza um modelo paramétrico do tipo CARIMA (*Controlled Auto-Regressive Integrated Moving Average*), representado pela seguinte equação a diferenças:

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

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

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

$$C(q^{-1}) = 1 + c_1q^{-1} + \dots + c_{nc}q^{-nc}$$

$$\Delta = 1 - q^{-1},$$
(2.35)

onde u(t) é a entrada do sistema (sinal de controle), y(t) é a saída do sistema, $\xi(t)$ é um ruído branco e *d* é um atraso de transporte conhecido, para efeitos de projeto.

Previsão e Função Objetivo:

O objetivo do controlador GPC é a minimização de uma função objetivo multi-estágio, que engloba a diferença quadrática entre a saída estimada $\hat{y}(t+k | t)$ e a referência $y_r(t+k)$, k passos à frente, acrescentada de uma ponderação no incremento do sinal de controle $\Delta u(t+k-1)$. Tem-se então:

$$J = \sum_{j=N_1}^{N_y} [\hat{y}(t+k \mid t) - y_r(t+k)]^2 + \sum_{j=1}^{N_u} \lambda [\Delta u(t+k-1)]^2 , \qquad (2.36)$$

onde λ é a ponderação de penalização do incremento no sinal de controle, Ny é o horizonte de previsão final, N_1 é o horizonte de previsão inicial, Nu é o horizonte de controle e ε é a

esperança matemática. Com base nesses parâmetros é possível a obtenção de diversos tipos de controladores preditivos (Clarke *et al.*, 1987).

Multiplicando a equação (2.36) por $q^k E_k(q^{-1})$, tem-se que:

$$E_{k}(q^{-1})A(q^{-1})\Delta y(t+k) = E_{k}(q^{-1})B(q^{-1})\Delta u(t+k-d) + E_{k}(q^{-1})C(q^{-1})\xi(t+k).$$
(2.37)

Seja a seguinte identidade polinomial:

$$C(q^{-1}) = E_k(q^{-1})\Delta A(q^{-1}) + q^{-k}F_k(q^{-1}), \qquad (2.38)$$

onde os polinômios $E_k(q^{-1})$ é encontrado dividindo 1 por $\Delta A(q^{-1})$ até que o resto da divisão se torne $q^{-k}F_k(q^{-1})$ (Camacho e Bordons, 2004):

$$E_k(q^{-1}) = 1 + e_1 q^{-1} + \dots + e_{ne} q^{-ne}$$
$$F_k(q^{-1}) = f_0 + f_1 q^{-1} + \dots + f_{nf} q^{-nf}$$
$$n_e = k - 1 \qquad n_f = \max(n_a, n_c - k).$$

Isolando o termo $E_k(q^{-1})\Delta A(q^{-1})$ da equação (2.38) e substituindo na equação (2.37), tem-se:

$$[C(q^{-1}) - q^{-\kappa}F_k(q^{-1})]y(t+k) = E_k(q^{-1})B(q^{-1})\Delta u(t+k-d) + E_k(q^{-1})C(q^{-1})\xi(t+k)$$

$$C(q^{-1})y(t+k) = F_k(q^{-1})y(t) + E_k(q^{-1})B(q^{-1})\Delta u(t+k-d) + E_k(q^{-1})C(q^{-1})\xi(t+k)$$
(2.39)

A equação (2.39) pode ser reescrita como:

$$y(t+k) = \frac{F_k(q^{-1})}{C(q^{-1})} y(t) + \frac{G_k(q^{-1})}{C(q^{-1})} \Delta u(t+k-d) + E_k(q^{-1})\xi(t+k),$$
(2.40)

onde

$$G(q^{-1}) = E_k(q^{-1})B(q^{-1})$$

Como $E(q^{-1})$ possui ordem $n_e = k - 1$, todos os sinais do distúrbio $\xi(t+k)$ são desconsiderados, pois estão no futuro. Essa modificação resulta na seguinte equação para a previsão:

$$\hat{y}(t+k) = \frac{F_k(q^{-1})}{C(q^{-1})} y(t) + \frac{G_k(q^{-1})}{C(q^{-1})} \Delta u(t+k-d) .$$
(2.41)

Seja $\hat{f}(t+k)$ a componente de $\hat{y}(t+k)$ que possui todas as informações disponíveis no presente, ou seja, a resposta livre. Para que seja possível determinar $\hat{f}(t+k)$ e diferenciar quais as informações de $\hat{y}(t+k)$ estão no presente e quais são futuras, deve-se aplicar a seguinte identidade polinomial:

$$G_k(q^{-1}) = \widetilde{G}_k(q^{-1})C(q^{-1}) + q^{-k}\overline{G}_k(q^{-1}).$$
(2.42)

Substituindo a equação (2.42) na equação (2.41) é obtida a seguinte expressão:

$$\hat{y}(t+k) = \tilde{G}_k(q^{-1})\Delta u(t+k-d) + \hat{f}(t+k), \qquad (2.43)$$

onde

$$\hat{f}(t+k) = \frac{F_k(q^{-1})}{C(q^{-1})} y(t) + \frac{\overline{G}_k(q^{-1})}{C(q^{-1})} \Delta u(t-d).$$

Com a resposta livre definida, é possível escrever a equação da previsão, (2.43), em forma vetorial, conforme segue:

$$\hat{Y} = G\Delta u + \hat{f} , \qquad (2.44)$$

onde

$$G = \begin{bmatrix} g(N_1 - d) & 0 & \cdots & 0 \\ g(N_1 - d + 1) & g(N_1 - d) & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ g(Ny - d) & g(Ny - d - 1) & \cdots & g(Ny - d - Nu + 1) \end{bmatrix}^T$$
$$\hat{Y} = \begin{bmatrix} \hat{y}(t + N_1) & \hat{y}(t + N_1 + 1) & \cdots & \hat{y}(t + Ny) \end{bmatrix}^T$$
$$\Delta u = \begin{bmatrix} \Delta u(t) & \Delta u(t + 1) & \cdots & \Delta u(t + Nu - 1) \end{bmatrix}^T$$
$$\hat{f} = \begin{bmatrix} \hat{f}(t + N_1) & \hat{f}(t + N_1 + 1) & \cdots & \hat{f}(t + Ny) \end{bmatrix}^T.$$

A função objetivo denotada pela equação (2.36) pode ser então representada por:

$$J = [G\Delta u + \hat{f} - Y_r][G\Delta u + \hat{f} - Y_r]^T + \lambda \Delta u \Delta u^T, \qquad (2.45)$$

onde

$$Y_r = [y_r(t+N_1) \quad y_r(t+N_1+1) \quad \dots \quad y_r(t+Ny)]$$

Lei de Controle:

O vetor de incremento do sinal de controle pode ser facilmente obtido a partir da função objetivo apresentada, bastando derivar a equação (2.45) e igualá-la a zero, o que resulta em:

$$\Delta u = [G^T G + \lambda I]^{-1} G^T [Y_r - \hat{f}]. \qquad (2.46)$$

Por estar englobado no conceito de horizonte deslizante, deve-se aplicar ao processo apenas o primeiro sinal de controle obtido no vetor de incremento u. Para isso, denota-se de L a primeira linha da matriz $\Delta u = [G^T G + \lambda I]^{-1} G^T$, reduzindo a equação (2.46) para:

$$\Delta u(t) = L[\mathbf{Y}_r - \hat{f}], \qquad (2.47)$$

onde

$$L = [l_{N_1} \quad l_{N_1+1} \quad \dots \quad l_{N_y}].$$

devendo apenas o sinal de controle $u(t) = u(t-1) + \Delta u(t)$ ser aplicado ao processo. Todo o processo apresentado deve então ser repetido.

Para encontrar a resposta em malha fechada de um sistema com GPC, deve-se utilizar a resposta livre e a trajetória de referência, no formato demonstrado nas equações (2.44) e (2.45) respectivamente. Deve-se aplicá-las à equação (2.47), resultando no seguinte:

$$\Delta u(t) = \sum_{k=N_1}^{N_y} l_k [y_r(t+k) - \frac{F_k(q^{-1})}{C(q^{-1})} y(t) - \frac{\overline{G}_k(q^{-1})}{C(q^{-1})} \Delta u(t-d)]$$
$$\left[C(q^{-1}) + q^{-d} \sum_{k=N_1}^{N_y} l_k \overline{G}_k(q^{-1}) \right] \Delta u(t) = \left[C(q^{-1}) \sum_{k=N_1}^{N_y} l_k y_r(t+k) \right] - \left[\sum_{k=N_1}^{N_y} l_k F_k(q^{-1}) \right] y(t)$$

$$\left[C(q^{-1}) + q^{-d}\sum_{k=N_1}^{N_y} l_k \overline{G}_k(q^{-1})\right] \Delta u(t) = \left[C(q^{-1})\sum_{k=N_1}^{N_y} l_{Ny+N_1-k} q^{-(k-N_1)}\right] y_r(t+Ny) - \left[\sum_{k=N_1}^{N_y} l_k F_k(q^{-1})\right] y(t).$$
(2.48)

A lei de controle do processo em malha fechada então pode ser encontrada com a utilização do conceito de controlador incremental, (ou RST):

$$R(q^{-1})\Delta u(t) = T(q^{-1})y_r(t) - S(q^{-1})y(t), \qquad (2.49)$$

onde

$$\begin{aligned} R(q^{-1}) &= C(q^{-1}) + q^{-d} \sum_{k=N_1}^{N_y} l_k \overline{G}_k(q^{-1}) \\ T(q^{-1}) &= C(q^{-1}) \sum_{k=N_1}^{N_y} l_{Ny+N_1-k} q^{-(k-N_1)} \\ S(q^{-1}) &= \sum_{k=N_1}^{N_y} l_k F_k(q^{-1}) , \end{aligned}$$

tal que $n_R = Ny - N_1$, $n_T = \max(n_B, n_C)$ e $n_S = \max(n_a, n_C - Ny)$.

A figura 2.7 representa essa estrutura de controle.



Figura 2.7 – Estrutura do controlador GPC.

Ao se substituir a lei de controle (2.49) na equação do processo (2.35) é obtida a seguinte expressão:

$$A(q^{-1})\Delta y(t) = q^{-d}B(q^{-1})\left[\frac{R(q^{-1})}{T(q^{-1})}y_r(t+Ny) - \frac{S(q^{-1})}{T(q^{-1})}y(t)\right] + C(q^{-1})\xi(t)$$

$$\left[A(q^{-1})\Delta + \frac{q^{-d}B(q^{-1})S(q^{-1})}{T(q^{-1})}\right]y(t) = q^{-d}B(q^{-1})\left[\frac{R(q^{-1})}{T(q^{-1})}y_r(t+Ny)\right] + C(q^{-1})\xi(t)$$

$$y(t) = \frac{\left[q^{-d}B(q^{-1})R(q^{-1})\right]y_r(t+Ny)}{\left[A(q^{-1})\Delta T(q^{-1}) + q^{-d}B(q^{-1})S(q^{-1})\right]} + \frac{\left[C(q^{-1})T(q^{-1})\xi(t)\right]}{\left[A(q^{-1})\Delta T(q^{-1}) + q^{-d}B(q^{-1})S(q^{-1})\right]}.$$
(2.50)

Utilizando como base a equação (2.50) pode-se obter o polinômio característico de malha fechada do controlador GPC, onde:

$$A(q^{-1})\Delta T(q^{-1}) + q^{-d}B(q^{-1})S(q^{-1}) = P_{MF}(q^{-1}).$$
(2.51)

Parâmetros para Sintonia:

Os parâmetros de sintonia de um controlador GPC são quatro, e por ventura são os mesmos do controlador DMC, o que prova que o DMC, assim como vários outros controladores são um caso específico do controlador generalizado. O quatro parâmetros são: o horizonte de previsão inicial (N_1), o horizonte de previsão final (Ny), o horizonte de controle (Nu) e a ponderação de controle (λ).

Diversos autores já propuseram estudos para a melhoria da sintonia desses parâmetros, tais quais Clarke *et al.* (1987), Clarke e Mohtadi (1987), Bitmead *et al.* (1990), McIntosh *et al.* (1991), Santos (1998), Rodrigues *et al.* (2002), Camacho e Bordons (2003), Rossiter (2004), entre outros.

A problemática para a utilização do método GPC é a correta sintonia desses parâmetros, que varia de acordo com o conhecimento prévio do projetista a respeito do processo a ser controlado.

Passos para Implementação:

Para se realizar a implementação do controlador GPC, deve-se seguir às etapas apresentadas na sequência:

- 1. Especificar o modelo: vetor com coeficientes da saída $A(q^{-1})$, vetor com coeficientes de controle $B(q^{-1})$ e vetor de distúrbios $C(q^{-1})$.
- 2. Definir os parâmetros de projeto: o horizonte de previsão inicial (N_1) , o horizonte de previsão final (Ny), o horizonte de controle (Nu) e a ponderação de controle (λ) .
- 3. Calcular recursivamente $N_y N_1$ passos os vetores $E(q^{-1})$ e $F(q^{-1})$ para obter a resolução da primeira equação diofantina.
- 4. Calcular recursivamente $N_y N_1$ passos os vetores $\overline{G}(q^{-1})$ e $\widetilde{G}(q^{-1})$ para obter a resolução da segunda equação diofantina.
- 5. Calcular a matriz G e a matriz objetivo resultante da equação (2.46), retirando todas as linhas, exceto sua primeira.
- 6. Calcular e aplicar o sinal de controle, através da estrutura RST.
- 7. Voltar para a etapa 3.

2.4 CONTROLE ADAPTATIVO

Para a compreensão do conceito de controle adaptativo, são apresentadas nos próximos parágrafos desta seção algumas definições.

Os sistemas biológicos são conhecidos por possuírem uma maneira fácil e eficiente de lidar com mudanças no seu meio ambiente. Muitos esforços na teoria de controle de sistemas visam incorporar características de sistemas biológicos para o tratamento de sistemas com incertezas, introduzindo diversos termos, tais como: adaptação, aprendizado, reconhecimento de padrões e auto-organização. O controle adaptativo foi provavelmente o primeiro destes termos a ser introduzido. O controle inteligente foi a teoria que começou a aparecer mais tarde (Narendra, 1994).

Segundo Åström e Wittenmark (1995a), adaptar significa mudar o seu comportamento a fim de se adequar a novas circunstâncias. Um controlador adaptativo então pode ser definido como um controlador que pode modificar seu comportamento em resposta a mudanças na dinâmica do processo e ao efeito de perturbações. Isto é realizado a partir da adição de um mecanismo de ajuste ao esquema tradicional de realimentação, para monitorar o sistema ou o sinal (Wellstead e Zarrop, 1991).

Um sistema adaptativo e seu conceito de funcionamento podem ser observados na figura 2.8.



Figura 2.8 – Diagrama de blocos de um controlador adaptativo.

Existem vários esquemas de controle adaptativo (Åström e Wittenmark, 1995; Isermann *et. al.*, 1992; Åström e Hägglund, 1996; Clarke, 1996; VanDoren, 2003), dependendo das variáveis que possam ser medidas e determinados dados disponíveis, tais quais: o modelo teórico do sistema, sinal de referência, parâmetros do processo, entre outros. Entre esses esquemas estão o Escalonamento de ganhos ou *Gain Scheduling* (GS), o *Model-Reference Adaptive System* (MRAS) e o *Self-Tuning Regulator* (STR), que serão brevemente apresentados na sequência, conforme descritos em (Åström e Wittenmark, 1995).

Escalonamento de ganhos

O escalonamento de ganhos é uma estrutura utilizada quando um determinado processo possui variáveis mensuráveis que possuem uma relação explícita com mudanças na sua dinâmica. O nome dessa abordagem é escalonamento de ganhos, pois foi originalmente desenvolvida para mensurar o ganho e então modificar – escalonar - o controlador para compensar mudanças no ganho do processo. Essa estrutura pode ser verificada na figura 2.9.



Figura 2.9 – Estrutura de escalonamento de ganhos.

O conceito de escalonamento de ganhos foi originado da conexão com o desenvolvimento dos sistemas de controle de vôo. Nesta aplicação, o número de Mach e a pressão dinâmica são medidas por sensores e usadas como variáveis de escalonamento. O escalonamento de ganhos é uma técnica útil na redução dos efeitos da variação de parâmetros em aplicações industriais. Segundo Åström e Wittenmark (1995), existem controvérsias se o escalonamento de ganhos deve ser considerado um sistema adaptativo ou não.

Model-Reference Adaptive System

O *Model-Reference Adaptive System* foi originalmente proposto para resolver problemas em que as especificações de desempenho são dadas através de um modelo de referência. Esse modelo representa a resposta ideal que o sistema deve apresentar quando do sinal de comando. Um diagrama de blocos é apresentado na figura 2.10.



Figura 2.10 – Estrutura MRAS.

