

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial

DISSERTAÇÃO
apresentada à UTFPR
para obtenção do título de

MESTRE EM CIÊNCIAS

por

MARIA CRISTINA SZPAK SWIECH

**ALGORITMOS GENÉTICOS PARA SINTONIA
SIMULTÂNEA DE MÚLTIPLOS CONTROLADORES
EM PROCESSOS DE REFINO**

Banca Examinadora:

Presidente e Orientador:

Prof. Dra. LÚCIA VALÉRIA RAMOS DE ARRUDA

UTFPR-PR

Examinadores:

Prof. Dra. JUSSARA FARIAS FARDIN

UFES-ES

Prof. Dr. FLÁVIO NEVES JR.

UTFPR-PR

Prof. Dr. JOÃO ALBERTO FABRO

UNIOESTE-PR

Curitiba, outubro de 2005

MARIA CRISTINA SZPAK SWIECH

**ALGORITMOS GENÉTICOS PARA SINTONIA
SIMULTÂNEA DE MÚLTIPLOS CONTROLADORES
EM PROCESSOS DE REFINO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná, como requisito parcial para a obtenção do título de “Mestre em Ciências” –
Área de Concentração: Informática Industrial.

Orientador: Prof. Dra. Lúcia Valéria R. de Arruda

Curitiba
2005

Ficha catalográfica elaborada pela Biblioteca do CEFET-PR – Unidade Curitiba

S976a Swiech, Maria Cristina Szpak

Algoritmos genéticos para sintonia simultânea de múltiplos controladores em processos de refino / Maria Cristina Szpak Swiech. – Curitiba : CEFET-PR, 2005.

xxi, 1499 f. : il. ; 30 cm

Orientador: Prof.Dr. Lúcia Valéria Ramos de Arruda
Dissertação (Mestrado) – CEFET-PR. Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial. Curitiba, 2005.

Bibliografia: 120-125

1. Automação industrial. 2. Automação de controle. 3. Engenharia química – processos industriais. 4. Algoritmos genéticos. I. Arruda, Lúcia Valéria Ramos de, Orient. II. Centro Federal de Educação Tecnológica do Paraná. Curso de Pós-Graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD: 629.8

Este trabalho recebeu apoio financeiro da Agência Nacional do Petróleo - ANP - e da Financiadora de Estudos e Projetos - FINEP - por meio do Programa de Recursos Humanos da ANP para o Setor Petróleo e Gás - PRH-ANP/MCT (PRH10-UTFPR).

AGRADECIMENTOS

Gostaria de agradecer a todos aqueles que de alguma forma contribuíram para que este trabalho se tornasse possível.

À Prof. Dra. Lúcia Valéria Ramos de Arruda pela oportunidade e pela orientação.

Ao Prof. Dr. Flávio Neves Jr. pela atenção aos problemas de programação.

Ao Sr. Cláudio Torres pelo incentivo ao ingresso neste mestrado e por ter possibilitado que a etapa de obtenção de créditos fosse cursada.

Ao colega Elder Oroski pela importante contribuição nos estágios de programação e simulação deste trabalho.

Aos demais colegas de laboratório, que sempre demonstraram companheirismo e atenção, em especial Elaine Yassue Nagai.

À minha família, em especial aos meus pais, Albino Swiech e Ana Szpak Swiech pelo incentivo e apoio durante todo este período, e por acreditarem que eu conseguiria atingir mais este objetivo. E aos meus irmãos, Fernando César e Maria Angela, que também foram companheiros durante este tempo.

E agradeço principalmente a Luis Fernando Kerscher, que esteve presente durante todo o desenvolvimento desta dissertação, e que, com muita dedicação e trabalho, contribuiu para que os meus objetivos fossem alcançados.

SUMÁRIO

CAPÍTULO 1	1
INTRODUÇÃO	1
1.1 CARACTERIZAÇÃO DO PROBLEMA E OBJETIVO	1
1.2 VALIDAÇÃO DA METODOLOGIA	2
1.3 DESAFIOS INTRÍNSECOS.....	3
1.4 CONTRIBUIÇÕES.....	3
1.5 ORGANIZAÇÃO DA DISSERTAÇÃO.....	4
CAPÍTULO 2	5
2 REVISÃO BIBLIOGRÁFICA	5
2.1 APRESENTAÇÃO DO CONTROLADOR PID.....	5
2.2 APRESENTAÇÃO DO CONTROLADOR NEBULOSO.....	8
2.3 INTRODUÇÃO AOS ALGORITMOS GENÉTICOS.....	12
2.3.1 TERMINOLOGIAS.....	13
2.3.2 ESTRUTURA DOS ALGORITMOS GENÉTICOS	14
2.3.3 REPRESENTAÇÃO E CODIFICAÇÃO.....	14
2.3.4 GERAÇÃO DA POPULAÇÃO INICIAL	15
2.3.5 AVALIAÇÃO DO NÍVEL DE APTIDÃO.....	16
2.3.6 MÉTODOS DE SELEÇÃO.....	17
2.3.7 OPERADORES GENÉTICOS.....	20
2.3.8 CRITÉRIOS DE PARADA.....	21
2.3.9 CONFIGURAÇÃO DOS PARÂMETROS DE CONTROLE.....	21
2.4 ALGORITMOS GENÉTICOS NA ENGENHARIA DE CONTROLE	23
2.4.1 CONFIGURAÇÃO DE PARÂMETROS DO CONTROLADOR PID	23
2.4.2 APLICAÇÕES EM CONTROLE ROBUSTO.....	25
2.4.3 APLICAÇÕES EM CONTROLE ÓTIMO.....	26
2.4.4 APLICAÇÕES EM CONTROLE INTELIGENTE.....	26
2.5 CONCLUSÃO	32
CAPÍTULO 3	35
3 METODOLOGIA	35
3.1 INTRODUÇÃO	35
3.2 PRINCIPAIS PARÂMETROS DO ALGORITMO GENÉTICO.....	38
3.2.1 FUNÇÃO DE AVALIAÇÃO	39

3.2.2	<i>ELITISMO E MÉTODO DE SELEÇÃO</i>	41
3.2.3	<i>CRITÉRIO DE PARADA</i>	43
3.3	SINTONIA DE CONTROLADORES PID	44
3.3.1	<i>REPRESENTAÇÃO CROMOSSÔMICA</i>	44
3.3.2	<i>OPERAÇÕES DE MUTAÇÃO E DE RECOMBINAÇÃO</i>	45
3.4	SINTONIA DE CONTROLADORES NEBULOSOS	46
3.4.1	<i>REPRESENTAÇÃO CROMOSSÔMICA DA BASE DE REGRAS</i>	46
3.4.2	<i>REPRESENTAÇÃO CROMOSSÔMICA DAS FUNÇÕES DE PERTINÊNCIA</i>	50
3.4.3	<i>OPERAÇÕES DE MUTAÇÃO E DE RECOMBINAÇÃO</i>	52
	CAPÍTULO 4	55
4	SIMULAÇÕES E RESULTADOS	55
4.1	INTRODUÇÃO	55
4.2	COLUNA DE DESTILAÇÃO WOOD-BERRY	57
4.2.1	<i>PROCESSO DE SINTONIA</i>	57
4.2.2	<i>CONFIGURAÇÕES DO AG</i>	58
4.2.3	<i>RESULTADOS OBTIDOS CONTROLE PI</i>	58
4.2.4	<i>RESULTADOS OBTIDOS CONTROLE PID</i>	60
4.2.5	<i>CONCLUSÃO</i>	63
4.3	COLUNA DE DESTILAÇÃO DE ISOPROPANOL.....	64
4.3.1	<i>ANÁLISE PRELIMINAR</i>	65
4.3.2	<i>PROCESSO DE CONSTRUÇÃO DAS BASES DE REGRAS</i>	70
4.3.3	<i>PROCESSO DE SINTONIA DAS FUNÇÕES DE PERTINÊNCIA</i>	77
4.3.4	<i>CONCLUSÃO</i>	83
4.4	PROCESSO DE CRAQUEAMENTO CATALÍTICO EM LEITO FLUIDIZADO.....	86
4.4.1	<i>ANÁLISE PRELIMINAR</i>	87
4.4.2	<i>PROCESSO DE SINTONIA CONTROLE NEBULOSO + PI</i>	91
4.4.3	<i>PROCESSO DE SINTONIA CONTROLE PI</i>	105
4.4.4	<i>CONCLUSÕES</i>	115
	CAPÍTULO 5	117
5	CONCLUSÃO	117
5.1	COMENTÁRIOS FINAIS	117
5.2	CONTRIBUIÇÕES.....	118
5.3	TRABALHOS FUTUROS.....	119
	REFERÊNCIAS BIBLIOGRÁFICAS	121
	ANEXO 1	127

LISTA DE FIGURAS

FIGURA 2.1- ARQUITETURA GERAL DE UM CONTROLE NEBULOSO.....	9
FIGURA 3.1- ARQUITETURA DE CONTROLE DESACOPLADO.....	35
FIGURA 3.2- CONSTRUÇÃO DAS CASTAS	42
FIGURA 3.3- ROTINA DA REPRESENTAÇÃO CROMOSSÔMICA DA BASE DE REGRAS.	49
FIGURA 3.4- REPRESENTAÇÃO DE UMA FUNÇÃO DO TIPO PSEUDO-TRAPEZOIDAL.....	51
FIGURA 3.5- CODIFICAÇÃO DAS FUNÇÕES DE PERTINÊNCIA.	51
FIGURA 4.1- ARQUITETURA DE CONTROLE, COLUNA DE DESTILAÇÃO WOOD BERRY.....	58
FIGURA 4.2- RESPOSTA OBTIDA Y1, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.	59
FIGURA 4.3- RESPOSTA OBTIDA Y2, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.	59
FIGURA 4.4- RESPOSTA OBTIDA Y1, CONTROLE PI SINTONIZADO PELO MÉTODO BLT.....	60
FIGURA 4.5- RESPOSTA OBTIDA Y2, CONTROLE PI SINTONIZADO PELO MÉTODO BLT.....	60
FIGURA 4.6- RESPOSTA OBTIDA Y1, CONTROLE PID SINTONIZADO POR ALGORITMOS GENÉTICOS.	61
FIGURA 4.7- RESPOSTA OBTIDA Y2, CONTROLE PID SINTONIZADO POR ALGORITMOS GENÉTICOS.	61
FIGURA 4.8- ALTERAÇÕES NOS VALORES DE REFERÊNCIA, SAÍDA Y1.	62
FIGURA 4.9- ALTERAÇÕES NOS VALORES DE REFERÊNCIA, SAÍDA Y2.	62
FIGURA 4.10- PERTURBAÇÕES TIPO SEQÜÊNCIA DE DEGRAUS INSERIDAS NA SAÍDA Y1 DO PROCESSO.....	62
FIGURA 4.11- RESPOSTA OBTIDA Y1 COM PERTURBAÇÃO INSERIDA NA SAÍDA Y1.....	62
FIGURA 4.12- RESPOSTA OBTIDA Y2 COM PERTURBAÇÃO INSERIDA NA SAÍDA Y1.....	62
FIGURA 4.13- RESPOSTA OBTIDA Y1 COM RÚIDO INSERIDO NA SAÍDA Y1.	62
FIGURA 4.14- RESPOSTA OBTIDA Y2 COM RÚIDO INSERIDO NA SAÍDA Y1.	63
FIGURA 4.15- ARQUITETURA DE CONTROLE, COLUNA DE DESTILAÇÃO ISOPROPANOL.	65
FIGURA 4.16- SUPERFÍCIE DE CONTROLE GERADA PELA BASE DE REGRAS PARA CONTROLADORES PD-NEBULOSOS.	66
FIGURA 4.17- VARIÁVEL LINGÜÍSTICA <i>ERRO</i> , CONTROLADOR 1.....	67
FIGURA 4.18- VARIÁVEL LINGÜÍSTICA <i>VARIACÃO DO ERRO</i> , CONTROLADOR 1.	67
FIGURA 4.19- VARIÁVEL LINGÜÍSTICA <i>SINAL DE CONTROLE</i> , CONTROLADOR 1.	67
FIGURA 4.20- VARIÁVEL LINGÜÍSTICA <i>ERRO</i> , CONTROLADOR 2.....	67
FIGURA 4.21- VARIÁVEL LINGÜÍSTICA <i>VARIACÃO DO ERRO</i> , CONTROLADOR 2.	67
FIGURA 4.22- VARIÁVEL LINGÜÍSTICA <i>SINAL DE CONTROLE</i> , CONTROLADOR 2.	67
FIGURA 4.23- RESPOSTA OBTIDA Y1 PARA OS PONTOS FINAIS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS PARA CONTROLADOR PD-NEBULOSO.	68
FIGURA 4.24- RESPOSTA OBTIDA Y2 PARA OS PONTOS FINAIS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS PARA CONTROLADOR PD-NEBULOSO.	69
FIGURA 4.25- RESPOSTA OBTIDA Y1 PARA OS PONTOS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS PARA CONTROLADOR PD-NEBULOSO.	69