O problema chave de um MRAS, segundo Åström e Wittenmark (1995), é determinar o mecanismo de ajuste de maneira que um sistema estável que leve o erro para zero seja obtido. Este problema não é trivial. O seguinte mecanismo de ajuste, denominado regra MIT foi usado no MRAS original:

$$\frac{\partial \theta}{\partial t} = -\gamma e \frac{\partial e}{\partial \theta}.$$
(2.52)

Na equação (2.52), $e = y - y_m$ denota o erro do modelo e θ é um parâmetro do controlador. As componentes do vetor $\frac{\partial e}{\partial \theta}$ são as derivadas da sensibilidade do erro com respeito ao parâmetro θ . O parâmetro γ determina a taxa de adaptação. A regra MIT pode ser considerada como um esquema de gradiente para minimizar o erro quadrático, $J(e) = e^2$. Um dos problemas da estrutura MRAS é que na prática é necessário fazer-se aproximações para obter a derivada de sensibilidade.

Self-Tuning Regulator

Os esquemas adaptativos discutidos nas seções anteriores são denominados métodos diretos, porque as regras de ajuste dizem como os parâmetros do controlador devem ser diretamente atualizados. Um esquema diferente é obtido se as estimativas dos parâmetros do processo são atualizadas e os parâmetros do controlador são obtidos da solução de um problema de projeto usando os parâmetros estimados. Um diagrama deste sistema é mostrado na figura 2.11.

O controlador adaptativo STR pode ser considerado como sendo composto de duas malhas. A malha interna consiste do processo e uma realimentação da saída do processo. Os parâmetros do controlador são ajustados pela malha exterior, que é composta por um estimador de parâmetros recursivo e um cálculo de projeto. Muitas vezes, não é possível estimar os parâmetros do processo sem a introdução de sinais de controle de prova ou perturbações. Esta abordagem de controle pode ser vista como uma automatização da modelagem e projeto, em que o modelo do processo e o projeto de controle são atualizados a cada período de amostragem. Um controlador que utilize esta abordagem de projeto é denotado por *Self-Tuning Regulator* para enfatizar que o controlador sintoniza

são:

automaticamente seus parâmetros para obter as propriedades desejadas do sistema em malha fechada.

O esquema de controle STR é flexível com relação a escolha do projeto e dos métodos de estimação, motivo pelo qual várias combinações diferentes têm sido exploradas. Os parâmetros do controlador podem ser tanto calculados indiretamente, ou seja, identificação do processo recursiva e sintonia dos parâmetros através desses novos valores, como diretamente, ou seja, a cada período de amostragem calculando recursivamente os valores do controlador. No STR, os parâmetros do controlador ou os parâmetros do processo são estimados em tempo real.



Figura 2.11 - Estrutura STR.

As principais definições que diferenciam os diversos modelos de controle adaptativo

- Descrição do processo e como as variáveis serão estimadas;
- Definir qual a sua estrutura de controle;
- Como adaptar os parâmetros do controlador.

Nessa qualificação será adotado apenas um controlador adaptativo, o PI adaptativo de Camacho *et al.* (1992), o qual será apresentado na próxima seção.

2.4.1 Controlador PI Adaptativo de Camacho e outros.

O controlador PI de Camacho *et al.* (1992), foi desenvolvido para realizar o controle de um gerador movido à energia solar com um campo distribuído de coletores. Placas coletam a luz solar e aquecem um óleo que passa por uma tubulação interna. Na maioria das aplicações práticas é aplicado o controlador PI ao invés do PID devido à uma parcela de ruído que é proveniente do termo derivativo nesse tipo de controlador.

Esse esquema de controlador está englobado no modelo STR indireto, por possuir um estimador de parâmetros das variáveis do processo e só após isso calcular os novos valores do controlador.

Método de identificação:

Para realizar a identificação do processo escolhido, o controlador PI de Camacho *et al.* (1992), utiliza uma estimação recursiva, com fator de esquecimento, realizada através do método *Recursive Least Squares* ou Mínimos quadrados recursivos (MQR).

O modelo utilizado para a realização desta estimação é o modelo ARX, (Auto-Regressive with eXogenous inputs), dado pela equação a diferenças (2.53).

$$A(q^{-1}) y(t) = q^{-d} B(q^{-1}) u(t)$$

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

$$B(q^{-1}) = b_0 + b_1 q^{-1} + \dots + b_{nb} q^{-nb},$$
(2.53)

onde u(t) é a entrada do sistema, y(t) é a saída do sistema e saída e d é um atraso de transporte conhecido, para efeitos de projeto.

Considerando que o sistema deverá possuir um comportamento típico de primeira ordem:

$$y(t) = ay(t-1) + b_0 u(t-2) + b_1 u(t-3).$$
(2.54)

Estrutura de Controle:

Pensando no conceito de controladores auto-reguláveis, Camacho *et al.* (1992) observaram em seus estudos que a resposta ao degrau da planta poderia ser aproximada à resposta obtida por um processo contínuo de primeira ordem. Com isso, a base para o

controlador PI adaptativo utiliza a equação típica de um sistema que possui essas características, e é dada por:

$$G(s) = \frac{e^{-\tau_D s} K}{\tau s + 1}, \qquad (2.55)$$

onde τ_D é o atraso do processo, τ é a constante de tempo do processo e *K* é o ganho do sistema.

Foi então observado que, no processo estudado, a constante de tempo τ , o atraso τ_D e o ganho *K* variam de acordo com a taxa de vazão do óleo aquecido, e, quando essa está no ponto mínimo, o atraso é duas vezes maior do que quando ela está no ponto máximo. Para que essa variação seja acomodada, foi mostrado em Rubio *et al.* (1989), que se pode utilizar esse modelo na forma discreta dada pela equação (2.56):

$$G(q^{-1}) = \frac{q^{-2}(b_0 + b_1 q^{-1})}{(1 - aq^{-1})}.$$
(2.56)

O período de amostragem desse sistema deve ser escolhido como o valor mínimo do atraso, segundo Camacho *et al.* (1992). Tal valor mínimo pode ser representado quando esse sistema possui $b_1 = 0$. Quando $b_0 = 0$, é obtido o maior valor possível de atraso entre dois períodos de amostragem. Quando esse valor de atraso τ_D não é múltiplo do período de amostragem, ou seja, $T < \tau_D < 2T$, o termo $(b_0 + b_1 q^{-1})$ age como sendo uma aproximação discreta de Padé de primeira ordem, para o atraso.

Com base nesses dados, é possível dar continuidade ao desenvolvimento do controlador PI adaptativo, utilizando o método de projeto de alocação de pólos. Para tanto, deve ser utilizada a seguinte equação para esse controlador:

$$K(q^{-1}) = \frac{g_0(1 - g_2 q^{-1})}{(1 - q^{-1})},$$
(2.57)

onde g_0 e g_2 são os ganhos desse controlador PI.

Escolhendo um zero do controlador para cancelar um pólo do processo, fazendo $g_2 = a$, o polinômio característico do sistema em malha fechada, $P(q^{-1})$, é dado por

$$P(q^{-1}) = q^{3} - q^{2} + g_{0}b_{0}q + g_{0}b_{1}.$$
(2.58)

Utilizando o conceito de alocação de pólos, ou seja, se no sistema em malha fechada deseja-se que exista um pólo dominante em q = A, deve-se substituir esse pólo na equação (2.58), para que possa ser encontrado o ganho g_0 , resultando na equação

$$g_0 = \frac{A^2(1-A)}{(b_0A+b_1)}.$$
(2.59)

Então, identificando os parâmetros do processo a, $b_0 e b_1$ através do MQR, os parâmetros do controlador $g_0 e g_2$ podem ser obtidos, de forma que há a garantia da obtenção de um pólo de malha fechada dominante em q = A.

Para realizar a prova a respeito dos pólos, a equação do polinômio característico (2.58) deve ser utilizada, na forma:

$$P(q^{-1}) = [q^2 - (1 - A)q + g_0 b_0 - A(1 - A)](z - A).$$
(2.60)

Analisando essa equação no lugar das raízes, são obtidos, além de q = A, mais outros dois pólos reais, um negativo e um positivo. Resolvendo então $P(q^{-1})$, tem-se a localização correta de ambos, garantindo então que o pólo selecionado realmente é o dominante em malha fechada.

Parâmetros para Sintonia:

O controlador PI desenvolvido por Camacho *et al.* (1992) é um controlador com poucos parâmetros de sintonia devido à sua estrutura de controle. Conforme pode ser verificado anteriormente, em decorrência do modelo de projeto por alocação de pólos, um parâmetro deve ser definido para que possa ser realizado o controle, que é o pólo dominante desejado, ou A.

Três parâmetros são necessários além do pólo especificado, que não são decorrentes de sua estrutura de controle, mas sim do método de identificação do processo utilizado, o MQR. Esses parâmetros são concentrados em um vetor, denominado $\theta(0)$, e definem qual é a estimativa inicial dos parâmetros a, b_0 e b_1 .

Outro parâmetro decorrente do método de identificação é o fator de esquecimento.

Etapas para Implementação:

Para se realizar a implementação do controlador PI de Camacho *et al* (1992). com sucesso, deve-se seguir as etapas apresentadas na seqüência:

- 1. Definir os parâmetros de projeto: A (pólo referência) e $\theta(0)$ (estimação inicial do MQR).
- 2. Estimar via MQR os parâmetros a, $b_0 e b_1$, segundo a equação (2.54).
- 3. Calcular o ganho do controlador, g_0 , utilizando a equação (2.59).
- 4. Calcular e aplicar o sinal de controle, através da equação (2.57).
- 5. Voltar para a etapa 2.

3 ALGORITMOS GENÉTICOS

3.1 INTRODUÇÃO

Inicialmente, os algoritmos genéticos foram desenvolvidos e apresentados no livro *Adaptation in Natural and Artificial Systems*, de Holland (1975), e possuem como base o conceito biológico da seleção natural, simulando a evolução para obter um melhor valor para uma determinada função objetivo (função *fitness*). O fluxo executado pelos algoritmos genéticos pode ser verificado na figura 3.1.



Figura 3.1 – Fluxograma dos algoritmos genéticos.

A primeira etapa de um AG é a validação das soluções inicialmente apresentadas. A partir dessas, existe a seleção dos indivíduos de acordo com os seus valores de

adequabilidade. O próximo passo é a realização de uma recombinação entre os indivíduos pais existentes (*crossover*) e, em seguida uma mutação, gerando uma nova população, com indivíduos filhos. A partir desses últimos são geradas novas soluções, e o algoritmo repete até que um determinado número de gerações seja satisfeito, ou uma determinada aptidão seja atingida.

As principais diferenças entre os algoritmos genéticos e os métodos de otimização e busca tradicionais, segundo (Carvalho, 2010), são que os AGs trabalham com uma codificação do conjunto de parâmetros e não com os próprios parâmetros do problema; trabalham com uma população e não com um único ponto; utilizam informações de custo ou recompensa e não derivadas ou outro conhecimento auxiliar; e utilizam regras de transição probabilísticas e não determinísticas.

Existem diversas maneiras de realizar a implementação desses algoritmos genéticos, dependendo geralmente do tipo de problema a ser otimizado (Araújo, 2008), tais quais a codificação dos indivíduos, a estratégia de seleção e os tipos de operadores de recombinação.

3.1.1 Codificação ou Representação

Para encontrar as soluções do problema a ser otimizado, Holland (1975) criou uma seqüência de bits, denominada de cromossomos ou indivíduos. Essa seqüência é composta de bits, denominados genes. Quando um algoritmo genético é aplicado a um problema, os cromossomos serão conjuntos compostos ordenados das características genéticas, ou, dos parâmetros a serem otimizados (Araújo, 2008).

Existem diversos tipos de codificação, tais quais a binária, mais comumente utilizada, a por números inteiros, a por números reais, entre outras. Nesta dissertação a binária será adotada.

A codificação binária, ou canônica, é dada pela atribuição de conjuntos de valores "0" ou "1" aos cromossomos, representando por uma quantidade específica de bits cada uma das variáveis, que varia de acordo com a faixa de valores dessas no problema.

A quantidade de cromossomos em uma população é um dos parâmetros de projeto de um algoritmo genético.

3.1.2 Estratégias de seleção

Para realizar a seleção dos indivíduos, foram desenvolvidos alguns métodos, baseados na seleção natural, que serão descritos na seqüência. Os indivíduos que possuem uma maior aptidão têm uma probabilidade maior de serem selecionados, contribuindo para a criação dos indivíduos-filho na próxima geração.

Serão explanados três estratégias de seleção, a roleta, o torneio e o elitismo.

3.1.2.1 Roleta

O método da Roleta para a seleção dos indivíduos consiste na representação proporcional de cada um dos cromossomos em um todo, baseado no índice de aptidão que cada um desses obteve em sua avaliação do problema, ou seja, o indivíduo que possuir a maior aptidão terá a maior chance de ser selecionado.

A sequência de aplicação do método se dá da seguinte forma:

- Inicialmente o *fitness*, ou aptidão, de cada um dos indivíduos da população em relação ao problema é encontrado.
- 2) Todos os valores de aptidão encontrados são somados, gerando S.
- Para cada um dos indivíduos é encontrada então uma aptidão relativa, que é o valor da sua aptidão dividida pela soma de aptidões.
- 4) Distribuir os cromossomos em forma de uma roleta e gerar um vetor de números aleatórios com distribuição uniforme entre 0 e *S*.
- 5) i = 0 e sum = 0.
- 6) Soma a aptidão do cromossomo *i* à variável *sum*.
- 7) Se o valor parcial da soma das aptidões até o momento (*sum*) é maior que algum dos números gerados aleatoriamente, encontra-se a posição desse número no vetor.
- Insere no vetor da população selecionada, na posição encontrada no item 6, o cromossomo *i*.
- Repetir o processo entre 6-8, com i = i +1, até o número total de cromossomos ser atingido.

Indivíduo	Aptidão	Soma das Aptidões	Aptidão Relativa
S i	f(S _i)	S	S _R
S 1	5,28		0,124
S 2	7,32	12 66	0,172
S ₃	15,84		0,371
S 4	2,25	42,00	0,053
S 5	5,47		0,128
S ₆	6,5		0,152

Um exemplo de aplicação do método da roleta é representado na figura 3.2.



Figura 3.2 – Exemplo de aplicação do método da roleta.

3.1.2.2 Seleção por Torneio

O método de seleção por torneio consiste em selecionar alguns indivíduos de forma aleatória, onde todos possuem a mesma chance, para participarem de um torneio, no qual os vencedores serão os selecionados para a próxima geração. A definição necessária para executar a seleção por torneio é o tamanho do mesmo, que pode variar entre 2 ao tamanho total da população. As etapas desse método são:

- Inicialmente o *fitness*, ou aptidão, de cada um dos indivíduos da população em relação ao problema é encontrado.
- Os indivíduos são aleatoriamente selecionados para o torneio. Todos os indivíduos possuem a mesma chance nessa fase, e a aptidão ainda não é levada em conta.

3.3.

- Após definidos os torneios entre os cromossomos, a maior aptidão é então levada em conta para que seja possível encontrar o vencedor.
- 4) O vencedor do torneio é então selecionado.
- 5) Repetir o processo entre 3 e 4 até o número desejado de selecionados ser atingido.

Um exemplo de aplicação do método de seleção por torneio é representado na figura



Figura 3.3 – Exemplo de aplicação do método do torneio.

3.1.2.3 Elitismo

O elitismo é uma técnica de seleção que garante os indivíduos de maior aptidão no processo. Para tanto, tais indivíduos são simplesmente copiados de uma geração para outra sem a influência de outros métodos. Dessa maneira as melhores soluções encontradas não são descartadas.

3.1.3 Operadores de reprodução

O princípio básico dos operadores de reprodução é a transformação da população através de sucessivas gerações, até que seja encontrado um resultado satisfatório. Esses operadores são necessários para garantir a diversificação da população, mantendo as características que foram adquiridas através das gerações anteriores (Carvalho, 2010). Dois operadores comumente usados são os operadores de mutação e os de recombinação (cruzamento ou *crossover*).

3.1.3.1 Operadores de mutação

O operador de mutação é responsável pela manutenção da diversidade genética da população. Para tanto, realiza arbitrariamente uma alteração de um ou mais bits do indivíduo escolhido. Essa mutação permite a inclusão de novos elementos na população. Com a utilização desse operador todos os pontos do espaço de busca podem ser alcançados, pois a cada modificação a direção de busca é alterada, o que auxilia a evitar mínimos locais. Esse operador é aplicado nos algoritmos genéticos como a taxa *Pm*.

A figura 3.4 ilustra uma mutação.



3.1.3.2 Operadores de recombinação

O operador de recombinação, *crossover*, ou cruzamento é responsável pela combinação de informações das características entre os pais escolhidos para que seja possível a herança de características pelos indivíduos filhos para a próxima geração. Esse operador é aplicado nos algoritmos genéticos como a taxa Pc.