FIGURA 4.26- RESPOSTA OBTIDA Y2 PARA OS PONTOS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS PARA CONTROLADOR PD-NEBULOSO.	69
FIGURA 4.27- SUPERFÍCIE DE CONTROLE GERADA PELA BASE DE REGRAS OBTIDA PARA O CONTROLADOR 1.	72
FIGURA 4.28- SUPERFÍCIE DE CONTROLE GERADA PELA BASE DE REGRAS OBTIDA PARA O CONTROLADOR 2.	72
FIGURA 4.29- RESPOSTA OBTIDA Y1 PARA OS PONTOS FINAIS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS CONSTRUÍDA POR ALGORITMOS GENÉTICOS.	73
FIGURA 4.30- RESPOSTA OBTIDA Y2 PARA OS PONTOS FINAIS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS CONSTRUÍDA POR ALGORITMOS GENÉTICOS.	74
FIGURA 4.31- RESPOSTA OBTIDA Y1 PARA OS PONTOS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS CONSTRUÍDA POR ALGORITMOS GENÉTICOS.	74
FIGURA 4.32- RESPOSTA OBTIDA Y2 PARA OS PONTOS DE OPERAÇÃO DO SISTEMA, BASE DE REGRAS CONSTRUÍDA POR ALGORITMOS GENÉTICOS.	74
FIGURA 4.33- PERTURBAÇÕES TIPO SEQÜÊNCIA DE DEGRAUS INSERIDAS NA SAÍDA Y1 DO PROCESSO.	75
FIGURA 4.34- RESPOSTA OBTIDA Y1 COM PERTURBAÇÃO INSERIDA NA SAÍDA Y1.	75
FIGURA 4.35- RESPOSTA OBTIDA Y2 COM PERTURBAÇÃO INSERIDA NA SAÍDA Y1.	76
FIGURA 4.36- RESPOSTA OBTIDA Y1 COM RUÍDO INSERIDO NA SAÍDA Y1.	76
FIGURA 4.37- RESPOSTA OBTIDA Y2 COM RUÍDO INSERIDO NA SAÍDA Y1.	76
FIGURA 4.38- VARIÁVEL LINGÜÍSTICA <i>ERRO</i> , CONTROLADOR 1.	78
FIGURA 4.39- VARIÁVEL LINGÜÍSTICA <i>VARIAÇÃO DO ERRO</i> , CONTROLADOR 1.	78
FIGURA 4.40- VARIÁVEL LINGÜÍSTICA <i>SINAL DE CONTROLE</i> , CONTROLADOR 1.	78
FIGURA 4.41- VARIÁVEL LINGÜÍSTICA <i>ERRO</i> , CONTROLADOR 2.	78
FIGURA 4.42- VARIÁVEL LINGÜÍSTICA <i>VARIAÇÃO DO ERRO</i> , CONTROLADOR 2.	78
FIGURA 4.43- VARIÁVEL LINGÜÍSTICA <i>SINAL DE CONTROLE</i> , CONTROLADOR 2.	78
FIGURA 4.44- SUPERFÍCIE DE CONTROLE GERADA PELA BASE DE REGRAS DO CONTROLADOR 1.	79
FIGURA 4.45- SUPERFÍCIE DE CONTROLE GERADA PELA BASE DE REGRAS DO CONTROLADOR 2.	79
FIGURA 4.46- RESPOSTA OBTIDA Y1 PARA OS PONTOS FINAIS DE OPERAÇÃO DO SISTEMA, FUNÇÕES DE PERTINÊNCIA AJUSTADAS POR ALGORITMOS GENÉTICOS.	80
FIGURA 4.47- RESPOSTA OBTIDA Y2 PARA OS PONTOS FINAIS DE OPERAÇÃO DO SISTEMA, FUNÇÕES DE PERTINÊNCIA AJUSTADAS POR ALGORITMOS GENÉTICOS.	81
FIGURA 4.48- RESPOSTA OBTIDA Y1 PARA OS PONTOS DE OPERAÇÃO DO SISTEMA, FUNÇÕES DE PERTINÊNCIA AJUSTADAS POR ALGORITMOS GENÉTICOS.	81
FIGURA 4.49- RESPOSTA OBTIDA Y2 PARA OS PONTOS DE OPERAÇÃO DO SISTEMA, FUNÇÕES DE PERTINÊNCIA AJUSTADAS POR ALGORITMOS GENÉTICOS.	81
FIGURA 4.50- RESPOSTA OBTIDA Y1 COM PERTURBAÇÃO INSERIDA NA SAÍDA Y1.	82
FIGURA 4.51- RESPOSTA OBTIDA Y2 COM PERTURBAÇÃO INSERIDA NA SAÍDA Y1.	82
FIGURA 4.52- RESPOSTA OBTIDA Y1 COM RUÍDO INSERIDO NA SAÍDA Y1.	83
FIGURA 4.53- RESPOSTA OBTIDA Y2 COM RUÍDO INSERIDO NA SAÍDA Y1.	83
FIGURA 4.54- ARQUITETURA DE CONTROLE DMC + PI.	87
FIGURA 4.55- VARIÁVEL CONTROLADA TRX, CONTROLE DMC.	88