Existem várias maneiras de se aplicar a recombinação entre genes de dois pais, sendo as mais comuns a simples, a multipontos e a uniforme. A simples é dada pela escolha de um determinado ponto de corte, e através dessa divisão, o primeiro cromossomo filho copia todo o conteúdo anterior ao ponto de corte de um dos pais e completa o restante com o conteúdo que está após o ponto de corte do outro cromossomo pai. A multipontos consiste na aplicação de dois ou mais pontos de corte. Já a uniforme não possui pontos de corte, mas trabalha com um parâmetro global, com o qual é definida a probabilidade de cada variável ser trocada entre os pais. A figura 3.5 demonstra esses três modelos de operadores de recombinação.



Figura 3.5 – Exemplos típicos de crossover.

4 COMPUTAÇÃO QUÂNTICA

4.1 INTRODUÇÃO

Neste capítulo são apresentados todos os conceitos necessários para a compreensão da computação quântica e sua superposição de estados, bem como um comparativo com algumas características da computação clássica.

4.2 BITS QUÂNTICOS

Em analogia aos conceitos de computação clássica, na computação quântica existe uma quantidade mínima de informação que pode ser representada, sendo denominados de qbit ou bit quântico. A principal diferença entre os bits clássicos e os q-bits é que ao invés do segundo ser representado por apenas dois valores, 1 ou 0, sua definição se dá por dois vetores de estado, $|0\rangle e |1\rangle$, que contêm as seguintes informações:

$$|0\rangle = \begin{bmatrix} 1\\ 0 \end{bmatrix}$$
 e $|1\rangle = \begin{bmatrix} 0\\ 1 \end{bmatrix}$. (4.1)

Essa notação, conhecida como *Bracket*, é utilizada em mecânica quântica e foi descrita inicialmente pelo físico britânico Paul Dirac (Portugal *et al.*, 2004; Araújo, 2008).

Um q-bit genérico $|\psi\rangle$, diferentemente de um bit genérico, é representado por uma combinação linear dos dois vetores de estados descritos em (4.1), conforme segue:

$$|\psi\rangle = \alpha |0\rangle + \beta |1\rangle, \tag{4.2}$$

onde $|0\rangle$ e $|1\rangle$ formam uma base canônica, $|\psi\rangle$ é uma superposição dos vetores e α e β são números complexo tais quais:

$$\alpha = a + jb$$
 e $\beta = c + jd$. (4.3)

Pode-se verificar que um q-bit pertence ao domínio \Re^4 , portanto sua regra de normalização segue a regra dos elementos contidos no mesmo, ou seja:

$$a^{2} + b^{2} + c^{2} + d^{2} = 1.$$
(4.4)

O que significa que:

$$\alpha |^{2} + |\beta|^{2} = 1, \qquad (4.5)$$

onde $|\alpha|^2$ é a probabilidade do q-bit observado estar no estado $|0\rangle e |\beta|^2$ é a probabilidade do mesmo estar no estado $|1\rangle$.

A interpretação física do q-bit é que ele se encontra ao mesmo tempo tanto no estado $|1\rangle$ quanto no $|0\rangle$, podendo armazenar uma quantidade infinita de informações no seu vetor de superposições, ou seja, $|\psi\rangle$. O porém é que, devido a essa informação estar em um nível quântico, quando há a necessidade de observar o estado atual do q-bit, o mesmo entra em colapso e assume um estado único, determinado pelas probabilidades $|\alpha|^2$ e $|\beta|^2$ correspondentes (Narayanan, 1999; Han e Kim, 2002; Khorsand *et al.*, 2006).

4.3 Q-BITS COMPOSTOS

Para que possa ser definida a utilização de diversos q-bits em conjunto para a representação de uma quantidade maior de estados, Portugal *et al.* (2004) propuseram a utilização de produtos tensoriais entre os q-bits desejados.

Um produto tensorial entre dois estados diferentes:

$$|\psi\rangle = \begin{bmatrix} \psi_1 \\ \psi_2 \\ \vdots \\ \psi_m \end{bmatrix} \qquad e \qquad |\varphi\rangle = \begin{bmatrix} \varphi_1 \\ \varphi_2 \\ \vdots \\ \varphi_n \end{bmatrix},$$

é denotado por $|\psi\rangle \otimes |\phi\rangle$ e gera um estado $|X\rangle$ como resultado, que é demonstrado na seqüência:

onde $\psi_i \varphi_{j1}$ é o produto usual entre os números complexos.

O produto tensorial entre dois q-bits resulta em um estado genérico $|\psi\rangle$, quando da superposição de quatro estados, $|00\rangle$, $|01\rangle$, $|10\rangle$ e $|11\rangle$, ou seja:

$$|\psi\rangle = \alpha_1|00\rangle + \alpha_2|01\rangle + \alpha_3|10\rangle + \alpha_4|11\rangle, \qquad (4.7)$$

onde a amplitude dos coeficientes complexos é dada por:

$$\sum_{i=1}^{4} |\alpha_i|^2 = 1.$$
(4.8)

Exemplificando, se dois q-bits, $|\sigma\rangle \in |\vartheta\rangle$ são representados numericamente por:

$$|\sigma\rangle = \frac{1}{\sqrt{2}}|0\rangle + \frac{1}{\sqrt{2}}|1\rangle$$
 e $|\vartheta\rangle = \frac{1}{\sqrt{3}}|0\rangle + \sqrt{\frac{2}{3}}|1\rangle$,
onde ambos satisfazem a equação (4.5) da seguinte maneira:

$$\left|\frac{1}{\sqrt{2}}\right|^2 + \left|\frac{1}{\sqrt{2}}\right|^2 = 1 \qquad e \qquad \left|\frac{1}{\sqrt{3}}\right|^2 + \left|\sqrt{\frac{2}{3}}\right|^2 = 1.$$

Tem-se que a probabilidade do q-bit $|\sigma\rangle$ assumir quando observado tanto o estado $|0\rangle$

como $|1\rangle$ é de $\left|\frac{1}{\sqrt{2}}\right|^2$, ou seja $\frac{1}{2}$, e a probabilidade do q-bit $|\mathcal{P}\rangle$ assumir o estado $|0\rangle$ é de $\left|\frac{1}{\sqrt{3}}\right|^2$, ou seja $\frac{1}{3}$. Para o estado $|1\rangle$, a probabilidade é de $\left|\sqrt{\frac{2}{3}}\right|^2$, resultando em $\frac{2}{3}$.

Aplicando um produto tensorial entre os dois q-bits, tem-se que:

$$\begin{aligned} |\sigma\rangle\otimes|\vartheta\rangle &= \left(\frac{1}{\sqrt{2}}\frac{1}{\sqrt{3}}\right)|00\rangle + \left(\frac{1}{\sqrt{2}}\sqrt{\frac{2}{3}}\right)|01\rangle + \left(\frac{1}{\sqrt{2}}\frac{1}{\sqrt{3}}\right)|10\rangle + \left(\frac{1}{\sqrt{2}}\sqrt{\frac{2}{3}}\right)|11\rangle \\ |\sigma\rangle\otimes|\vartheta\rangle &= \frac{1}{\sqrt{6}}|00\rangle + \frac{1}{\sqrt{3}}|01\rangle + \frac{1}{\sqrt{6}}|10\rangle + \frac{1}{\sqrt{3}}|11\rangle. \end{aligned}$$

Ou seja, o q-bit composto resultante do produto tensorial $|\sigma\rangle \otimes |\vartheta\rangle$ satisfaz também a propriedade dada pela equação (4.5), ou seja:

$$\left|\frac{1}{\sqrt{6}}\right|^2 + \left|\frac{1}{\sqrt{3}}\right|^2 + \left|\frac{1}{\sqrt{6}}\right|^2 + \left|\frac{1}{\sqrt{3}}\right|^2 = \frac{1}{6} + \frac{1}{3} + \frac{1}{6} + \frac{1}{3} = 1,$$

possuindo as probabilidades de assumir os estados $|00\rangle$, $|01\rangle$, $|10\rangle$ e $|11\rangle$ como $\frac{1}{6}$, $\frac{1}{3}$, $\frac{1}{6}$ e $\frac{1}{2}$, respectivamente.

Observa-se que, para um produto tensorial de *m* q⁻bits, existirão 2^m estados disponíveis. Generalizando então, para casos com *m* q⁻bits, assumindo x_i como a representação de um estado, pode-se afirmar que:

$$|X\rangle = \sum_{i=1}^{2^m} \alpha_i x_i , \qquad (4.9)$$

onde as amplitudes dos estados devem satisfazer a seguinte equação:

$$\sum_{i=1}^{2^{m}} |\alpha_{i}|^{2} = 1.$$
(4.10)

Outro conceito importante na computação quântica é o conceito de emaranhamento, o qual define que um estado de 2 q-bits nem sempre é o resultado do produto tensorial entre dois q-bits. Pode-se tomar como exemplo um estado $|01\rangle$, que pode ser escrito como um produto tensorial dos estados $|0\rangle$ e $|1\rangle$, conforme segue:

$$|01\rangle = \begin{bmatrix} 0\\1\\0\\0 \end{bmatrix} = \begin{bmatrix} 1\\0 \end{bmatrix} \otimes \begin{bmatrix} 0\\1 \end{bmatrix}$$

No entanto, o estado:

$$\begin{bmatrix} 0\\1\\1\\0\end{bmatrix}$$

É um estado emaranhado, pois não existe produto tensorial entre estados de um q-bit que resulte nele.

4.4 PORTAS QUÂNTICAS

Para que seja possível realizar operações e evoluções nos q-bits sem perder o foco probabilístico representado pela equação (4.5), existem as portas quânticas. Elas podem ser representadas tanto matematicamente (sendo considerada uma operação unitária U) quanto logicamente (utilizando circuitos quânticos).

Existem vários tipos de portas quânticas utilizadas para evoluir um q-bit genérico $|\psi\rangle$ a um estado evoluído $U|\psi\rangle$, tais quais a porta NOT, a *Controlled* NOT (CNOT), a porta T, a porta S, a porta H e a porta de rotação de Han e Kim (2002), entre outras, das quais algumas serão brevemente apresentadas na seqüência.

4.4.1 Porta NOT quântica

A porta NOT quântica é representada por um operador unitário X que deve, analogamente ao caso clássico, transformar estado 0 em 1 e vice-versa, satisfazendo as seguintes condições:

$$X|0\rangle = |1\rangle$$
 e $X|1\rangle = |0\rangle$. (4.11)

Para satisfazer a equação (4.11), a matriz unitária X deve ser composta da seguinte maneira:

$$X = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}.$$
 (4.12)

Quando essa porta é aplicada aos estados $|0\rangle e |1\rangle$, o resultado é o seguinte:

$$X | 0 \rangle = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} | 0 \rangle = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} = | 1 \rangle$$
$$X | 1 \rangle = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} | 1 \rangle = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} = | 0 \rangle.$$
(4.13)

Ou seja, quando a porta NOT é aplicada a um q²-bit genérico $|\psi\rangle = \alpha |0\rangle + \beta |1\rangle$, assim como a porta NOT clássica, gera a seguinte resposta:

$$X|\psi\rangle = \beta|0\rangle + \alpha|1\rangle. \tag{4.14}$$

4.4.2 Porta CNOT quântica

A porta CNOT quântica é uma operação definida sobre pelo menos dois q-bits, um de controle e um alvo. Uma porta controlada deve ser ativada apenas se o q-bit de controle estiver no estado $|1\rangle$, modificando o valor do segundo q-bit. Numa porta CNOT quântica, os q-bits podem estar superpostos e também emaranhados. A representação da porta CNOT quântica em formato matricial, para 2 q-bits, é a seguinte:

$$U_{CNOT} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}.$$
 (4.15)

Sua aplicação aos quatro estados do produto tensorial entre dois q-bits, considerando que o primeiro é o de controle, é:

$$\begin{split} U_{CNOT} \left| 00 \right\rangle &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \\ U_{CNOT} \left| 01 \right\rangle &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} \\ U_{CNOT} \left| 10 \right\rangle &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} \\ U_{CNOT} \left| 11 \right\rangle = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} . \end{split}$$
(4.16)

4.4.3 Porta Hadamard ou porta H

A porta Hadamard, ou porta H, é de extrema importância quando da aplicação do algoritmo de Grover (Portugal *et al.*, 2004). Tal porta é definida pelo operador:

$$H = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1\\ 1 & -1 \end{bmatrix}.$$
 (4.17)

Aplicando a porta H aos estados $|0\rangle$ e $|1\rangle$, é obtido:

$$H|0\rangle = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{bmatrix} = \frac{1}{\sqrt{2}} (|0\rangle + |1\rangle)$$
$$H|1\rangle = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \begin{bmatrix} 1/\sqrt{2} \\ -1/\sqrt{2} \end{bmatrix} = \frac{1}{\sqrt{2}} (|0\rangle - |1\rangle) .$$
(4.18)

O resultado encontrado demonstra que a porta H transforma um estado de um q⁻bit em uma superposição dos dois estados possíveis, com uma probabilidade de 50% de se obter qualquer um quando uma medição for realizada.

Para o caso genérico, com m d-bits, pode-se afirmar que:

$$H^{\otimes m} | 0...0 \rangle = (H | 0 \rangle)^{\otimes m}$$

$$H^{\otimes m} | 0...0 \rangle = (\frac{1}{\sqrt{2}} (| 0 \rangle + | 1 \rangle))^{\otimes m}$$

$$H^{\otimes m} | 0...0 \rangle = \frac{1}{\sqrt{2^m}} \sum_{i=1}^{2^m} |i\rangle.$$
(4.19)

4.4.4 Porta de Rotação

A porta de rotação foi apresentada por Han e Kim (2002), para atualizar a probabilidade dos indivíduos (q-bits) serem observados em um estado $|0\rangle$ ou $|1\rangle$ em um algoritmo genético, sendo definida por:

$$U(\Delta \theta_i) = \begin{bmatrix} \cos(\Delta \theta_i) & -\sin(\Delta \theta_i) \\ \sin(\Delta \theta_i) & \cos(\Delta \theta_i) \end{bmatrix},$$
(4.20)

onde $\Delta \theta_i$, i = 1, 2, 3, ..., m é o ângulo da rotação de cada um dos m q-bits em direção ao estado $|0\rangle$ ou $|1\rangle$, dependendo de seu sinal. Segue na seqüência uma aplicação dessa porta a um qbit genérico $|\psi\rangle = \alpha |0\rangle + \beta |1\rangle$, com $\Delta \theta_i = \pi/2$:

$$U(\pi/2)|\psi\rangle = \begin{bmatrix} \cos(\pi/2) & -\sin(\pi/2) \\ \sin(\pi/2) & \cos(\pi/2) \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \begin{bmatrix} -\beta \\ \alpha \end{bmatrix}$$
$$|\psi\rangle = -\beta |0\rangle + \alpha |1\rangle.$$
(4.21)

5 ALGORITMOS EVOLUTIVOS INSPIRADOS NA COMPUTAÇÃO QUÂNTICA

Unindo-se a metodologia dos algoritmos evolutivos com a inspiração quântica, surge o QEA. Na computação evolutiva, a representação do indivíduo pode ser binária, numérica ou simbólica, por exemplo. Entretanto, o QEA em sua primeira proposição utiliza um novo recurso para esta representação, chamado de *Q-bit*, que é baseado no conceito do q-bit da computação quântica. O conceito de algoritmos genéticos com inspiração quântica foi inicialmente proposto por Han e Kim (2002), com o algoritmo QEA (*Quantum-inspired evolutionary algorithm*).

5.1 REPRESENTAÇÃO

A representação ou codificação de um indivíduo nos QEA é formada por uma seqüência de *Q-bits*, e representa probabilisticamente uma possível solução ao problema. A vantagem de um indivíduo de *Q-bits* em comparação aos cromossomos ou indivíduos do AG convencional é que ele pode representar uma superposição linear dos estados, propriedade esta derivada da computação quântica, no espaço de busca. Ou seja, um indivíduo de *Q-bits* pode gerar probabilisticamente todos os indivíduos binários que representam as possíveis soluções ao problema, através da observação da *string* de *Q-bits*. Portanto, a representação por *Q-bit* tem uma característica de diversidade populacional melhor que outras representações. Os valores reais definidos como parâmetros mínimo e máximo de busca são transformados em números binários. A aplicação da conversão será demonstrada no capítulo de implementação dos controladores.

Segundo Han e Kim (2002), o QEA é um algoritmo estocástico que apresenta similaridades com outros algoritmos evolutivos. QEA, porém, mantém uma população de indivíduos de *Q-bits*, $Q(t) = \{q_1^t, q_2^t, ..., q_n^t\}$ na geração *t*, onde *n* é o tamanho da população, e

 q_j^t é um indivíduo de *m* q-bits, sendo que *m* é o tamanho da string do indivíduo. Cada *Q-bit* é representado por:

$$q_{j}^{t} = \begin{bmatrix} \alpha_{j1}^{t} & \alpha_{j2}^{t} & \dots & \alpha_{jm}^{t} \\ \beta_{j1}^{t} & \beta_{j2}^{t} & \dots & \beta_{jm}^{t} \end{bmatrix}$$
(5.1)

O que significa que, conforme demonstrado no capítulo 4:

$$\left|\alpha_{ji}^{t}\right|^{2} + \left|\beta_{ji}^{t}\right|^{2} = 1, \qquad (5.2)$$

onde $|\alpha_{ji}^t|^2$ é a probabilidade do q-bit observado estar no estado $|0\rangle e |\beta_{ji}^t|^2$ é a probabilidade do mesmo estar no estado $|1\rangle$.

5.2 ESTRUTURA DO ALGORITMO

A estrutura do algoritmo evolucionário baseado em computação quântica é representado nas figuras 5.1 e 5.2, obtidas de Han e Kim (2002).



Figura 5.1 - Diagrama do fluxo do QEA (Han e Kim, 2002).

Início
geração $t \leftarrow 0$
i) iniciar $Q(t)$
ii) criar $P(t)$ observando os estados de $Q(t)$
iii) avaliar $P(t)$
iv) armazenar as melhores soluções entre $P(t)$ em $B(t)$
v) en quanto $t \le t_{max}$ fazer
início
$t \leftarrow t + 1$
vi) criar $P(t)$ observando os estados de $Q(t-1)$
vii) avaliar $P(t)$
viii) atualizar $Q(t)$ usando portas quânticas
ix) armazenar as melhores soluções entre $B(t-1)$ e
$P(t) \mathbf{em} B(t)$
x) armazenar a melhor solução b entre $B(t)$
xi) se (condição de migração global) então
migrar b para $B(t)$ globalmente
xii) se (condição de migração local) então
migrar $b_j^t \in B(t)$ para $B(t)$ localmente
fim
Fim

Figura 5.2 - Procedimentos para implementação do QEA (Han e Kim, 2002).

A descrição dos passos do algoritmo segue abaixo:

i. Na etapa de inicialização, os α_i^0 e $\beta_i^0, i = 1, 2, ..., m$, de todo $q_j^0 = q_j^t |_{t=0}, j = 1, 2, ..., n$, são inicializados com $1/\sqrt{2}$, ou seja, cada indivíduo q_j^0 representa as superposições lineares de todos os estados com a mesma probabilidade:

$$\left|\psi_{q_{j}^{0}}\right\rangle = \sum_{k=1}^{2m} \frac{1}{\sqrt{2^{m}}} \left|X_{K}\right\rangle$$

$$(5.3)$$

onde X_{K} é o K estado representado pela string binária $(x_{1}, x_{2}, ..., x_{m})$, onde $x_{i}, i = 1, 2, ..., m$ é 0 ou 1 de acordo com a probabilidade de $|\alpha_{i}^{0}|^{2}$ e $|\beta_{i}^{0}|^{2}$, respectivamente.

ii. Nesta etapa são geradas soluções binárias P(0), a partir da observação dos estados de Q(0), onde $P(0) = \{x_1^0, x_2^0, ..., x_n^0\}$ na geração t = 0. Uma solução binária $x_j^0, j = 1, 2, ..., n$ é uma *string* de tamanho *m*, formada pela seleção de 0 ou 1 para cada bit, usando a probabilidade de $|\alpha_i^0|^2$ e $|\beta_i^0|^2$, i = 1, 2, ..., m de q_i^0 , respectivamente.

- iii. Cada solução binária x_i^0 é validada, gerando um valor de *fitness*.
- iv. As melhores soluções iniciais são selecionadas entre as soluções binárias, P(0)e guardadas em B(0), onde $B(0) = \{b_1^0, b_2^0, \dots, b_n^0\}$.
- v. Enquanto não for satisfeito o número de gerações, faça:
- vi. Gera P(t) observando os estados de Q(t-1).
- vii. A solução binária P(t) é validada, gerando um valor de *fitness*.
- viii. Nesta etapa, os *Q-bits* em Q(t) são atualizados com a utilização de portas quânticas, ou *Q-gates* Um *Q-gate* é definido como operador de variação do QEA, que modifica os indivíduos, levando-os a representar melhores soluções ou até eventualmente um único estado.
- ix. As melhores soluções entre B(t-1) e P(t) são selecionadas e então guardadas em B(t).
- x. Se a melhor solução b em B(t) for mais apta que a solução atualmente guardada, a solução guardada é substituída pelo novo b.
- xi. Se a condição de migração global for satisfeita, todos os valores de B(t) são substituídos por b.
- xii. Se a condição de migração local for satisfeita, alguns valores de B(t) são substituídos por b_i^t .
- xiii. Enquanto condição em v. não for satisfeita, retornar para o passo vi.

5.3 PORTA QUÂNTICA DE ROTAÇÃO

O processo de atualização dos valores dos indivíduos do QEA é realizado com a utilização das portas quânticas. O QEA proposto em Han e Kim (2002) utiliza as portas quânticas de rotação, onde o *i*-ésimo *Q*-bit (α_i^t, β_i^t) de q_j^t é atualizado usando a equação 5.4, tal que

$$\begin{bmatrix} \alpha_i^{t+1} \\ \beta_i^{t+1} \end{bmatrix} = U\left(\Delta \theta_i^t \right) \begin{bmatrix} \alpha_i^t \\ \beta_i^t \end{bmatrix} = \begin{bmatrix} \cos(\Delta \theta_i^t) & -\sin(\Delta \theta_i^t) \\ \sin(\Delta \theta_i^t) & \cos(\Delta \theta_i^t) \end{bmatrix} \begin{bmatrix} \alpha_i^t \\ \beta_i^t \end{bmatrix}.$$
(5.4)

Neste trabalho adotam-se os mesmos parâmetros de ângulo e tabela de busca (ver figura 5.3 e tabela 5.1) usados para a porta de rotação do clássico QEA proposto por Han e Kim (2002) com uma variação na constante para uma convergência um pouco mais lenta, ou seja, $\theta_3 = 0.01\pi$, $\theta_5 = -0.01\pi$, e 0 para os outros ângulos. θ_i , i = 1, 2, ..., 8, são os ângulos de rotação a serem aplicados através da equação (5.4), em cada caso descrito na tabela 5.1. Tais parâmetros são utilizados para minimizar o erro de cada controlador nessa dissertação. Após a rotação, o estado do *Q-bit* se aproxima de "0" ou "1", dependendo do sinal do ângulo de rotação. Deve-se enfatizar que a magnitude e o sinal de $\Delta \theta_i$ afetam a velocidade de convergência do QEA. A figura 5.3 representa a rotação de cada q-bit.



Figura 5.3 – Rotação de um q-bit no plano polar (Han e Kim, 2002).

x_{ji}^t	$b_{_{ji}}^{^t}$	$f(x_j^t) \ge f(b_j^t)$	$\Delta heta_i$
0	0	Falso	$ heta_1$
0	0	Verdadeiro	θ_2
0	1	Falso	θ_{3}
0	1	Verdadeiro	$ heta_4$
1	0	Falso	θ_{5}
1	0	Verdadeiro	$\theta_{_6}$
1	1	Falso	θ_7
1	1	Verdadeiro	$\theta_{_8}$

Tabela 5.1 – Ângulos de Rotação dos q-bit.

Com sucessivas aplicações da porta quântica, cada Q-bit do indivíduo se aproxima de 0 ou 1, e o indivíduo tende a convergir para um estado único. Desta maneira, a diversidade das soluções desaparece gradualmente. Por este mecanismo inerente, QEA pode tratar o equilíbrio entre exploração e abuso.

5.4 MODIFICAÇÃO PROPOSTA

O algoritmo MQEA proposto adota uma porta quântica NOT para modificar o valor dos Q-bits se o melhor *fitness* não aumenta enquanto a seguinte relação é satisfeita: $(t / t_{max}) >$ 0.01. Neste caso, a posição *i* do Q-bit individual na geração *t* é selecionado e o valor (α_i^t, β_i^t) do *i*-ésimo Q-bit é atualizado utilizando a porta NOT. A Porta NOT tem uma probabilidade de 50% de ser aplicada. Este método tem inspiração na operação de mutação existente em outros diversos algoritmos evolutivos. Quando a porta NOT é aplicada a um Q-bit genérico $|\psi\rangle = \alpha |0\rangle + \beta |1\rangle$, conforme demonstrado no capítulo 4, resultando em

$$X|\psi\rangle = \beta|0\rangle + \alpha|1\rangle. \tag{5.5}$$

Com essa modificação, há a possibilidade de escapar de ótimos locais, se o algoritmo ficar nesse máximo por um determinado número de gerações. A estrutura do algoritmo após a modificação proposta é demonstrada na figura 5.4.



Figura 5.4 – Estrutura do MQEA.

6 DESCRIÇÃO DOS ESTUDOS DE CASO

6.1 INTRODUÇÃO

A intenção deste capítulo é apresentar quatro processos não-lineares, aos quais serão aplicados os controladores com otimização inspirada na computação quântica.

Definição - Princípio da Superposição dos Efeitos

"A resposta produzida pela aplicação da combinação linear de duas ou mais excitações diferentes é igual à combinação linear das respostas individuais a cada uma das excitações."

Ou seja, tem-se que:

Entradas Saídas

$$u_1 \rightarrow y_1$$

 $u_2 \rightarrow y_2$
 $k_1u_1 + k_2u_2 \rightarrow k_1y_1 + k_2y_2$
(6.1)

Com base nesse princípio, pode-se afirmar que os processos demonstrados na seqüência são não lineares, sendo que todos – trocador de calor, neutralização de pH e coluna de destilação - são controlados em simulações.

6.2 TROCADOR DE CALOR

Um trocador de calor é um reator que utiliza o processo de condensação do vapor para aumentar a temperatura da água do processo. A taxa de fluxo do vapor e a da água do processo podem ser controladas através de válvulas pneumáticas. Um desenho esquemático de um trocador de calor é representado pela figura 6.1.



Figura 6.1 – Trocador de calor.

Um modelo não-linear para a utilização de um trocador de calor foi apresentado em Eskinat *et al.* (1991), utilizando como base para tal modelagem um modelo de dinâmica não linear Hammerstein, dado por um bloco não linear estático em série com um bloco linear dinâmico (Santos, 2007). As condições de estado estacionário para as quais a dinâmica do processo foi obtida são observadas na tabela 6.1.

Item	Valor
Taxa de fluxo de vapor	62% do máximo
Taxa de fluxo da água	42% do máximo
Temperatura de entrada da água	30°C

Tabela 6.1 – Condições de estado estacionário (Trocador de Calor).

As equações dinâmicas encontradas em Eskinat *et al.* (1991) para o processo sãorepresentadas em (6.2).

$$y(t) = \frac{0.207 z^{-1} - 0.1764 z^{-2}}{1 - 1.608 z^{-1} + 0.6385 z^{-2}} x(t)$$
$$x(t) = -31.549u(t-1) + 41.732u^{2}(t-1) - 24.201u^{3}(t-1) + 68.634u^{4}(t-1), \qquad (6.2)$$

onde x(t) é a não-linearidade estática, u(t) é a taxa de fluxo de água do processo, y(t) é a temperatura da água do processo e z^{-n} é um atraso em n unidades. A curva estática do trocador de calor pode ser verificada na figura 6.2.



Figura 6.2 – Curva estática do processo 1.

A curva estática da região em que os controladores serão aplicados, com entradas 15, 35 e 45, pode ser verificada na figura 6.3.



Figura 6.3 - Região a ser controlada da curva estática do processo 1.

Segundo Eskinat *et al.* (1991), quando o fluxo de vapor é modificado, as mudanças na temperatura da água do processo possuem uma característica linear. O processo apresentado apresenta um certo grau de não linearidade quando o fluxo de vapor é mantido constante. O vapor condensado é drenado através de um filtro, que permite a saída apenas da parte líquida. Quando o fluxo de água do processo está alto, a temperatura de saída do vapor cai, ficando menor que a de condensação na pressão atmosférica, transformando assim o vapor num líquido sub-refrigerado. Esse líquido então inunda o trocador de calor, o que ocasiona uma diminuição na área de transferência de calor, ou seja, há uma diminuição da transferência de calor por unidade de massa da água do processo, ocasionando assim a não-linearidade.

Naeem e Al-Duwaish (2001) utilizaram esse modelo para o desenvolvimento de novos controladores.

6.3 NEUTRALIZAÇÃO DE pH

O processo de neutralização de pH consiste em um tanque de agitação com volume (V) constante, no qual é realizada uma mistura composta por três vazões distintas de entrada: uma de ácido (HNO_3), uma de base (NaOH) e uma de um composto ($NaHCO_3$).

Esse processo foi reproduzido em uma bancada de laboratório da UCSB (*University of California, Santa Bárbara*, Estados Unidos da América) em tamanho reduzido (Gómez *et al.*, 2004; Henson e Seborg, 1992; Henson e Seborg, 1997) e é ilustrado na figura 6.4.



Figura 6.4 – Processo de neutralização de pH.

As entradas do sistema são dadas pela taxa de vazão da base (u_1) , pela taxa de vazão do composto (u_2) e pela taxa de vazão do ácido (u_3) , enquanto a saída (y) é o pH da solução efluente. Tanto a taxa de vazão do ácido (u_3) quanto o volume (V) do tanque são assumidos como constantes. Em geral, é utilizada apenas como variável de controle a taxa de vazão da base, com o objetivo de controlar o pH da solução efluente, observando a taxa de vazão do composto como um distúrbio (Gómez *et al.*, 2004).

O modelo do processo de neutralização de pH é não-linear devido à sua equação característica de saída, dada por (6.8). Considerando as invariantes de reação (W_{a1}, W_{b1}) , (W_{a2}, W_{b2}) , (W_{a3}, W_{b3}) e (W_a, W_b) como a vazão da base, a vazão do composto, a vazão do ácido e a solução efluente respectivamente, a dinâmica desse processo é dada por (Gómez *et al.*, 2004; Henson e Seborg, 1992; Henson e Seborg, 1997):

$$\dot{x} = f(x) + g(x)u_1 + p(x)u_2$$

$$h(x, y) = 0,$$
(6.3)

onde

$$x \stackrel{\Delta}{=} [x_1, x_2]^T = [W_a W_b]^T$$
(6.4)

$$f(x) = \left[\frac{u_3}{V}(W_{a3} - x_1), \frac{u_3}{V}(W_{b3} - x_2)\right]^T$$
(6.5)

$$g(x) = \left[\frac{1}{V}(W_{a1} - x_1), \frac{1}{V}(W_{b1} - x_2)\right]^T$$
(6.6)

$$p(x) = \left[\frac{1}{V}(W_{a2} - x_1), \frac{1}{V}(W_{b2} - x_2)\right]^T$$
(6.7)

$$h(x, y) = x_1 + 10^{y-14} - 10^{-y} + x_2 \frac{1 + 2x10^{y-pK_2}}{1 + 10^{pK_1 - y} + 10^{y-pK_2}}.$$
(6.8)

Na equação (6.8), as constantes pK_1 e pK_2 são a primeira e a segunda constantes de dissociação do ácido H_2CO_3 . As condições nominais de operação, apresentadas em (Henson e Seborg, 1992; Henson e Seborg, 1997) podem ser encontradas na tabela 6.2.

$u_3 = 16,60 \text{ ml/s}$	$u_2 = 0.55 \text{ ml/s}$	V = 2900 ml
$u_1 = 15,55 \text{ ml/s}$	y = 7,0	$W_a = -4,32 \ge 10^{-4} \mod 10^{-4}$
$W_{a1} = -3,05 \ge 10^{-3} \mod 10^{-3}$	$W_{b1} = 5 \ge 10^{-5} \text{ mol}$	$W_b = 5,28 \ge 10^{-4} \mod 10^{-4}$
$W_{a2} = -3,00 \ge 10^{-2} \mod 10^{-2}$	$W_{b2} = 3 \ge 10^{-2} \text{ mol}$	$pK_1 = 6,35$
$W_{a3} = 3,00 \ge 10^{-3} \mod 10^{-3}$	$W_{b3} = 0 \text{ mol}$	$pK_2 = 10,25$

Tabela 6.2 - Condições normais de operação (Neutralização de pH).

Um modelo para esse processo foi apresentado em Gómez *et al.* (2004). As equações dinâmicas encontradas para o processo são dadas por:

$$y(t) = \frac{0,0084z^{-1} - 0,0133z^{-2} + 0,0054z^{-3}}{1 - 2,5515z^{-1} + 2,1610z^{-2} - 0,6085z^{-3}}u(t),$$
(6.9)

onde u(t) é a taxa de vazão da base, y(t) é o pH da solução efluente e z^{-n} é um atraso em n unidades.

A característica não-linear estimada do processo é apresentada na figura 6.5.



Figura 6.5 - Característica não-linear estimada do processo de neutralização de pH.