FIGURA 4.56- VARIÁVEL CONTROLADA TRG2 CONTROLE DMC.	88
FIGURA 4.57- VARIÁVEL CONTROLADA HRA, CONTROLE PI SINTONIZADO POR TÉCNICAS TRADICIONAIS.	88
FIGURA 4.58- VARIÁVEL CONTROLADA DPR, CONTROLE PI SINTONIZADO POR TÉCNICAS TRADICIONAIS.	88
FIGURA 4.59- VARIÁVEL CONTROLADA PsUC, CONTROLE PI SINTONIZADO POR TÉCNICAS TRADICIONAIS.	89
FIGURA 4.60- VARIÁVEL MANIPULADA ATCV.....	89
FIGURA 4.61- VARIÁVEL MANIPULADA RAI.....	89
FIGURA 4.62- VARIÁVEL MANIPULADA LCV.....	89
FIGURA 4.63- VARIÁVEL MANIPULADA PdCV.....	89
FIGURA 4.64- VARIÁVEL MANIPULADA PCV.....	90
FIGURA 4.65- ARQUITETURA DE CONTROLE NEBULOSO + PI.....	91
FIGURA 4.66- VARIÁVEL LINGÜÍSTICA <i>ERRO</i> , CONTROLADOR 1.....	92
FIGURA 4.67- VARIÁVEL LINGÜÍSTICA <i>VARIAÇÃO DO ERRO</i> , CONTROLADOR 1.....	92
FIGURA 4.68- VARIÁVEL LINGÜÍSTICA <i>INCREMENTO DO ATUADOR</i> , CONTROLADOR 1.....	92
FIGURA 4.69- VARIÁVEL LINGÜÍSTICA <i>ERRO</i> , CONTROLADOR 2.....	92
FIGURA 4.70- VARIÁVEL LINGÜÍSTICA <i>VARIAÇÃO DO ERRO</i> , CONTROLADOR 2.....	93
FIGURA 4.71- VARIÁVEL LINGÜÍSTICA <i>INCREMENTO DO ATUADOR</i> , CONTROLADOR 2.....	93
FIGURA 4.72- SUPERFÍCIE DE CONTROLE GERADA PELA BASE DE REGRAS OBTIDA PARA O CONTROLADOR 1.....	95
FIGURA 4.73- SUPERFÍCIE DE CONTROLE GERADA PELA BASE DE REGRAS OBTIDA PARA O CONTROLADOR 2.....	95
FIGURA 4.74- VARIÁVEL CONTROLADA TRX, CONTROLE NEBULOSO SINTONIZADO POR ALGORITMOS GENÉTICOS.....	96
FIGURA 4.75- VARIÁVEL CONTROLADA TRG2, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.....	96
FIGURA 4.76- VARIÁVEL CONTROLADA HRA, CONTROLE NEBULOSO SINTONIZADO POR ALGORITMOS GENÉTICOS.....	97
.....	97
FIGURA 4.77- VARIÁVEL CONTROLADA DPR, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.....	97
FIGURA 4.78- VARIÁVEL CONTROLADA PsUC, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.....	97
FIGURA 4.79- VARIÁVEL MANIPULADA ATCV.....	98
FIGURA 4.80- VARIÁVEL MANIPULADA RAI.....	98
FIGURA 4.81- VARIÁVEL MANIPULADA LCV.....	98
FIGURA 4.82- VARIÁVEL MANIPULADA PdCV.....	98
FIGURA 4.83- VARIÁVEL MANIPULADA PCV.....	98
FIGURA 4.84- PERTURBAÇÃO: DEGRAUS NA VAZÃO DE CARGA.....	99
FIGURA 4.85- VARIÁVEL CONTROLADA TRX, PERTURBAÇÃO NA VAZÃO DE CARGA.....	100
FIGURA 4.86- VARIÁVEL CONTROLADA TRG2, PERTURBAÇÃO NA VAZÃO DE CARGA.....	100
FIGURA 4.87- VARIÁVEL CONTROLADA HRA, PERTURBAÇÃO NA VAZÃO DE CARGA.....	100
FIGURA 4.88- VARIÁVEL CONTROLADA DPR, PERTURBAÇÃO NA VAZÃO DE CARGA.....	100
FIGURA 4.89- VARIÁVEL CONTROLADA PCV, PERTURBAÇÃO NA VAZÃO DE CARGA.....	100
FIGURA 4.90- VARIÁVEL MANIPULADA ATCV, PERTURBAÇÃO NA VAZÃO DE CARGA.....	101
FIGURA 4.91- VARIÁVEL MANIPULADA RAI, PERTURBAÇÃO NA VAZÃO DE CARGA.....	101
FIGURA 4.92- VARIÁVEL MANIPULADA LCV, PERTURBAÇÃO NA VAZÃO DE CARGA.....	101
FIGURA 4.93- VARIÁVEL MANIPULADA PdCV, PERTURBAÇÃO NA VAZÃO DE CARGA.....	101

FIGURA 4.94- VARIÁVEL MANIPULADA PCV, PERTURBAÇÃO NA VAZÃO DE CARGA.	101
FIGURA 4.95- VARIÁVEL CONTROLADA TRX, RUÍDO INSERIDO NA VARIÁVEL TRX.	102
FIGURA 4.96- VARIÁVEL CONTROLADA TRG2, RUÍDO INSERIDO NA VARIÁVEL TRX.	102
FIGURA 4.97- VARIÁVEL CONTROLADA HRA, RUÍDO INSERIDO NA VARIÁVEL TRX.	103
FIGURA 4.98- VARIÁVEL CONTROLADA DPR, RUÍDO INSERIDO NA VARIÁVEL TRX.	103
FIGURA 4.99- VARIÁVEL CONTROLADA PSUC, RUÍDO INSERIDO NA VARIÁVEL TRX.	103
FIGURA 4.100- VARIÁVEL MANIPULADA ATCV, RUÍDO INSERIDO NA VARIÁVEL TRX.	104
FIGURA 4.101- VARIÁVEL MANIPULADA RAI, RUÍDO INSERIDO NA VARIÁVEL TRX.	104
FIGURA 4.102- VARIÁVEL MANIPULADA LCV, RUÍDO INSERIDO NA VARIÁVEL TRX.	104
FIGURA 4.103- VARIÁVEL MANIPULADA PdCV, RUÍDO INSERIDO NA VARIÁVEL TRX.	104
FIGURA 4.104- VARIÁVEL MANIPULADA PCV, RUÍDO INSERIDO NA VARIÁVEL TRX.	104
FIGURA 4.105- ARQUITETURA DE CONTROLE PI, PROCESSO FCC.	105
FIGURA 4.106- VARIÁVEL CONTROLADA TRX, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.	107
FIGURA 4.107- VARIÁVEL CONTROLADA TRG2, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.	107
FIGURA 4.108- VARIÁVEL CONTROLADA HRA, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.	107
FIGURA 4.109- VARIÁVEL CONTROLADA DPR, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.	107
FIGURA 4.110- VARIÁVEL CONTROLADA PSUC, CONTROLE PI SINTONIZADO POR ALGORITMOS GENÉTICOS.	107
FIGURA 4.111- VARIÁVEL MANIPULADA ATCV.	108
FIGURA 4.112- VARIÁVEL MANIPULADA RAI.	108
FIGURA 4.113- VARIÁVEL MANIPULADA LCV.	108
FIGURA 4.114- VARIÁVEL MANIPULADA PdCV.	108
FIGURA 4.115- VARIÁVEL MANIPULADA PCV.	108
FIGURA 4.116- VARIÁVEL CONTROLADA TRX, PERTURBAÇÃO NA VAZÃO DE CARGA.	109
FIGURA 4.117- VARIÁVEL CONTROLADA TRG2, PERTURBAÇÃO NA VAZÃO DE CARGA.	109
FIGURA 4.118- VARIÁVEL CONTROLADA HRA, PERTURBAÇÃO NA VAZÃO DE CARGA.	110
FIGURA 4.119- VARIÁVEL CONTROLADA DPR, PERTURBAÇÃO NA VAZÃO DE CARGA.	110
FIGURA 4.120- VARIÁVEL CONTROLADA PSUC, PERTURBAÇÃO NA VAZÃO DE CARGA.	110
FIGURA 4.121- VARIÁVEL MANIPULADA ATCV, PERTURBAÇÃO NA VAZÃO DE CARGA.	111
FIGURA 4.122- VARIÁVEL MANIPULADA RAI, PERTURBAÇÃO NA VAZÃO DE CARGA.	111
FIGURA 4.123- VARIÁVEL MANIPULADA LCV, PERTURBAÇÃO NA VAZÃO DE CARGA.	111
FIGURA 4.124- VARIÁVEL MANIPULADA PdCV, PERTURBAÇÃO NA VAZÃO DE CARGA.	111
FIGURA 4.125- VARIÁVEL MANIPULADA PCV, PERTURBAÇÃO NA VAZÃO DE CARGA.	111
FIGURA 4.126- VARIÁVEL CONTROLADA TRX, RUÍDO INSERIDO NA VARIÁVEL TRX.	112
FIGURA 4.127- VARIÁVEL CONTROLADA TRG2, RUÍDO INSERIDO NA VARIÁVEL TRX.	112
FIGURA 4.128- VARIÁVEL CONTROLADA HRA, RUÍDO INSERIDO NA VARIÁVEL TRX.	113
FIGURA 4.129- VARIÁVEL CONTROLADA DPR, RUÍDO INSERIDO NA VARIÁVEL TRX.	113
FIGURA 4.130- VARIÁVEL CONTROLADA PSUC, RUÍDO INSERIDO NA VARIÁVEL TRX.	113
FIGURA 4.131- VARIÁVEL MANIPULADA ATCV, RUÍDO INSERIDO NA VARIÁVEL TRX.	114
FIGURA 4.132- VARIÁVEL MANIPULADA RAI, RUÍDO INSERIDO NA VARIÁVEL TRX.	114

FIGURA 4.133- VARIÁVEL MANIPULADA LCV, RUÍDO INSERIDO NA VARIÁVEL TRX.....	114
FIGURA 4.134- VARIÁVEL MANIPULADA PdCV, RUÍDO INSERIDO NA VARIÁVEL TRX.	114
FIGURA 4.135- VARIÁVEL MANIPULADA PCV, RUÍDO INSERIDO NA VARIÁVEL TRX.....	114

LISTA DE TABELAS

TABELA 3.1- DISTRIBUIÇÃO DAS CASTAS.....	42
TABELA 3.2- BASE DE REGRAS PARA CONTROLADOR PD-NEBULOSO.....	47
TABELA 3.3- – SIMETRIA DA BASE DE REGRAS PARA CONTROLADOR PD-NEBULOSO.....	48
TABELA 4.1- BASE DE REGRAS OBTIDA PARA O CONTROLADOR 1.	71
TABELA 4.2- BASE DE REGRAS OBTIDA PARA O CONTROLADOR 2.	71
TABELA 4.3- BASE DE REGRAS OBTIDA PARA O CONTROLADOR 1.	94
TABELA 4.4- BASE DE REGRAS OBTIDA PARA O CONTROLADOR 2.	94

NOMENCLATURA

ABREVIACÕES:

ABS	<i>Antilock-Brake-System</i>
AG	Algoritmo Genético
IGA	<i>Improved Genetic Algorithm</i> Algoritmos Genéticos Aperfeiçoados
BLT	<i>Biggest Log Modulus</i>
DMC	<i>Dynamic Matrix Control</i>
FCC	<i>Fluid Catalytic Cracking</i> Craqueamento Catalítico em Leito Fluidizado
IAE	<i>Integral of Absolute Value of Error</i> Integral do Módulo do Erro
ISE	<i>Integral of Error Squared</i> Integral do Erro Quadrático
ITAE	<i>Integral Time Absolute Error</i> Integral do Módulo do Erro Multiplicado pelo Tempo
ITSE	<i>Integral Time Squared Error</i> Integral do erro Quadrático Ponderado pelo Tempo
KFC	<i>Kalman Filter Controller</i>
K_d	Ganho Derivativo
K_i	Ganho Integral
K_p	Ação Proporcional
LQG	<i>Linear Quadratic Gaussian</i> Linear Quadrático Gaussiano
LQR	<i>Linear Quadratic Regulation</i> Ajuste Linear Quadrático
MIMO	<i>Multiple Input, Multiple Output</i> Múltiplas Entradas, Múltiplas Saídas
MOGA	<i>Multiple Objective Genetic Algorithm</i> Algoritmos Genéticos Multi-Objetivos

MOHGA	<i>Multi-Objective Hierarchical Genetic Algorithm</i> Algoritmos Genéticos Hierárquicos Multi-Objetivos
MSE	<i>Mean Square Error</i> Média dos Erros ao Quadrado
NG	Negativo Grande
NP	Negativo Pequeno
PD	Proporcional Derivativo
PI	Proporcional Integral
PID	Proporcional Integral Derivativo
PG	Positivo Grande
PP	Positivo Pequeno
RGA	<i>Relative Gain Array</i> Matriz de Ganho Relativo
RPE	<i>Relative Probable Error</i> Erro de previsão relativo
SISO	<i>Single Input, Single Output</i> Única Entrada, Única Saída
T_d	Tempo Derivativo
T_i	Tempo Integral
ZE	Zero

NOTAÇÕES:

$e(t)$	erro do processo
$\Delta e(t)$	variação do erro do processo
t	tempo
$u(t)$	sinal de controle
$y(t)$	saída do processo

RESUMO

Este trabalho apresenta uma metodologia de sintonia simultânea de controladores utilizados em um processo multivariável, através da utilização de algoritmos genéticos e sua aplicação em processos de refino.

Propõe-se a utilização de uma função de avaliação do algoritmo genético composta por três parcelas considerando os critérios ITSE (*Integral Time Squared Error*) e de variância mínima para os sinais de saída e de controle. A metodologia pode ser aplicada na sintonia integrada de diferentes tipos de controladores, mesmo quando inseridos em processos que apresentam forte interação entre as variáveis.

Para a validação da metodologia, foram utilizados os controladores PID (proporcional-integral-derivativo) e PD-nebuloso, aplicados sob arquitetura de controle descentralizado em três diferentes processos multivariáveis, Coluna de Destilação Wood-Berry, Coluna de Destilação de Isopropanol, e *Fluid Catalytic Cracking* (FCC) ou Processo de Craqueamento Catalítico em Leito Fluidizado.

A metodologia apresenta bons resultados, podendo ser estendida a outros tipos de controladores e processos.

ABSTRACT

This work proposes the use of genetic algorithms to tuning decoupled controllers for multivariable systems for refine process.

It is presented a new fitness function for genetic algorithm that considers both ITSE (Integral Time Squared Error) and minimum variance criteria. The proposed technique can be applied to tune different control architectures also including non-linear controllers to process presenting strong interactions among its variables.

In order to demonstrate the performance of the proposed method, it is applied to three multivariable processes Wood-Berry Distillation Column, Isopropanol Distillation Column and Fluid Catalytic Cracking (FCC), with the use of PID (proportional-integral-derivative) and PD-fuzzy decentralised controllers.

This approach shows good performance and can be extend to different kinds of controllers and processes.

CAPÍTULO 1

INTRODUÇÃO

1.1 CARACTERIZAÇÃO DO PROBLEMA E OBJETIVO

As indústrias de processo em geral são compostas por sistemas multivariáveis que podem apresentar acoplamento entre suas variáveis. Para o controle destes processos, podem ser empregados controladores multivariáveis plenos como o DMC (*Dynamic Matrix Control*) (LUYBEN, 1990) ou LQG (*Linear Quadratic Gaussian*) (PHILLIPS e NAGLE, 1990).

Porém, um sistema multivariável controlado por várias malhas de controladores independentes é mais fácil de se implementar na prática que um controle multivariável pleno (FABRO e ARRUDA, 2004), pois a matemática utilizada para o projeto e manutenção destas malhas de controle é mais simples (LUYBEN, 1990).