Apesar do processo não-linear possuir essa curva, o controlador será aplicado à aproximação linear contida na equação (6.9), representada pela curva estática apresentada na figura 6.6.



Figura 6.6 – Curva estática da aproximação linear do processo 2.

6.4 COLUNA DE DESTILAÇÃO

A coluna de destilação é um processo importante nas indústrias químicas e pode ocasionar diversos problemas, no que se diz respeito à modelagem e controle, aos engenheiros (Eskinat *et al.*, 1991). Segundo os autores, pode-se encontrar na literatura diversas aplicações da modelagem desse tipo de processo.

Para que seja possível encontrar o modelo dinâmico do processo, algumas premissas são assumidas:

- A volatilidade relativa é constante;
- Eficiência de estágio 100%;
- Respostas de vapor e líquido imediatas;
- Controle de nível perfeito na bomba de refluxo e na base da coluna.

Tendo como base essas premissas, o modelo dinâmico da coluna de destilação é descrito pelas seguintes equações:

Base e trocador de calor

$$M_{b} \frac{dx_{b}}{dt} = L_{1}x_{1} - Bx_{b} - Vy_{b}$$
(6.10)

Condensador e acumulador

$$M_d \frac{dx_d}{dt} = Vy_{nt} - Rx_d - Dx_d$$
(6.11)

Bandeja de alimentação

$$M_{nf} \frac{dx_{nf}}{dt} = V(y_{nf-1} - y_{nf}) + L_{nf+1}x_{nf+1} - L_{nf}x_{nf} + Fz_f$$
(6.12)

Bandeja de topo (destilado)

$$M_{nt} \frac{dx_{nt}}{dt} = V(y_{nt-1} - y_{nt}) + Rx_d - L_{nf} x_{nf}$$
(6.13)

Outras bandejas

$$M_{i} \frac{dx_{i}}{dt} = V(y_{i-1} - y_{i}) + L_{i+1}x_{i+1} - L_{i}x_{i}, \qquad (6.14)$$

onde

$$L_{i} = \begin{cases} R & i > nf \\ R + F & i \le nf \end{cases}$$
$$y_{i} = \frac{\alpha x_{i}}{1 + (\alpha - 1)x_{i}}.$$
(6.15)

As condições normais de operação da coluna de destilação encontram-se na tabela 6.3.

Número de bandejas = 25	Refluxo (R) = 1,477
Bandeja de alimentação = 12	Aquecimento a vapor $(V) = 1,977$
Composição de entrada (x_{nf}) = 0,5	Volatilidade relativa= 2
Composição no topo (x_d)= 0,995	Fluxo do destilado $(D) = 0,5$
Composição na base (x_b) = 0,005	Fluxo na base $(B) = 0.5$
<i>Holdup</i> da base e condensador = $0,5$	Holdup das bandejas = $0,5$

Tabela 6.3 – Condições normais de operação (coluna de destilação).

Partindo das equações dinâmicas do processo, Eskinat *et al.* (1991), utilizaram como base um modelo dinâmico não-linear de Hammerstein para encontrar qual o modelo do processo, de quarta ordem, que pode ser verificado na equação 6.16 (Wang, 2000), tal que

$$y(t) = \frac{0.243z^{-1}}{1 - 0.757z^{-1}}x(t)$$

$$x(t) = 1.04u(t-1) - 14.11u^{2}(t-1) - 16.72u^{3}(t-1) + 562.75u^{4}(t-1), \qquad (6.16)$$

onde x(t) é a não-linearidade estática, u(t) é a taxa de refluxo, em mol/min, y(t) é a composição na bandeja de topo, em porcentagem e z^{-n} é um atraso em n unidades. A curva estática referente a esse processo pode ser observada na figura 6.7.



Figura 6.7 – Curva estática do processo 3.

Pode-se observar que o sistema possui um alto grau de não linearidade. A região a ser controlada, entradas 0.7, 0.8 e 0.9, é representada pela figura 6.8.



Figura 6.8 – Região a ser controlada da curva estática do processo 3.

7 IMPLEMENTAÇÃO DOS CONTROLADORES

Neste capítulo será realizada a implementação dos controladores apresentados no capítulo 2 aos estudos de caso. Para efetuar a sintonia dos parâmetros de cada um, serão utilizados os dois conceitos de algoritmos de otimização apresentados nesta dissertação, o algoritmo genético e o algoritmo evolutivo inspirado na computação quântica.

7.1 PARÂMETROS E CONSIDERAÇÕES INICIAIS

Como parâmetros padrões para todos os controladores, foi adotada na utilização do algoritmo genético uma população de 30 cromossomos, com taxa de mutação Pm de 5% e taxa de cruzamento de 85%. Cada cromossomo é convertido com uma resolução de 16 bits, quantia essa utilizada em placas de aquisição de dados, e foi adotado um padrão de 100 gerações.

Na utilização do algoritmo evolutivo com inspiração quântica, foi adotada uma população de 30, que possuirá 16 Q-Bits para cada elemento, quantia essa utilizada em placas de aquisição de dados. O número de gerações escolhido foi 100 e todos os ângulos de rotação dependendo dos quadrantes das portas quânticas de rotação foram definidos conforme Han e Kim (2002).

Em ambas as aplicações o processo é realizado em 10 experimentos, cada um com uma semente de geração de números aleatórios diferente, baseada no número do experimento. Com esses experimentos, são totalizadas para cada controlador 30000 avaliações (população*geração*experimentos) na função objetivo.

A função objetivo é a minimização do erro do controlador pelo critério de desempenho ITSE (*Integral Time Squared Error*), descrito pela equação (7.1). $ITSE = \int_{t=0}^{\infty} t.e(t).dt ,$

ou seja,

$$ITSE = \sum_{n=0}^{N} (yr - y)^2 n .$$
(7.1)

Quando o sistema possui mais de uma referencia aplicada, o ITSE é dividido em partes, sendo calculado para cada referencia e somente após o término somado em conjunto.

A função *fitness* é calculada então a partir do ITSE, sendo considerada em um intervalo de [0,1000], sendo 1000 o valor utópico para erro nulo e 0 para erro infinito, da seguinte forma:

$$fitness = \frac{1000}{1 + ITSE}.$$
(7.2)

A aplicação do AG realiza a minimização da equação (7.1), para então converter o valor para a equação (7.2) e o MQEA encontra o valor do ITSE e o aplica na equação (7.2), trabalhando com maximização.

A resolução de conversão para a codificação de números decimais para binários pode ser encontrada através da equação (7.3).

$$res = \frac{\lim_{m \to ins} \min_{m \to i$$

onde lim_max é o limite máximo estipulado para a região de busca, lim_min é o limite mínimo estipulado para a região de busca e n_{bits} é o número de bits desejados para a conversão. A conversão de cada um dos números decimais para binário então é realizada de acordo com a equação (7.4).

$$Btemp = \frac{x - (I * \lim_{m \to \infty} \min)}{I * res},$$
(7.4)

onde lim_miné o limite mínimo estipulado para a região de busca, x é o valor decimal a ser convertido, I é uma matriz unitária, *res* é a resolução encontrada através da equação (7.3) e *Btemp* é o número temporário encontrado. Este número encontrado está em um *range* criado do limite mínimo até o limite máximo estipulados, dependendo da resolução. O número *Btemp* é então convertido para binário.

7.2 TROCADOR DE CALOR

A aplicação dos controladores propostos otimizados ao trocador de calor será apresentada nessa seção. A utilização dos sistemas de controle a esse processo utilizará como base os mesmos parâmetros da identificação de Eskinat *et al.* (1991), que são 300 amostras da referencia, com o valor 35 para as 100 primeiras, 45 entre a amostra 101 e a amostra 200 e, por fim, 15 nas amostras restantes. A ação de controle u(t) desse processo deve estar no intervalo [0,1].

7.2.1 Controle PID

Para a aplicação do controlador PID, três parâmetros são necessários, o ganho proporcional K_p , o tempo integral T_i e o tempo derivativo T_d . As faixas adotadas para ambos os algoritmos de otimização é de $[0,100] \in \Re$ para cada uma dessas três variáveis. O resultado obtido pode ser verificado na tabela 7.1.

Trocador de Calor - PID - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	0,0021911	0,0021949	
ITSE	456392,16	455599,35	
ISE	16100,30	16090,36	
MSE	53,668	53,635	
Média do Melhor Fitness	0,0021668	0,0021721	
Média do Pior Fitness	0,0010708	0,0011514	
Média de Desvio Padrão	0,000392	0,000357	
Кр	8,6976	9,3416	
Ti	14,8394	83,3295	
Td	19,1165	18,6465	

Tabela 7.1 – Resultado PID para o processo 1.

Pode-se observar, em termos de *fitness* máximo, média do melhor *fitness* e média de desvio padrão, que o melhor controlador PID para o trocador de calor foi encontrado utilizando sintonia via MQEA, e o resultado pode ser observado na figura 7.1.



Figura 7.1 – (a) Ação de controle PID e (b) Referência e saída do processo 1.

O controle PID, conforme pode ser observado, resultou em uma resposta instável. A variação do sinal de controle PID pode ser verificada na figura 7.2.



Figura 7.2 – Variação da ação de controle PID para o processo 1.

Como pode-se observar, o controlador PID, apesar de seguir a referência, não conseguiu controlar o processo do trocador de calor, tanto na otimização via MQEA quanto via AG. O esforço e a variação de controle foram altos, levando o sistema sempre a saturar a ação.

7.2.2 GMV

Para a aplicação do controlador GMV, três parâmetros são necessários, sendo: a ponderação da saída $(P(q^{-1}))$, a ponderação da referência $(\Gamma(q^{-1}))$ e a ponderação do controle $(\lambda(q^{-1}))$. Como constante, ao parâmetro $\lambda(q^{-1})$ foi multiplicado um polinômio integrador, para garantir erro em regime permanente, tornando-o $\lambda(q^{-1}) = \lambda(q^{-1}) * (1-q^{-1})$. As faixas adotadas para ambos os algoritmos de otimização é de $[0,100] \in \Re$ para cada uma dessas três variáveis. O resultado obtido pode ser verificado na tabela 7.2.

Trocador de Calor - GMV - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	0,002913	0,005943	
ITSE	343307,08	168251,68	
ISE	14055,60	13816,91	
MSE	46,852	46,056	
Média do Melhor Fitness	0,002048	0,002402	
Média do Pior Fitness	0,000124	0,000087	
Média de Desvio Padrão	0,000599	0,000632	
λ	97,4044	96,0845	
Р	2,4292	0,9796	
Mi	2,4689	0,9964	

Tabela 7.2 – Resultado GMV para o processo 1.

Ao analisar a tabela 7.2, é possível verificar que o MQEA obteve um resultado melhor, ou seja, um valor maior em termos de média do melhor *fitness* e *fitness* máximo. O melhor controlador GMV para o trocador de calor pode ser verificado na figura 7.3.



Figura 7.3 – (a) Ação de controle GMV e (b) Referência e saída do processo 1.

A variação do sinal de controle GMV encontrada quando aplicado ao processo 1 pode ser verificada na figura 7.4.



Figura 7.4 – Variação da ação de controle GMV para o processo 1.

Como pode-se observar, o controlador GMV não conseguiu controlar o processo do trocador de calor, tanto na otimização via MQEA quanto via AG, obtendo um resultado melhor que o PID, mas não satisfatório, pois não zera os erros em regime permanente.

7.2.3 DMC

Para a aplicação do controlador DMC, quatro parâmetros são necessários, sendo a quantidade de coeficientes da resposta ao degrau, o horizonte de previsão final (*Ny*), o horizonte de controle (*Nu*) e a ponderação de controle (λ). O número de coeficientes da resposta ao degrau utilizado foi de 50, suficiente para que o trocador de calor estabilize. Apenas os outros 3 parâmetros foram otimizados. A faixa adotada para o horizonte de previsão final é [0,20] $\in Z$, a ponderação de controle está entre [0,200] $\in \Re$ e o horizonte de controle está na faixa [0,5] $\in Z$. O resultado obtido pode ser verificado na tabela 7.3.

Trocador de Calor - DMC - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	0,004154	0,004154	
ITSE	240743,89	240743,89	
ISE	23982,73	23982,73	
MSE	79,942	79,942	
Média do Melhor Fitness	0,003943	0,003958	
Média do Pior Fitness	0,000066	0,000054	
Média de Desvio Padrão	0,001484	0,001298	
λ	11,331349	11,331349	
Ny	6	6	
Nu	3	3	

Tabela 7.3 – Resultado DMC para o processo 1.

O valor encontrado para o *fitness* máximo foi igual para os dois algoritmos de otimização, mas o desvio padrão e a média do melhor *fitness* obtiveram um melhor desempenho com a utilização do MQEA. Essa igualdade se dá devido aos parâmetros inteiros de sintonia do controlador, conforme o GPC.

O controlador DMC utiliza a resposta ao degrau para encontrar os coeficientes para a matriz dinâmica. Nessa aplicação, foram utilizados 50 coeficientes da resposta ao degrau.



Figura 7.5 – Resposta do processo 1 ao degrau unitário.

O melhor controlador DMC para o trocador de calor, encontrado utilizando o MQEA pode ser verificado na figura 7.6 e a variação do sinal de controle na figura 7.7.



Figura 7.6 – (a) Ação de controle DMC e (b) Referência e saída do processo 1.



Figura 7.7 – Variação da ação de controle DMC para o processo 1.

Como pode-se observar, o controlador DMC obteve um excelente desempenho na primeira faixa de atuação, mas quando a referência aumentou, não conseguiu seguir a referencia. O sistema foi novamente controlado apenas quando a referencia desceu para 15, na terceira faixa.

7.2.4 GPC

Para a aplicação do controlador GPC, quatro parâmetros são necessários, sendo: o horizonte de previsão inicial (N_1) , o horizonte de previsão final (Ny), o horizonte de controle (Nu) e a ponderação de controle (λ) . O valor do horizonte de previsão inicial foi mantido constante em 1. Apenas os outros 3 parâmetros foram otimizados. A faixa adotada para o horizonte de previsão final é $[0,20] \in Z$, a ponderação de controle está entre $[0,200] \in \Re$ e o horizonte de controle está na faixa $[0,5] \in Z$. O resultado obtido pode ser verificado na tabela 7.4.

Trocador de Calor - GPC - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	0,0182305	0,0182305	
ITSE	54852,17	54852,17	
ISE	11573,11	11573,11	
MSE	38,577	38,577	
Média do Melhor Fitness	0,0180363	0,0180163	
Média do Pior Fitness	0,0003125	0,0001708	
Média de Desvio Padrão	0,006409	0,006362	
λ	124,2176	124,2176	
Ny	3	3	
Nu	2	2	

Tabela 7.4 – Resultado GPC para o processo 1.

O valor encontrado para o *fitness* máximo foi igual para os dois algoritmos de otimização, mas o desvio padrão do MQEA foi menor. Por outro lado, a média do melhor *fitness* obteve um maior desempenho com a utilização do AG. Esse resultado se deve ao fato de o GPC utilizar números inteiros para dois de seus três parâmetros de sintonia.

O melhor controlador GPC para o trocador de calor, encontrado utilizando tanto o AG quanto o MQEA pode ser verificado na figura 7.8.



Figura 7.8 – (a) Ação de controle GPC e (b) Referência e saída do processo 1.

A variação do sinal de controle GPC pode ser verificada na figura 7.9.



Figura 7.9 – Variação da ação de controle GPC para o processo 1.

Como pode-se observar, o controlador GPC conseguiu controlar o processo em duas faixas de operação, deixando apenas a central com uma variação pequena na resposta. A resposta com AG e com o MQEA foi a mesma, pois os dois algoritmos encontraram os mesmos parâmetros nas respectivas otimizações.

7.2.5 PI Adaptativo

Para a aplicação do controlador PI Adaptativo, são necessários quatro parâmetros, sendo: o pólo dominante A e três parâmetros contidos dentro do vetor de identificação MQR, denominado $\theta(0)$, e definem qual é a estimativa inicial dos parâmetros a, b_0 e b_1 . As faixas adotadas para ambos os algoritmos de otimização é de [-200,200] $\in \Re$ para cada uma das três variáveis de estimação inicial e um valor entre $[0,1] \in \Re$ para o pólo dominante. O resultado obtido pode ser verificado na tabela 7.5.

Trocador de Calor - Adap PI - ITSE		
Amostras	300	
	AG	MQEA
Fitness Máximo	0,055912	0,080646
ITSE	17884,24	12398,82
ISE	5072,31	4100,93
MSE	16,908	13,670
Média do Melhor Fitness	0,050911	0,048185
Média do Pior Fitness	0,000051	0,000048
Média de Desvio Padrão	0,016099	0,012724
A	0,945	0,9966
	-12,4144	-45,9022
Θ	-7,4983	-4,0986
	9 8054	4 2084

Tabela 7.5 - Resultado PI Adaptativo para o processo 1.

Ao se observar os resultados obtidos nas otimizações, é possível notar que o MQEA obteve um *fitness* máximo 44% maior que o encontrado via AG. O desvio padrão também obteve um melhor desempenho com o MQEA, mas a média do melhor *fitness* ficou maior com o AG. O controlador PI adaptativo com melhor desempenho para o trocador de calor, encontrado utilizando o MQEA pode ser verificado na figura 7.10.



Figura 7.10 – (a) Ação de controle PI Adaptativo e (b) Referência e saída do processo 1.

A variação do sinal de controle PI Adaptativo pode ser verificada na figura 7.11.



Figura 7.11 - Variação da ação de controle PI Adaptativo para o processo 1.
Como pode-se observar, o controlador PI Adaptativo conseguiu controlar o processo em todas as faixas de operação satisfatoriamente com a otimização dos parâmetros. O desempenho obtido para o melhor *fitness* pelo MQEA foi 44% maior que o encontrado com o AG, apesar da média do melhor e pior *fitness* ficarem abaixo, em torno de 5%.

7.2.6 Resultados

Todos os resultados apresentados para o processo 1 foram agregados e comparados na tabela 7.6.

Melhores resultados por controlador para o processo 1					
200 Augustus	PID	GMV	DMC	GPC	PI Adaptativo
500 Amostras	MQEA	MQEA	MQEA	MQEA	MQEA
Fitness Máximo	0,0021949	0,005943	0,004154	0,0182305	0,080646
ITSE	455599,35	168251,68	240743,89	54852,17	12398,82
ISE	16090,36	13816,91	23982,73	11573,11	4100,93
MSE	53,635	46,056	79,942	38,577	13,670
Média do Melhor Fitness	0,0021721	0,002402	0,003958	0,0180163	0,048185
Média do Pior Fitness	0,0011514	0,000087	0,000054	0,0001708	0,000048
Média de Desvio Padrão	0,000357	0,000632	0,001298	0,006362	0,012724

Tabela 7.6 – Resumo de resultados para o processo 1.

Pode-se observar que o melhor controlador obtido em termos de *fitness* foi o controlador PI Adaptativo, com um *fitness* máximo encontrado de 0,080646, com o ITSE mínimo encontrado sendo 12398,82. Todos os melhores resultados em comparação entre os algoritmos de otimização foram encontrados com a utilização do MQEA. É possível observar que os controladores GPC e DMC otimizados com MQEA obtiveram o mesmo *fitness* máximo que com o AG, mas foram selecionados por possuírem uma média de desvio padrão menor.

Uma das características do MQEA é que normalmente ele demora mais que o AG para convergir com os ângulos selecionados para rotação, mas quando converge encontra um resultado melhor. A comparação de convergência de todos os controladores otimizados com os dois métodos propostos aplicados ao trocador de calor pode ser verificada na figura 7.12.



Figura 7.12 – Convergência da média dos melhores *fitness* para o processo 1.

Ao analisar a convergência de todos os controladores, pode-se observar que o MQEA possui um tempo de convergência maior que o GA, mas encontra um resultado igual ou melhor nas ultimas gerações. O desempenho dos diferentes controladores aplicados ao processo 1 também pode ser verificado, com uma grande diferença entre o PI adaptativo e os outros.

7.3 NEUTRALIZAÇÃO DE pH

A aplicação dos controladores propostos otimizados ao processo de neutralização de pH será apresentada nessa seção. A utilização dos sistemas de controle a esse processo utilizará como base 600 amostras da referencia, com o valor 7 para as 150 primeiras, 3 entre a amostra 151 e a amostra 300, 9 entre a amostra 301 e 450 e, por fim, 7 nas amostras restantes. A ação de controle u(t) desse processo deve estar no intervalo [0,30].

7.3.1 Controle PID

Para a aplicação do controlador PID, três parâmetros são necessários, o ganho proporcional K_p , o tempo integral T_i e o tempo derivativo T_d . As faixas adotadas para ambos os algoritmos de otimização é de $[0,100] \in \Re$ para cada uma dessas três variáveis. O resultado obtido pode ser verificado na tabela 7.7.

Neutralizador de pH - PID - ITSE			
Amostras	600		
	AG	MQEA	
Fitness Máximo	0,0850997	0,0850997	
ITSE	11749,92	11749,92	
ISE	1339,86	1339,86	
MSE	2,233	2,233	
Média do Melhor Fitness	0,084739	0,084957	
Média do Pior Fitness	0,060733	0,065489	
Média de Desvio Padrão	0,0056445	0,005305	
Кр	90,5409	81,0879	
Ti	7,83398	2,7436	
Td	0,5417	0,6027	

Tabela 7.7 – Resultado do controle PID para o processo 2.

Pode-se observar, em termos de *fitness* máximo que ambos os controladores obtiveram a mesma resposta, mas ao analisar a média do melhor *fitness* e média de desvio padrão, que o melhor controlador PID para o trocador de calor foi encontrado utilizando sintonia via MQEA. O melhor resultado entre os encontrados pode ser observado na figura 7.13.



Figura 7.13 – (a) Ação de controle PID e (b) Referência e saída do processo 2.

A variação do sinal de controle PID pode ser verificada na figura 7.14.



Figura 7.14 – Variação da ação de controle PID para o processo 2.

Como pode-se observar, o controlador PID conseguiu controlar o processo de neutralização de pH satisfatoriamente, cortando todo o sobre-sinal. Ambas as técnicas de otimização encontraram o mesmo resultado com o melhor *fitness*, mas o desempenho em termos de média de desvio padrão foi o do MQEA.

7.3.2 GMV

Para a aplicação do controlador GMV, três parâmetros são necessários, sendo: a ponderação da saída $(P(q^{-1}))$, a ponderação da referência $(\Gamma(q^{-1}))$ e a ponderação do controle $(\lambda(q^{-1}))$. Como constante, ao parâmetro $\lambda(q^{-1})$ foi multiplicado um polinômio integrador, para garantir erro em regime permanente, tornando-o $\lambda(q^{-1}) = \lambda(q^{-1}) * (1-q^{-1})$. As faixas adotadas para ambos os algoritmos de otimização é de $[0,100] \in \Re$ para cada uma dessas três variáveis. O resultado obtido pode ser verificado na tabela 7.8.

Neutralizador de pH - GMV - ITSE			
Amostras	600		
	AG	MQEA	
Fitness Máximo	0,09008655	0,091118	
ITSE	11098,75	10973,76	
ISE	1290,93	1277,23	
MSE	2,152	2,129	
Média do Melhor Fitness	0,080348	0,083116	
Média do Pior Fitness	0,000068	0,000816	
Média de Desvio Padrão	0,030976	0,023756	
λ	0,9644	0,5752	
P	50,0023	33,8628	
Mi	49,9947	33,7865	

Tabela 7.8 – Resultado GMV para o processo 2.

O resultado obtido pela otimização via MQEA foi melhor que o AG, em termos tanto de melhor *fitness* e média de desvio padrão quanto com a média de melhor *fitness*. O melhor controlador GMV para o processo de neutralização de pH, encontrado utilizando o MQEA pode ser verificado na figura 7.15.



Figura 7.15 – (a) Ação de controle GMV e (b) Referência e saída do processo 2.

A variação do sinal de controle GMV pode ser verificada na figura 7.16.



Figura 7.16 – Variação da ação de controle GMV para o processo 2.

Como pode-se observar, o controlador GMV conseguiu controlar o processo, mas demandou um esforço de controle muito instável, que ora deve ser positivo e ora negativo. No sistema real esse esforço pode ocasionar problemas físicos nas válvulas.

7.3.3 DMC

Para a aplicação do controlador DMC, quatro parâmetros são necessários, sendo a quantidade de coeficientes da resposta ao degrau, o horizonte de previsão final (*Ny*), o horizonte de controle (*Nu*) e a ponderação de controle (λ). O número de coeficientes da resposta ao degrau utilizado foi de 350, suficiente para que o tanque de neutralização de pH estabilize. Apenas os outros 3 parâmetros foram otimizados. A faixa adotada para o horizonte de previsão final é [0,20] $\in \mathbb{Z}$, a ponderação de controle está entre [0,200] $\in \mathbb{R}$ e o horizonte de controle está na faixa [0,5] $\in \mathbb{Z}$. O resultado obtido pode ser verificado na tabela 7.9.

Neutralizador de pH - DMC - ITSE			
Amostras	600		
	AG	MQEA	
Fitness Máximo	0,081427	0,081420	
ITSE	12279,89	12280,90	
ISE	1040,82	1041,43	
MSE	1,735	1,736	
Média do Melhor Fitness	0,079622	0,077795	
Média do Pior Fitness	0,049522	0,000909	
Média de Desvio Padrão	0,028289	0,027061	
λ	1,4679	1,4069	
Ny	16	16	
Nu	1	2	

Tabela 7.9 – Resultado DMC para o processo 2.

O controlador DMC utiliza a resposta ao degrau para encontrar os coeficientes para a matriz dinâmica. Nessa aplicação, foram utilizados 350 coeficientes da resposta demonstrada na figura 7.17, pois o processo de neutralização de pH possui uma resposta lenta.



Figura 7.17 - Resposta do processo 2 ao degrau unitário.

A resposta ao degrau unitário do processo 02 é lenta, estabilizando apenas após 300 amostras, conforme figura 7.17. Pode-se observar na tabela 7.9, em termos de *fitness* máximo e média do melhor *fitness*, que o controlador sintonizado via AG obteve um melhor desempenho, mas a média de desvio padrão ficou melhor com a utilização do MQEA. O melhor controlador DMC para o processo de neutralização de pH, encontrado utilizando o AG pode ser verificado na figura 7.18.



Figura 7.18 – (a) Ação de controle DMC e (b) Referência e saída do processo 2.

A variação do sinal de controle DMC pode ser verificada na figura 7.19.



Figura 7.19 – Variação da ação de controle DMC para o processo 2.

Como pode-se observar, o controlador DMC apresentou um comportamento que segue a referencia, mas em poucos momentos conseguiu zerar o erro em regime permanente, principalmente devido ao tempo de estabilização alto do sistema.

7.3.4 GPC

Para a aplicação do controlador GPC, quatro parâmetros são necessários, sendo: o horizonte de previsão inicial (N_1) , o horizonte de previsão final (Ny), o horizonte de controle (Nu) e a ponderação de controle (λ) . O valor do horizonte de previsão inicial foi mantido constante em 1. Apenas os outros 3 parâmetros foram otimizados. A faixa adotada para o horizonte de previsão final é $[0,20] \in Z$, a ponderação de controle está entre $[0,200] \in \Re$ e o horizonte de controle está na faixa $[0,5] \in Z$. O resultado obtido pode ser verificado na tabela 7.10.

Neutralizador de pH - GPC - ITSE			
Amostras	600		
	AG	MQEA	
Fitness Máximo	0,06344	0,063343	
ITSE	15761,73	15786,09	
ISE	1113,07	1114,80	
MSE	1,855	1,858	
Média do Melhor Fitness	0,058345	0,05669	
Média do Pior Fitness	0,001882	0,000089	
Média de Desvio Padrão	0,019233	0,017018	
λ	1,416	1,297	
Ny	19	18	
Nu	5	3	

Tabela 7.10 – Resultado GPC para o processo 2.

Ao observar a tabela 7.10, pode-se verificar, em termos de *fitness* máximo, média do melhor *fitness* e média de desvio padrão, que o melhor controlador GPC para o processo de neutralização de pH foi encontrado utilizando sintonia via AG. Esse controlador pode ser observado na figura 7.20.



Figura 7.20 – (a) Ação de controle GPC e (b) Referência e saída do processo 2.

A variação do sinal de controle GPC pode ser verificada na figura 7.21.



Figura 7.21 – Variação da ação de controle GPC para o processo 2.

O GPC foi melhor otimizado com o algoritmo do AG. Como pode-se observar, o processo foi controlado, mas o GPC é um controlador mais robusto, o que leva a resposta a ser mais lenta, característica do processo de neutralização. Em duas faixas o sinal de controle ficou instável, chegando em dois passos distintos a quase saturar tanto pelo limite mínimo quanto pelo máximo.

7.3.5 PI Adaptativo

Para a aplicação do controlador PI Adaptativo, são necessários quatro parâmetros, sendo: o pólo dominante A e três parâmetros contidos dentro do vetor de identificação MQR, denominado $\theta(0)$, e definem qual é a estimativa inicial dos parâmetros a, b_0 e b_1 . As faixas adotadas para ambos os algoritmos de otimização é de [-200,200] $\in \Re$ para cada uma das três variáveis de estimação inicial e um valor entre $[0,1] \in \Re$ para o pólo dominante. O resultado obtido pode ser verificado na tabela 7.11.

Neutralizador de pH - Adap PI - ITSE			
Amostras	600		
	AG	MQEA	
Fitness Máximo	0,090402	0,091514	
ITSE	11060,61	10926,26	
ISE	1091,78	1083,09	
MSE	1,820	1,805	
Média do Melhor Fitness	0,085921	0,084323	
Média do Pior Fitness	0,001558	0,000588	
Média de Desvio Padrão	0,024105	0,026766	
A	0,787976	0,5143	
	-66,3554	-75,1263	
Θ	-82,3774	-192,6452	
	64,9638	99,1195	

Tabela 7.11 – Resultado PI Adaptativo para o processo 2.

Pode-se observar, em termos de *fitness* máximo, que o MQEA obteve melhor desempenho, porém a média do melhor *fitness* e a média de desvio padrão foram maiores com a utilização do AG. O melhor controlador PI adaptativo para o processo de neutralização de pH, encontrado então utilizando o MQEA pode ser verificado na figura 7.22.



Figura 7.22 – (a) Ação de controle PI adaptativo e (b) Referência e saída do processo 2.

A variação do sinal de controle PI Adaptativo pode ser verificada na figura 7.23.



Figura 7.23 – Variação da ação de controle PI Adaptativo para o processo 2.

Apesar de o desempenho do PI Adaptativo otimizado com o MQEA ter sido melhor que o de outros controladores para o processo 2, a variação do sinal de controle foi muito brusca e o sistema não conseguiu zerar o erro em regime permanente. Por outro lado, a resposta foi mais rápida que as anteriores.

7.3.6 Resultados

Todos os resultados apresentados para o processo 2 foram agregados e comparados na tabela 7.12, apresentada na seqüência.

Melhores resultados por controlador para o processo 2					
600 Amostras	PID	GMV	DMC	GPC	PI Adaptativo
	MQEA	MQEA	AG	AG	MQEA
<i>Fitness</i> Máximo	0,0850997	0,091118	0,081427	0,06344	0,091514
ITSE	11749,92	10973,76	12279,89	15761,73	10926,26
ISE	1339,86	1277,23	1040,82	1113,07	1083,09
MSE	2,233	2,129	1,735	1,855	1,805
Média do Melhor Fitness	0,084957	0,083116	0,079622	0,058345	0,084323
Média do Pior Fitness	0,065489	0,000816	0,049522	0,001882	0,000588
Média de Desvio Padrão	0,005305	0,023756	0,028289	0,019233	0,026766

Tabela 7.12 – Resumo de resultados para o processo 2.

Pode-se observar que o melhor controlador obtido em termos de *fitness* foi o controlador PI Adaptativo, com um *fitness* máximo encontrado de 0,091514, com o ITSE mínimo encontrado sendo 10926,26. Em três dos casos o MQEA apresentou o melhor resultado, sendo PID, GMV e PI Adaptativo, controladores onde existe uma quantidade maior de parâmetros para otimização, considerando número de parâmetros ou range. É possível observar que o controlador PID otimizado com MQEA obteve o mesmo *fitness* máximo que com o AG, mas foi selecionado por possuir uma média de desvio padrão menor.

A comparação de convergência de todos os controladores otimizados com os dois métodos propostos aplicados ao processo de neutralização de pH pode ser verificada na figura 7.24.



Figura 7.24 – Convergência da média dos melhores *fitness* para o processo 2.

Ao analisar a convergência de todos os controladores, pode-se observar que o MQEA possui um tempo de convergência maior que o GA, mas encontra um resultado igual ou melhor nas ultimas gerações. O desempenho dos diferentes controladores aplicados ao processo 2 também pode ser verificado, com a maioria deles obtendo uma aptidão máxima em uma faixa próxima de 0,085, com exceção do GPC, que se manteve próximo de 0,06.

7.4 COLUNA DE DESTILAÇÃO

A aplicação dos controladores propostos otimizados à coluna de destilação será apresentada nessa seção. A utilização dos sistemas de controle a esse processo utilizará como base os mesmos parâmetros da identificação de Eskinat *et al.* (1991), que são 300 amostras da referencia, com o valor 0.7 para as 100 primeiras, 0.9 entre a amostra 101 e a amostra 200 e, por fim, 0.8 nas amostras restantes. A ação de controle u(t) desse processo deve estar no intervalo [0,1]. A otimização dos controladores, foi realizada com base no ITSE. O ISE e o MSE também foram encontrados para comparação.