Apesar da implementação mais simples, o processo de ajuste dos vários controladores, utilizados nesta configuração, pode se tornar difícil e demorado em sistemas acoplados. Se, por exemplo, n controladores PI forem utilizados, haverá $2n$ parâmetros a serem sintonizados, sendo possível verificar na indústria que esta tarefa é, em muitos casos, feita através de métodos de tentativa e erro, que demandam tempo e muitas vezes são incapazes de atingir os critérios de melhor desempenho da planta (LUYBEN, 1986).

A indústria de petróleo possui processos que apresentam fortes interações entre as malhas de controle e não-linearidades. Características estas que interferem na visualização correta do comportamento de cada malha por parte do operador, gerando dificuldades na sintonia dos diversos controladores existentes no processo.

Considerando que a procura atual por uma maior eficiência nas etapas de produção tem justificado o uso de procedimentos de melhoria nos principais pontos de uma indústria, e que as técnicas de sintonia baseadas em algoritmo genético (AG) têm se mostrado eficientes em muitos destes problemas (conforme será discutido no capítulo 2), o objetivo do trabalho é o desenvolvimento de uma metodologia automática de sintonia conjunta dos diversos controladores utilizados em um processo multivariável, através da utilização de algoritmos genéticos e sua aplicação em processos de refino.

A metodologia é aplicada em processos acoplados, porém a arquitetura de controle é efetuada como se o processo fosse desacoplado, através da utilização de n controladores

monovariáveis. As malhas de controle são sintonizadas simultaneamente, como se fossem um controlador multivariável, através do emprego de algoritmos genéticos.

Desenvolve-se, assim, uma metodologia alternativa às técnicas tradicionais que é capaz de melhorar o processo de sintonia de controladores, mesmo em sistemas que apresentem fortes interações entre as variáveis, como as presentes em processos de refino.

O desenvolvimento e validação da técnica proposta são feitos através de processos simulados. A simulação é necessária devido ao grande número de testes de desempenho do sistema de controle realizado pelo algoritmo genético sobre o processo, e porque alguns destes testes podem interferir no comportamento da planta de uma maneira não segura.

A metodologia proposta é abrangente, independe do tipo de controladores utilizados, como também do número de entradas e saídas existente no processo, podendo, portanto, ser adaptada e utilizada em diferentes arquiteturas de controle, bem como em diferentes processos.

1.2 VALIDAÇÃO DA METODOLOGIA

Para a validação da metodologia, foi determinada a utilização de dois tipos de controladores, o controlador PID (proporcional-integral-derivativo) e um controlador nebuloso.

O controlador PID é um controlador muito utilizado no meio industrial (ASTRÖM e HÄGGLUND, 2001), tendo ainda forte importância, mesmo na presença de técnicas de controle mais modernas, o que justifica sua escolha.

O controle nebuloso, por ser um sistema dinâmico e não linear (SHAW e SIMÕES, 1999) é uma boa opção para o controle de processos complexos com grandes não-linearidades, que são focos deste estudo.

Estes dois tipos de controladores serão utilizados sob arquitetura de controle desacoplado em três diferentes processos multivariáveis, Coluna de Destilação Wood-Berry, Coluna de Destilação de Isopropanol, e *Fluid Catalytic Cracking* (FCC) ou Processo de Craqueamento Catalítico em Leito Fluidizado.

1.3 DESAFIOS INTRÍNSECOS

Para a concretização da proposta, existem dois desafios principais que devem ser superados.

O primeiro é a correta representação dos parâmetros de configuração dos controladores a ser utilizada pelos algoritmos genéticos, que deve ser suficiente para o correto ajuste dos controladores, e bem elaborada para não sobrecarregar a rotina de busca.

O segundo desafio é o desenvolvimento de uma função de avaliação capaz de verificar corretamente quais são os melhores conjuntos de parâmetros de sintonia, levando-se em consideração o desempenho de todos os controladores utilizados no processo.

1.4 CONTRIBUIÇÕES

A principal contribuição deste trabalho é o estabelecimento de uma metodologia capaz de sintonizar automaticamente diversos controladores utilizados em um processo multivariável. Essa proposta é possível devido à utilização de algoritmos genéticos.

A segunda contribuição apresentada neste trabalho é a utilização, pelo algoritmo genético, de uma função de avaliação que alia diferentes critérios de desempenho baseados no erro quadrático e na variância mínima dos sinais de saída e de controle (ASTRÖM E WITTENMARK, 1995). Em geral, esta função de avaliação assegura bons resultados mesmo para sistemas fortemente acoplados, pois os critérios de desempenho utilizados são universais e capazes de representar as características de resposta do processo independentemente do tipo de controle utilizado.

Este trabalho apresenta também uma pequena contribuição com relação às características de funcionamento do elitismo de indivíduos (GOLDBERG, 1989) na estrutura do algoritmo genético.

Tradicionalmente o elitismo tem somente a função de transportar pequeno número de bons indivíduos diretamente para a população seguinte, garantindo a transmissão de boas respostas para as demais gerações (GOLDBERG, 1989). Neste trabalho, utiliza-se de uma casta elitista com um número significativo de indivíduos que são imunes às operações de mutação e recombinação. O objetivo desta modificação é preservar, durante toda a evolução, os melhores indivíduos encontrados, que não correm risco de ser alterados, através da atuação dos operadores genéticos, como também de ser substituídos, no caso da convergência para

uma única solução. Desta maneira, ao final da evolução, serão disponíveis não apenas uma, mas um conjunto de soluções potenciais para o problema.

1.5 ORGANIZAÇÃO DA DISSERTAÇÃO

Neste capítulo foram apresentados as motivações, os objetivos, e as contribuições deste trabalho.

O capítulo 2 apresentará as características do controlador PID e do controlador nebuloso utilizados neste trabalho, além de uma introdução aos algoritmos genéticos, e revisão de literatura sobre a aplicação desta técnica em áreas da engenharia de controle.

No capítulo 3 será descrita a metodologia desenvolvida, e serão apresentados alguns detalhes de implementação do algoritmo genético.

No capítulo 4 serão apresentados os processos simulados para a validação da proposta, os resultados obtidos, e a discussão e avaliação dos resultados de cada simulação efetuada.

No capítulo 5 serão apresentados os comentários finais, as principais conclusões do trabalho, e algumas sugestões de trabalhos futuros.

CAPÍTULO 2

2 REVISÃO BIBLIOGRÁFICA

2.1 APRESENTAÇÃO DO CONTROLADOR PID

O algoritmo PID (proporcional-integral-derivativo) tem sido utilizado com sucesso em processos industriais desde a década de 40, e, atualmente, continua sendo empregado de maneira eficaz em uma grande faixa de aplicações, como processamento de petróleo, indústrias químicas, entre outras (MARLIN, 1995).

Este tipo de controlador é a arquitetura básica existente no controle automático. Foi a primeira solução experimentada quando o controle a realimentação foi utilizado, e hoje atinge cerca de 90% das malhas de controle industriais (ASTRÖM e HÄGGLUND, 2001).