7.4.1 Controle PID

Para a aplicação do controlador PID, três parâmetros são necessários, o ganho proporcional K_p , o tempo integral T_i e o tempo derivativo T_d . As faixas adotadas para ambos os algoritmos de otimização é de $[0,100] \in \Re$ para cada uma dessas três variáveis. O resultado obtido pode ser verificado na tabela 7.13.

Coluna de Destilação - PID - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	50,685075	50,683064	
ITSE	18,73	18,73	
ISE	4,18	4,18	
MSE	0,014	0,014	
Média do Melhor Fitness	20,582124	24,550038	
Média do Pior Fitness	0,000006	0,000006	
Média de Desvio Padrão	8,513847	6,174986	
Кр	0,177	0,1663	
Ti	56,0799	6,6163	
Td	0,8682	0,9262	

Tabela 7.13 – Resultado do controle PID para o processo 3.

Ao observar a tabela 7.13, é possível verificar que, em termos de *fitness* máximo o AG obteve um melhor desempenho, porém a média do melhor *fitness* e a média de desvio padrão obtiveram valores melhores com a sintonia via MQEA. O melhor controlador PID para a coluna de destilação, utilizando AG pode ser verificado na figura 7.25.



Figura 7.25 – (a) Ação de controle PID e (b) Referência e saída do processo 3.

A variação do sinal de controle PID pode ser verificada na figura 7.26.



Figura 7.26 – Variação da ação de controle PID para o processo 3.

Como se pode observar, o controlador PID conseguiu controlar o processo da coluna de destilação, com sobre-sinal em todas as faixas. O esforço de controle foi pequeno. Apenas na faixa central o sistema apresentou variação sem alcançar a referencia em regime permanente.

7.4.2 GMV

Para a aplicação do controlador GMV, três parâmetros são necessários, sendo: a ponderação da saída $(P(q^{-1}))$, a ponderação da referência $(\Gamma(q^{-1}))$ e a ponderação do controle $(\lambda(q^{-1}))$. Como constante, ao parâmetro $\lambda(q^{-1})$ foi multiplicado um polinômio integrador, para garantir erro em regime permanente, tornando-o $\lambda(q^{-1}) = \lambda(q^{-1}) * (1-q^{-1})$. As faixas adotadas para ambos os algoritmos de otimização é de $[0,100] \in \Re$ para cada uma dessas três variáveis. O resultado obtido pode ser verificado na tabela 7.14.

Coluna de Destilação - GMV - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	16,453206	16,450249	
ITSE	59,78	59,79	
ISE	6,92	6,91	
MSE	0,023	0,023	
Média do Melhor Fitness	11,095335	9,858736	
Média do Pior Fitness	0,000743	0,000032	
Média de Desvio Padrão	4,360679	2,34455	
λ	85,1194	83,769	
Р	3,4577	3,4287	
Mi	2,8458	2,8214	

Tabela 7.14 – Resultado GMV para o processo 3.

O controlador GMV obteve um *fitness* máximo e a média do melhor *fitness* maiores quando sintonizados via AG, porém, pode-se verificar que a média de desvio padrão encontrada foi melhor quando sintonizado via MQEA. O melhor controlador, utilizando o MQEA pode ser verificado na figura 7.27.



Figura 7.27 – (a) Ação de controle GMV e (b) Referência e saída do processo 3.

A variação do sinal de controle GMV pode ser verificada na figura 7.28.



Figura 7.28 - Variação da ação de controle GMV para o processo 3.

Pode-se verificar que o sistema é controlado, com bastante sobre-sinal e variações, mas com um esforço pequeno de controle e zerando o erro em regime permanente nas duas ultimas faixas.

7.4.3 DMC

Para a aplicação do controlador DMC, quatro parâmetros são necessários, sendo a quantidade de coeficientes da resposta ao degrau, o horizonte de previsão final (*Ny*), o horizonte de controle (*Nu*) e a ponderação de controle (λ). O número de coeficientes da resposta ao degrau utilizado foi de 50, suficiente para que a coluna de destilação estabilize. Apenas os outros 3 parâmetros foram otimizados. A faixa adotada para o horizonte de previsão final é [0,20] $\in Z$, a ponderação de controle está entre [0,200] $\in \Re$ e o horizonte de controle está na faixa [0,5] $\in Z$. O resultado obtido pode ser verificado na tabela 7.15.

Coluna de Destilação - DMC - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	0,113167	0,126628	
ITSE	8801,83	7896,12	
ISE	180,84	167,53	
MSE	0,603	0,558	
Média do Melhor Fitness	0,107723	0,114191	
Média do Pior Fitness	0,093875	0,054274	
Média de Desvio Padrão	0,002843	0,015393	
λ	101,564	100,1602	
Ny	2	2	
Nu	17	9	

Tabela 7.15 – Resultado DMC para o processo 3.

O controlador DMC utiliza a resposta ao degrau para encontrar os coeficientes para a matriz dinâmica. Nessa aplicação, foram utilizados 50 coeficientes da resposta demonstrada na figura 7.29.



Figura 7.29 – Resposta do processo 3 ao degrau unitário.

A resposta ao degrau unitário do processo 03 estabiliza após 25 amostras, conforme figura 7.29. Pode-se observar na tabela 7.15, em termos de *fitness* máximo, média do melhor *fitness* e a média de desvio padrão, que o controlador sintonizado via MQEA obteve um melhor desempenho. O controlador DMC melhor sintonizado para a coluna de destilação, encontrado, utilizando o MQEA, pode ser verificado na figura 7.30.



Figura 7.30 – (a) Ação de controle DMC e (b) Referência e saída do processo 3.

A variação do sinal de controle DMC pode ser verificada na figura 7.31.



Figura 7.31 – Variação da ação de controle DMC para o processo 3.

Como se pode observar, o controlador DMC não conseguiu controlar o processo da coluna de destilação, demonstrando instabilidade na resposta e na variação da ação de controle. Tal fato se deve à resposta ao degrau possuir um ganho de em torno de 530 unidades ao degrau aplicado. A ponderação do sinal de controle nesse sistema é muito sensível.

7.4.4 GPC

Para a aplicação do controlador GPC, quatro parâmetros são necessários, sendo: o horizonte de previsão inicial (N_1) , o horizonte de previsão final (Ny), o horizonte de controle (Nu) e a ponderação de controle (λ) . O valor do horizonte de previsão inicial foi mantido constante em 1. Apenas os outros 3 parâmetros foram otimizados. A faixa adotada para o horizonte de previsão final é $[0,20] \in Z$, a ponderação de controle está entre $[0,200] \in \Re$ e o horizonte de controle está na faixa $[0,5] \in Z$. O resultado obtido pode ser verificado na tabela 7.16.

Coluna de Destilação - GPC - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	51,2342	51,2342	
ITSE	18,16	18,16	
ISE	3,86	3,86	
MSE	0,013	0,013	
Média do Melhor Fitness	47,0004	49,7433	
Média do Pior Fitness	0,0949	0,0199	
Média de Desvio Padrão	17,971852	17,491399	
λ	10,0221	10,0221	
Ny	3	3	
Nu	1	1	

Tabela 7.16 – Resultado GPC para o processo 3.

Ao observar a tabela 7.16, pode-se verificar que, em termos de *fitness* máximo, a sintonia via AG e MQEA obteve o mesmo resultado, com os mesmos parâmetros encontrados para os horizontes de previsão e controle e para a ponderação de controle. A média do melhor *fitness* e a média de desvio padrão ficaram melhores com a utilização do algoritmo MQEA. O melhor controlador GPC para o processo 3, encontrado utilizando tanto o AG quanto o MQEA pode ser verificado na figura 7.32.



Figura 7.32 – (a) Ação de controle GPC e (b) Referência e saída do processo 3.

A variação do sinal de controle GPC pode ser verificada na figura 7.33.



Figura 7.33 – Variação da ação de controle GPC para o processo 3.

Como se pode observar, o controlador GPC conseguiu controlar o processo, mas com sobre-sinal e com uma pequena variação, não alcançando o zero em regime permanente. O maior *fitness* foi encontrado nas duas otimizações, mas o MQEA leva vantagem em termos de média de melhor *fitness* e média de desvio padrão.

7.4.5 PI Adaptativo

Para a aplicação do controlador PI Adaptativo, são necessários quatro parâmetros, sendo: o pólo dominante A e três parâmetros contidos dentro do vetor de identificação MQR, denominado $\theta(0)$, e definem qual é a estimativa inicial dos parâmetros a, b_0 e b_1 . As faixas adotadas para ambos os algoritmos de otimização é de [-200,200] $\in \Re$ para cada uma das três variáveis de estimação inicial e um valor entre $[0,1] \in \Re$ para o pólo dominante. O resultado obtido pode ser verificado na tabela 7.17.

Coluna de Destilação - Adap PI - ITSE			
Amostras	300		
	AG	MQEA	
Fitness Máximo	43,907883	62,804165	
ITSE	21,77	14,92	
ISE	2,90	2,22	
MSE	0,010	0,007	
Média do Melhor Fitness	14,6813	20,9168	
Média do Pior Fitness	0,0303	0,0015	
Média de Desvio Padrão	5,038352	5,463314	
A	0,2103	0,6133	
	-0,5768	-0,1617	
Θ	-30,6676	-86,833	
	6 9306	54 6365	

Tabela 7.17 - Resultado PI Adaptativo para o processo 3.

O controlador PI adaptativo foi melhor sintonizado, em termos de *fitness* máximo, média do melhor *fitness* e média do desvio padrão com a utilização do algoritmo MQEA.O controlador aplicado ao processo da coluna de destilação pode ser verificado na figura 7.34.



Figura 7.34 – (a) Ação de controle PI adaptativo e (b) Referência e saída do processo 3.

A variação do sinal de controle PI Adaptativo pode ser verificada na figura 7.35.



Figura 7.35 – Variação da ação de controle PI Adaptativo para o processo 3.

Como pode-se observar, o controlador PI Adaptativo conseguiu controlar o processo em todas as faixas de operação com a otimização dos parâmetros, mas com um pouco de sobre-sinal. O desempenho obtido para o melhor *fitness* pelo MQEA foi 44% maior que o encontrado com o AG, apesar da média de desvio padrão ficar um pouco abaixo, em torno de 9%.

7.4.6 Resultados

Todos os resultados apresentados para o processo 3 foram agregados e comparados na tabela 7.18, apresentada na seqüência.

Melhores resultados por controlador para o processo 3							
300 Amostras	PID	GMV	DMC	GPC	PI Adaptativo		
	AG	AG	MQEA	MQEA	MQEA		
Fitness Máximo	50,685075	16,45321	0,126628	51,2342	62,804165		
ITSE	18,73	59,78	7896,12	18,16	14,92		
ISE	4,18	6,92	167,53	3,86	2,22		
MSE	0,014	0,023	0,558	0,013	0,007		
Média do Melhor Fitness	20,582124	11,09534	0,114191	49,7433	20,9168		
Média do Pior Fitness	0,000006	0,000743	0,054274	0,0199	0,0015		
Média de Desvio Padrão	8,513847	4,360679	0,015393	17,491399	5,463314		

Tabela 7.18 – Resumo de resultados para o processo 3.

Pode-se observar que o melhor controlador obtido em termos de *fitness* foi o controlador PI Adaptativo, com um *fitness* máximo encontrado de 62,804165, com o ITSE mínimo encontrado sendo 14,92. Para a comparação o resultado do DMC será desconsiderado, tendo em vista que não controlou o sistema.

Dos 4 controladores que foram efetivos, 2 foram mais bem sintonizados com a utilização do AG e 2 com o MQEA. O controlador que obteve a maior diferença entre os 2 algoritmos de otimização foi o PI Adaptativo, que obteve uma diferença de 44%. Os 2 controladores melhor sintonizados pelo AG, o PID e o GMV, obtiveram um resultado muito próximo do melhor *fitness* encontrado com o MQEA. É possível observar que o controlador GPC otimizado com MQEA obteve o mesmo *fitness* máximo que com o AG, mas foi selecionado por possuir uma média de desvio padrão menor.

A comparação de convergência de todos os controladores otimizados com os dois métodos propostos aplicados ao trocador de calor pode ser verificada na figura 7.36. Essa figura não engloba os valores encontrados com o DMC.



Figura 7.36 - Convergência da média dos melhores fitness - Processo 3.

É possível observar que a combinação que melhor converge nas gerações é o GPC otimizado com o MQEA. O PI Adaptativo, que obteve o maior *fitness*, ficou apenas na intermediária, sendo o 5º apenas nesse aspecto.

8 CONCLUSÃO

Baseado nos objetivos propostos, que eram os de modificar e utilizar uma técnica de sintonia em diversa técnicas de controle e compará-las com uma técnica existente, os algoritmos genéticos, foi necessário conduzir um estudo abrangendo a teoria de controle clássico, preditivo e adaptativo, englobando cinco diferentes técnicas, o PID, o GMV, o DMC, o GPC e o PI adaptativo. Além dessas, foi necessária a atenção em uma área desenvolvida nos últimos anos, que é a computação quântica.

O objeto de estudo para a utilização e modificação da técnica foi o q-bit, cujas propriedades, definições e aplicações foram demonstradas no decorrer deste projeto. Foi então necessário o estudo do QEA, desenvolvido por Han e Kim (2002), para que fosse possível uma modificação para a aplicação nos controladores. A modificação realizada foi a inclusão de um sistema análogo à mutação de algoritmos genéticos, para modificar os valores dos indivíduos após um determinado número de gerações com o valor da função objetivo estabilizada. O algoritmo com essa mudança proposta foi denominado de MQA.

Todos os controladores foram então aplicados aos 3 processos não lineares propostos, com a sintonia de seus parâmetros realizada de duas maneiras, sendo a primeira via algoritmos genéticos e a segunda via MQEA. Essa aplicação foi realizada individualmente por controlador para cada processo, gerando então 30 diferentes aplicações diversas com 30000 validações da função objetivo em cada.

Ao analisar a resposta obtida para a aplicação de controle no capítulo 7, pode-se verificar que o MQEA proposto obteve uma resposta satisfatória na maioria dos casos, conforme demonstrado na tabela 8.1, com 71%. É possível também observar que o método proposto obteve um melhor desempenho no PI adaptativo, o que leva à conclusão que o percentual de sucesso do MQEA é maior quando aplicado em problemas que possuam um maior número de variáveis a ser otimizadas, com uma região de aplicação maior.

MELHORES RESULTADOS				
	PROCESSO 1			
	GA	IQEA		
PID		Х		
GMV		Х		
DMC		Х		
GPC		Х		
PI Adaptativo		Х		
	PROCESSO 2			
	GA	IQEA		
PID		Х		
GMV		Х		
DMC	Х			
GPC	Х			
PI Adaptativo		Х		
	PROCESSO 3			
	GA	IQEA		
PID	Х			
GMV	Х			
DMC	-	-		
GPC		X		
PI Adaptativo		Х		
TOTAL	4	10		
PERCENTUAL	29%	71%		

Tabela 8.1 - Percentual de melhores resultados encontrados.

A convergência do MQEA, levando em conta as médias de melhor *fitness*, foi mais demorada que a do AG, mas obteve em geral um melhor resultado. Baseado nos resultados encontrados, conclui-se que o MQEA pode ser uma boa opção para a sintonia de parâmetros de controladores.

8.1 PRÓXIMOS TRABALHOS

Como próximos estudos, pode-se citar novas otimizações na metodologia de mutação e seleção do MQEA, como a utilização de medição de diversidade ou outros métodos baseados em computação evolutiva. Outra possibilidade é expandir o método MQEA para processos de controle multivariável, ou com restrições.

9 REFERÊNCIAS BIBLIOGRÁFICAS

AGRAWAL, S.; LAKSHMINARAYANAN, P. Tuning proportional-integral-derivative controllers using achievable performance indices, **Industrial & Engineering Chemical Research**, 42(22):5576-5582, 2003.

ALTINTEN, A. Generalized predictive control applied to a pH neutralization process, **Computers & Chemical Engineering**, 31(10):1199-1204, 2007.

ARAUJO, M. P. M. Síntese evolucionária de circuitos seqüenciais inspirada nos princípios da computação quântica, Dissertação de mestrado, Rio de Janeiro, RJ: Universidade do Estado do Rio de Janeiro, 2008.

ARROYO-FIGUEROA, G.; SANCHEZ-LOPEZ, A.; VILLAVIVENCIO-RAMIREZ, A. Advanced control algorithms for steam temperature regulation of thermal power plant, **International Journal of Electrical Power and Energy Systems**, 26(10):779-785, 2004.

ÅRZÉN, K. J. A simple event based PID, Proceedings of the 14th IFAC World Congress, Q:423–428, Beijing, China, 1999.

ÅSTRÖM, K. J. Theory and applications of adaptive control – a Survey, Automatica, 19(5):471–486, 1983.