O controle PID é utilizado em sistemas monovariáveis também conhecidos como sistemas SISO (*single input, single output*), nos quais existem apenas uma variável controlada e uma variável manipulada. Porém, freqüentemente na indústria, muitos sistemas monovariáveis são implementados simultaneamente em um processo, e o desempenho de cada sistema de controle pode ser afetado pela interação com outras malhas (MARLIN, 1995). Da mesma forma, um sistema multivariável, ou MIMO (*multiple input, multiple output*), pode ser controlado por controladores monovariáveis em cada uma de suas malhas.

O controlador PID compõe três ações de controle, proporcional, integral e derivativa, para gerar um só sinal de controle $u(t)$, genericamente dado por (OGATA, 1998):

$$u(t) = K_p e(t) + \frac{K_p}{T_i} \int_0^t e(t) dt + K_p T_d \frac{de(t)}{dt}$$

Sendo:

$u(t)$ → sinal de controle

$e(t)$ → erro atuante

K_p → ganho proporcional

T_i → tempo integral

T_d → tempo derivativo

Existem três parâmetros de sintonia no controlador PID: o ganho proporcional K_p (ação proporcional), o tempo integral T_i (ação integral) e o tempo derivativo T_d (ação derivativa).

A ação de controle proporcional, correspondente ao parâmetro K_p , é proporcional à amplitude do valor do sinal de erro do processo (referência/saída). Sua atuação melhora a precisão do sistema em malha fechada diminuindo o erro de estado estacionário. Ao se aumentar o ganho deste parâmetro, a resposta se aproxima do seu valor de referência, porém o comportamento transitório tende a apresentar maiores oscilações. Portanto, o aumento deste ganho é possível até determinado limite, pois valores excessivos podem levar o sistema à instabilidade (MARLIN, 1995) (OGATA, 1998).

A ação de controle integral, correspondente ao parâmetro T_i , é proporcional à integral do erro do processo. Sua atuação está diretamente ligada à melhoria da precisão do sistema e permite o seguimento de referência com erro de estado estacionário nulo. Entretanto, a ação integral interfere na estabilidade do sistema em malha fechada. Portanto, em geral, esta ação de controle não pode ser utilizada isoladamente, sua aplicação é feita conjuntamente com a ação proporcional (MARLIN, 1995) (OGATA, 1998).

A ação de controle derivativa, correspondente ao parâmetro T_d , é proporcional à derivada do erro do processo. Esta ação de controle atua apenas durante o período transitório, proporcionando correções na resposta do sistema durante este tempo. Sua atuação não influencia o valor final de erro de estado estacionário. Outra característica, é que a ação de controle derivativa corresponde a uma ação baseada na tendência de evolução do erro do processo, desta forma, a correção ocorre de maneira antecipada, melhorando o comportamento dinâmico do sistema. (MARLIN, 1995) (OGATA, 1998).

A função de transferência $G(s)$ de um controlador PID pode ser genericamente definida como (OGATA, 1998):

$$G(s) = K_p \left(1 + \frac{1}{T_i s} + T_d s \right)$$

Ou, como:

$$G(s) = \left(K_p + K_i \frac{1}{s} + K_d s \right)$$

Neste último formato, os parâmetros K_i e K_d são conhecidos respectivamente como ganho integral e ganho derivativo, e substituem T_i e T_d .

Este tipo de controlador não precisa necessariamente conter as três ações de controle. Existem aplicações que utilizam apenas as ações proporcional e integral (controlador PI), como outras que utilizam apenas das ações proporcional e derivativa (controlador PD).

Os parâmetros de ajuste do controlador PID devem ser sintonizados para o desempenho específico da planta na qual estão inclusos. A tarefa de sintonia implica na otimização simultânea de características de resposta, tais como sobre-sinal, tempo de acomodação, tempo de subida e erro de estado estacionário (SHAW e SIMÕES, 1999).

Para este processo de sintonia, existem diversas metodologias encontradas na literatura, como método *Ziegler-Nichols* (OGATA, 1998), método *BLT Biggest Log Modulus* (LUYBEN, 1986), método de Panagopoulos *et al.* (1998), método de Zhuang e Atherton (1993), entre outras. Porém, cada uma destas técnicas de sintonia apresenta vantagens e desvantagens, e desempenho em função das características de processo. Aström e Hägglund (2001) deixam explícita esta realidade afirmando que a técnica de sintonia mais utilizada, método de *Ziegler-Nichols*, pode proporcionar resultados com pouca robustez, portanto, insatisfatórios em muitas aplicações industriais. Isso se deve ao fato de que esta técnica se baseia em regras que utilizam informações insuficientes sobre o processo (ASTRÖM E HÄGGLUND, 2004). Apesar disto, a utilização de controladores PID sempre esteve presente no controle de processos. Nos últimos anos, porém, o interesse por metodologias eficientes de sintonia automática de controladores PID tem se tornado crescente (ASTRÖM e HÄGGLUND, 2001). Um dos motivos para isto é que técnicas de controle avançado, muito estudadas e aplicadas atualmente, requerem controladores PID bem sintonizados no nível básico de controle (ASTRÖM e HÄGGLUND, 2001). Além disto, toda a instrumentação moderna e sistemas de controle básicos do tipo PLC (*Programmable Logic Controllers*) e DCS (*Distributed Control Systems*) utilizam-se de estruturas com controladores PID (BANDYOPADHYAY *et al.*, 2001).

Isto demonstra a importância dos controladores PID no meio industrial ainda hoje, frente ao surgimento de técnicas de controle mais modernas.

Portanto, a grande utilização dos controladores PID em sua forma básica nas indústrias de processo, aliada a necessidade requerida por outras estruturas de controle atuais, justificam o estudo de técnicas de sintonia alternativas como a apresentada neste trabalho, com a utilização de algoritmos genéticos.

2.2 APRESENTAÇÃO DO CONTROLADOR NEBULOSO

Os controladores PID, apesar de possuírem uma posição importante na indústria de processo, conforme abordado anteriormente, apresentam algumas limitações.

O desempenho destes controladores é satisfatório se o processo for linear, porém, se a relação de entrada e saída apresentar não-linearidades, ajustes periódicos dos parâmetros são necessários (SHAW e SIMÕES, 1999). Portanto, no caso de processos não-lineares, ou na utilização de elementos de controle ou atuadores não-lineares na malha de realimentação, ou quando existem dificuldades na modelagem matemática do processo, os controladores PID não apresentam bom desempenho (SHAW e SIMÕES, 1999).

Controladores nebulosos têm sido mencionados na literatura como uma alternativa ao controle PID (ASTRÖM e HÄGGLUND, 2001). Muitos controladores nebulosos usados na indústria têm a mesma estrutura de controladores PI, PD ou PID, porém, com a utilização de regras e funções de pertinência, características deste tipo de sistema, é possível a inclusão de não-linearidades nas leis de controle (ASTRÖM e HÄGGLUND, 2001).