ÅSTRÖM, K. J.; HÄGGLUND, T. Automatic tuning of PID controllers, **The Control Handbook**, cap. 52, 817-826, CRC Press, 1996.

ÅSTRÖM, K. J.; HÄGGLUND, T. The future of PID Control, Control Engineering Practice, 9(11):1163-1175, 2001.

ÅSTRÖM, K. J.; HÄGGLUND, T. **PID Controllers: Theory, Design, and Tuning**, 2^a ed. Instrument Society of America, Research Triangle Park, NC, USA, 1995.

ÅSTRÖM, K. J., WITTENMARK, B. A survey of adaptive control applications, **Proceedings** of the 34th Conference on Decision and Control, 649-654, New Orleans, USA, Dec. 1995b.

ÅSTRÖM, K. J.; WITTENMARK, B. Adaptive Control, 2^a ed. Addison Wesley Publishing Company, 1995a.

ÅSTRÖM, K. J.; WITTENMARK, B. Computer-Controlled Systems, 3^a ed. Prentice Hall, 1997.

ÅSTRÖM, K. J.; WITTENMARK, B. On self-tuning regulators, Automatica 9(2):185-199, 1973.

BOBÁL, V.; BÖHM, J.; FESSL, J.; MACHÁCEK, J. Digital self-tuning controllers: algorithms, implementation and applications, London, UK: Springer Verlag, 2005.

CAMACHO, E. F.; BORDONS, C. Model predictive control in process industry, New York, USA: Springer Verlag, 1997.

CAMACHO, E. F.; BORDONS, C. A generalized predictive controller for a wide class of industrial processes, **IEEE Transactions on Control Systems Technology**, 6(3):372-387, 1998.

CAMACHO, E. F.; BORDONS, C. Model predictive control, 2^a ed. London, UK: Springer Verlag, 2003.

CAMACHO, E. F.; RUBIO, F. R; HUGHES, F. M. Self tuning control of a solar power plant with a distributed collector field, **IEEE Control Systems**, 12(2):72-78, 1992.

CAON JR., J. R. Controladores PID industriais com sintonia automática por realimentação à relé, Dissertação de Mestrado, São Carlos, SP: Universidade de São Carlos, 1999.

CARVALHO, A. P. L. F. **Conceitos dos algoritmos genéticos**, disponível em < <u>http://www.icmc.usp.br/~andre/research/genetic/index.htm</u>>. Acessado em 14/03/2010.

CLARKE, D.W.; GAWTHROP, P.J. Self tuning controller, IEE Proceedings, 122(9):929–934, 1975.

CLARKE, D.W.; GAWTHROP, P.J. Self tuning control, **IEE Proceedings**, 126(6):633–640, 1979.

CLARKE, D.W. Self tuning control, **The control Handbook**, cap. 53, 827-846, CRC Press, 1996.

CLARKE, D.W.; MOHTADI, C.; TUFFS, P.S. Generalized predictive control: Part I: The basic algorithm, Automatica, 23(2):137–148, 1987.

CLARKE, D.W.; MOHTADI, C.; TUFFS, P.S. Generalized predictive control: Part II: Extensions and interpretations, **Automatica**, 23(2):149–160, 1987.

CLARKE, D.W.; MOHTADI, C. Properties of generalized predictive control, **10th World Congress on Automatic Control Preprints**, vol. 10:149–160, Munique, Alemanha, 1987.

COELHO, A. A. R.; COELHO, L. S. Identificação de Sistemas Dinâmicos Lineares, Editora da UFSC, Florianópolis, SC, 2004.

COELHO, L. S.; BERNERT, D. L. A. An improved harmony search algorithm for synchronization of discrete-time chaotic systems, **Chaos, Solitons & Fractals**, 41(5):2526-2532, 2009.

COELHO, L. S.; BERNERT, D. L. A. PID control design for chaotic synchronization using a tribes optimization approach, **Chaos, Solitons & Fractals**, 42(1):634-640, 2009.

COELHO, L. S. ; GREBOGI, R. B.; BERNERT, D. L. A. PID tuning using a modified particle swarm optimization approach applied to chaotic synchronization. **Proceedings of 20th International Congress of Mechanical Engineering**, COBEM, 2009, Gramado, RS.

CRUZ, A. V. A. Algoritmos evolutivos com inspiração quântica para problemas com representação numérica, Tese de Doutorado, Rio de Janeiro, RJ: PUC-Rio, 2007.

CUTLER, C. R.; RAMAKER, B. L. Dynamic matrix control - a computer control algorithm., Automatic Control Conference, San Francisco, CA, USA, 1980.

DE KEYSER, R. M. C.; VAN CAUWENBERGHE, A. L. Extended prediction self-adaptive controller, **IFAC Symposium on Identification and System Parameter Estimation**, 1255-1260, York, U.K., 1985.

DUTRA, C. B. S. **Controle preditivo multiobjetivo para processos com atraso,** Tese de Doutorado, Florianópolis, SC: Universidade Federal de Santa Catarina, 2003.

EKLUND, P.; TUFVESSON, M. **Predictive control of irrigation channels,** Lund (Suécia): Lund Institute of Technology, 2000.

ESKINAT, E.; JOHNSON, S. H.; LUYBEN, W. L. Use of Hammerstein in identification of nonlinear systems, **AIChE Journal**, 37(2):255-268, 1991.

FACCIN, F. Abordagem inovadora no projeto de controladores PID, Dissertação de Mestrado, Porto Alegre, RS: Universidade Federal do Rio Grande do Sul, 2004.

FERNANDES JR., F. G. **Metodologia para re-sintonia de controladores PID industriais**, Dissertação de Mestrado, Natal, RN: Universidade Federal do Rio Grande do Norte, 2006.

FLEMING, P. J.; PURSHOUSE, R. C. Genetic algorithms in control systems engineering, **Proceedings of 12th IFAC World Congress**, (2):383-390, Sidney, Australia, 2001.

FOGEL, L. J.; OWENS, A. J.; WALSH, M. J. Artificial intelligence through simulated evolution, New York, USA: John Wiley & Sons Inc., 1966.

AGWTHROP, P.J. Some interpretations of the self-tuning controller, IEE Proceedings, 124(10):889–894, 1977.

GOLDBERG, D. E. Genetic algorithms in search, optimization and machine learning, Boston, USA: Addison-Wesley Longman Publishing Co. Inc., 1989.

GÓMEZ, J. C.; JUTAN, A.; BAEYENS, E. Wiener model identification and predictive control of a pH neutralization process, **IEEE Proceedings on Control Theory and Applications**, 151(3):329-228, 2004.

GUIAMBA, I. R. F.; MULHOLLAND, M. - Adaptive linear dynamic matrix control applied to an integrating process, **Computers and Chemical Engineering**, 28(12):2621-2633, 2004.

HAN, K. H.; KIM, J. H. Quantum-inspired evolutionary algorithm for a class of combinatorial optimization, IEEE Transactions on Evolutionary Computation, 6(6):580-593, 2002.

HAN, K. H.; KIM, J. H. On the analysis of the quantum-inspired evolutionary algorithm with a single individual, **Proceedings of the 2006 IEEE Congress on Evolutionary Computation**, Vancouver, BC, Canada, 2622-2629, 2006.

HENSON, M.; SEBORG, D. Adaptive nonlinear control of a pH neutralization process, **IEEE Transactions on Control System Technology**, 2(3):169–182, 1994.

HENSON, M.; SEBORG, D. Nonlinear process control, New Jersey, USA: Prentice Hall, 1997.

HO, H. L.; RAD, A.B.; CHAN C. C.; WONG, Y. K. Comparative studies of three adaptive controllers, **ISA Transactions**, 38(1):43-53, 1999.

HOLLAND, J. Adaptation in natural and artificial systems, Michigan, USA: University of Michigan Press, 1975.

HOUK, B. G. Model predictive control of a delayed coking unit with DMC Development issues, **Fuel and Energy Abstracts**, 37(3):176-176, 1996.

ISERMANN, R.; MATKO, D.; LACHMANN, K. H. Adaptive control systems, Prentice Hall, New Jersey, USA, 1992.

KARACAN, S. Application of a non-linear long range predictive control to a packed distillation column, **Chemical Engineering and Processing**, 42(12):943-953, 2003.

KATEBI, M. R.; ORDYS, A. W. Minimum variance control, **The Control Handbook**, Levine, W. S., Cap. 62, 1089-1096, Boca Raton, USA: CRC Press, 1996.

KHORSAND, A. R.; AKBARZADEH-T, M. R.; MOIN, H. Genetic quantum algorithm for voltage and pattern design of piezoelectric actuator, **Proceedings of the 2006 IEEE Congress on Evolutionary Computation**, Vancouver, BC, Canada: 2593-2600, 2006.

KOZA, J. Genetic programming: on the programming of computers by means of natural selection, USA: MIT Press, 1992.

LU, C. H.; TSAI, C. C. Generalized predictive control using recurrent fuzzy neural networks for industrial processes, **Journal of Process Control**, 17(1):83-92, 2007.

LUNDSTROM, P.; LEE, J. H.; MORARI, M.; SKOGESTAD, S. Generalized predictive control using recurrent fuzzy neural networks for industrial processes, **Computers and Chemical Engineering**, 19(4):409-421, 1995.

MAITI, S. N.; SARAF, D. N. Adaptive dynamic matrix control of a distillation column with closed-loop online identification, **Journal of Process Control**, 5(5):315-327, 1995.

McINTOSH, A. R.; SHAH, S. L.; FISHER, D. G. Analisys and tuning of adaptive generalized predictive control, **The Canadian Journal of Chemical Engineering**, 69(1):97-110, 1991.

MIKKI, S. M.; KISHK, A. A. Quantum particle swarm optimization for electromagnetics, **IEEE Transactions on Antennas and Propagation**, 54(10):2764-2775, 2006.

MUNIZ, L. A. R. Controle preditivo adaptativo aplicado a um reator de pirólise operando em regime semi-batelada, Tese de Doutorado, Florianópolis, SC: Universidade Federal de Santa Catarina, 2004.

NAEEM, W.; AL-DUWAISH H. Nonlinear model predictive control of Hammerstein and Wiener models using genetic algorithms, **Proceedings of the 2001 IEEE International Conference on Control,** 465-469, Cidade do México, México, 2001.

NARENDRA, K. S. Parameter adaptive control: The end or the beginning?, **IEEE Conference on Decision and Control**, Lake Buena Vista, FL, USA, 3:2117-2125, 1994.

NETO, J. X. V.; BERNERT, D. L. A.; COELHO, L. S. Diferentes algoritmos evolutivos inspirados em computação quântica aplicados à otimização de despacho econômico de energia elétrica. **IX Simpósio Brasileiro de Automação Inteligente**, SBAI, 2009, Brasília, DF.

NETO, J. X. V.; BERNERT, D. L. A.; COELHO, L. S. Otimização de despacho econômico de energia elétrica baseado em um algoritmo evolutivo com inspiração quântica e informação de diversidade. **IX Congresso Brasileiro de Redes Neurais / Inteligência Computacional**, CBRN, 2009, Ouro Preto, MG.

NÚÑEZ-REYES, A.; SCHEFFER-DUTRA, C.B.; BORDONS, C. Comparison of different predictive controllers with multi-objective optimization. Application to an olive oil mill. **Proceedings of Congress of Control Applications,** p. 1242–1247, Glasgow, Scotland, 2002.

OAGTA, K. Engenharia de Controle Moderno, 2^a ed. Prentice Hall, Rio de Janeiro, RJ, Brasil, 1993.

OLIVEIRA, I. S.; SARTHOUR, R.; BULNES, J.; BELMONTE, S. B.; GUIMARÃES, A. P.; AZEVEDO, E. R. de; VIDOTO, E. L. G.; BONAAGMBA, T. J.; FREITAS, J. C. C. Computação quântica: Manipulando a informação oculta do mundo quântico. **Ciência Hoje**, 33(193), 22–29, 2003.

OLIVEIRA, P.; SEQUEIRA, J.; SENTIEIRO, J. Selection of controller parameters using genetic algorithms, Engineering systems with intelligence. Concepts, tools, and applications, 431-438, Kluwer Academic Publishers, Dordrecht, Netherlands, 1991.

ONNEN, C.; BABUSKA, R.; KAYMAK, U.; SOUSA, J. M.; VERBRUGGEN, H. B.; ISERMANN, R. Genetic algorithms for optimization in predictive control, **Control Engineering Practice**, 5(10):1363-1372, 1997.

OSMAN, M. S.; ABO-SINNA, M. A; MOUSA, A. A. An effective genetic algorithm approach to multiobjective resource allocation problems (MORAPs), Applied Mathematics and computation, 163(2):755-768, 2005.

PIÑÓN, S. M.; CAMACHO, E. F.; KUCHEN, B. Constrained predictive control of a greenhouse, **Proceedings of the 15th IFAC Triennal World Congress**, Barcelona, Espanha, 2002.

PORTER, B.; JONES, A. H. Genetic tuning of digital PID controllers, Electronics Letters, 28(9):843-844, 1992.

PORTUGAL, R.; LAVOR, C. C.; CARVALHO, L. M.; MACULAN, N. Uma introdução à computação quântica, **Notas em Matemática Aplicada**, vol. 8, 62 p., 2004.

QIN, S. J.; BADGWELL, T. A. An overview of industrial model predictive control technology. Chemical Process Control, 93(316):232-256,1997.

RECHENBERG, I. Evolutionstrategie: optimierung technishes systeme nach prinzipien der biologischen evolution, Tese de Doutorado, Berlim, Alemanha: Frommann-Hoolzboog Verlag, 1973.

RODRIGUES, J. A. D.; TOLEDO, E. C. V.; FILHO, R. M. A tuned approach of the predictive–adaptive GPC controller applied to a fed-batch bioreactor using complete factorial design, **Computers and Chemical Engineering**, 26(10):1493–1500, 2002.

ROSSITER, J. A. **Model-based predictive control: A practical approach**, Boca Raton, CA, USA: CRC Press, 2004.

RUBIO, F. R; HUGHES, F. M.; CAMACHO, E. F. Self tuning PI control of a solar power plant, **Preprints of IFAC Symposium in Adaptive System in Control and Signal Processing**, 335–340, Glasgow, Scotland, 1989.

SALAMANCA, H. L. L. Análise, sintonia, experimentação de controladores PID via projetos GMV e GPC, Dissertação de Mestrado, Florianópolis, SC: Universidade Federal de Santa Catarina, 2007.

SANTOS, J. E. S. **Controle preditivo não-linear para sistemas de hammerstein**, Tese de Doutorado, Florianópolis, SC: Universidade Federal de Santa Catarina, 2007.

SANTOS, J. E. S. **Critérios de desempenho e aspectos de robustez na síntese de controladores preditivos,** Dissertação de Mestrado, Florianópolis, SC: Universidade Federal de Santa Catarina, 1998.

SASTRY, S.; BODSON, M. Adaptive control: stability, convergence and robustness, Prentice Hall, Englewood Cliffs, NJ, USA, 1989.

SCHWEFEL, H. –P. Numerische optimierung von computer-modellen, Tese de Doutorado, Birkhauser, Alemanha, 1977.

SILVA, F. T. Simulated annealing aplicado ao problema da sintonia de parâmetros de controladores PID, Monografia de Graduação, Ouro Preto, MG: Universidade Federal de Ouro Preto, 2005.

TAKATSU, H.; ITOH, T. Future needs for control theory in industry – Report of the control technology survey in Japanese industry, **IEEE Transactions on Control Systems Technology**, 7(3), 298-305,1999.

VANDOREN, V. J. **Techniques for adaptive control**, 1^a ed. Butterworth-Heinemann, Elsevier Science, USA, 2003.
VLACHOS, C.; WILLIAMS, D.; GOMM, J. B. Genetic approach for decentralized PID controller tuning for multivariable processes, **IEEE Proceedings on Control Theory and Applications**, 146(1):58-64, 1999.

WANG, F.; LI, M.; AGO, F. An analytical predictive control law for a class of nonlinear processes, **Industrial and Engineering Chemistry Research**, ACS – American Chemical Society, 39(6):2029-2034, 2000.

WANG, L. Model predictive control: System design and implementation using MATLAB®, 1^a. ed. London: Springer Verlag, 2009.

WELLSTEAD, P. E. E.; ZARROP, M. B. Self-tuning systems: Control and signal processing, John Wiley & Sons, New York, NY, USA, 1991.

XU, M.; LI, S. Practical generalized predictive control with decentralized identification approach to HVAC systems, **Energy and Conversion Management**, 48(1):292-299, 2007.

YDSTIE, B. E. Extended horizon adaptive control, **Proceedings of the 9th IFAC World Congress**, 7:133-138, Budapeste, Hungary, 1984.

ZIEGLER, J. B.;NICHOLS, N. B. Optimum settings for automatic controllers, ASME Transactions, (64):759-768, 1942.