Os sistemas nebulosos, inicialmente propostos por Zadeh (1965), permitem a representação de conhecimentos incertos, contraditórios e incompletos de uma maneira matemática e lógica.

Os controladores industriais baseados em sistemas nebulosos podem ser investidos com o conhecimento experimental de operadores humanos já treinados, em substituição ao modelo matemático do processo, e proporcionar ação de controle consistente (SHAW e SIMÕES, 1999).

Controladores nebulosos são simples conceitualmente. Sua estrutura consiste basicamente em três estágios: entrada (nebulização), processamento (raciocínio nebuloso) e saída (desnebulização). A arquitetura geral de um controlador nebuloso é mostrada na Figura 2.1 (CAMPOS e SAITO, 2004).

O estágio de nebulização representa as variáveis de entrada e saída do processo, aqui denominadas variáveis lingüísticas, que geralmente são provenientes de sensores das grandezas físicas ou de dispositivos computadorizados (SHAW e SIMÕES, 1999), em termos de universo de discurso e funções de pertinência.

O universo de discurso de uma variável representa o intervalo numérico de todos os possíveis valores reais que ela pode assumir. As funções de pertinência são funções numéricas gráficas ou tabuladas que atribuem valores de pertinência dentro do universo de discurso de cada variável (SHAW e SIMÕES, 1999).

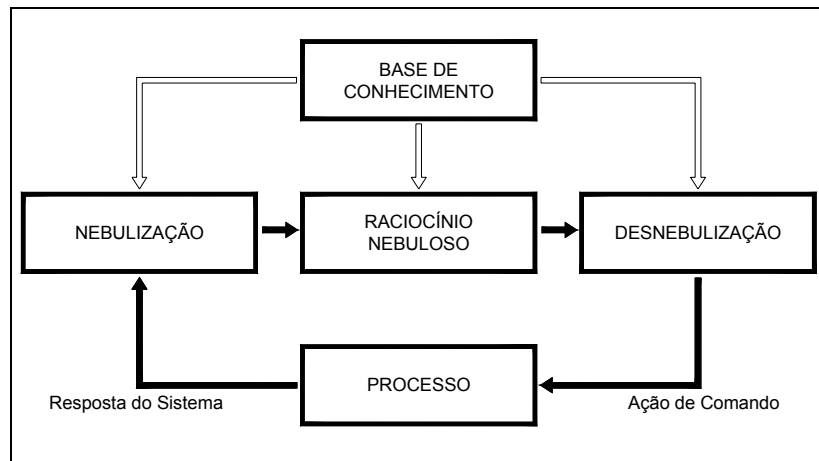


Figura 2.1- Arquitetura geral de um controle nebuloso.

A seleção do número de funções de pertinência é uma etapa importante no projeto do controlador. Um número grande de funções de pertinência possibilita um ajuste mais fino do controle, porém pode sobrecarregar o sistema, pois implica em um número maior de regras a serem definidas e executadas. Na prática, controladores nebulosos são projetados para utilizar entre 3 e 12 funções de pertinência (CAMPOS e SAITO, 2004).

As funções de pertinência das variáveis do processo representam basicamente os dados de entrada e saída do controlador nebuloso.

A base de conhecimento, ou base de regras, possui as informações a respeito dos valores lingüísticos das funções de pertinência de todas as variáveis do sistema e caracteriza os objetivos e a estratégia de controle a ser tomada, por meio de um conjunto de regras em geral lingüísticas (SHAW e SIMÕES, 1999).

O raciocínio nebuloso gera ações de controle – conseqüentes – obtidas a partir de um conjunto de condições de entrada – antecedentes (SHAW e SIMÕES, 1999). Assim, a base de regras deve possuir uma previsão de resposta para cada estado possível de operação do processo, ou seja, as regras de controle devem cobrir todo o universo de domínio das variáveis de entrada. Porém, não existe um método para a determinação do número mínimo de regras necessárias ao controle do processo, a solução depende do desempenho desejado, do número de valores lingüísticos escolhido e outros aspectos qualitativos do processo a ser controlado (CAMPOS e SAITO, 2004).

Desta forma, a base de regras fornece os parâmetros utilizados no estágio de raciocínio nebuloso, e pode ser considerada como o cérebro do controlador. A aquisição dos conhecimentos necessários à elaboração desta base é a parte mais importante, demorada e crítica durante o desenvolvimento de um controlador nebuloso (CAMPOS e SAITO, 2004).

A partir das variáveis lingüísticas de saída, e dos seus respectivos graus de pertinência, o estágio de desnebulização do controlador nebuloso calcula uma ação de controle precisa a ser aplicada no processo (CAMPOS e SAITO, 2004).

Este tipo de controlador nebuloso tem algumas vantagens práticas, entre as quais pode-se verificar (SHAW e SIMÕES, 1999):

- As regras de controle nebuloso são, em muitos casos, de fácil compreensão pelos operadores do processo.
- Todas as funções de controle associadas com uma regra podem ser testadas individualmente, aumentando assim a facilidade de manutenção.
- Sistemas nebulosos podem controlar processos complexos a partir da utilização de expressões simples.
- Controladores nebulosos são inerentemente confiáveis e robustos.

Os parâmetros principais de projeto do controlador nebuloso são: o universo de discurso das variáveis lingüísticas, o formato e a disposição das funções de pertinência sobre o universo de discurso, e a base de regras. Estes parâmetros podem ser determinados de forma heurística (LAZO *et al.*, 1999) ou a partir de técnicas de ajuste automático como as que utilizam algoritmos genéticos.

Os algoritmos genéticos têm sido aplicados para o ajuste das funções de pertinência e para a obtenção da base de regras utilizada em sistemas nebulosos. Existem três abordagens

diferentes de ajuste destas estruturas para o projeto de controladores nebulosos (FABRO, 2003).

A primeira abordagem aplica o algoritmo genético para evoluir as funções de pertinência das variáveis lingüísticas dentro do universo de discurso utilizado, com base de regras pré-determinada e fixa (ARSLAN e KAYA, 2001) (FABRO e ARRUDA, 2004).

A segunda abordagem propõe a evolução da base de regras do controlador nebuloso com funções de pertinência igualmente distribuídas no universo de discurso de cada uma das variáveis envolvidas na construção do controlador (GÜROCAK, 1999) (PAL e PAL, 2003).

A terceira metodologia sintoniza de forma paralela as duas estruturas, procurando as melhores características das funções de pertinência e a base de regras utilizada pelo controlador (HOMAIFAR e MCCORMICK, 1995) (ARRUDA e NAGAI, 2002) (RIVAS *et al.*, 2003).

Controladores nebulosos podem ser estruturados para fornecer ações de controle próximas às fornecidas por controladores PID. Tais controladores são conhecidos como PID-nebuloso.

As variáveis lingüísticas de entrada de um controlador PID-nebuloso são geralmente o erro (e), que é o desvio entre a saída do processo e seu valor de referência, a derivada no tempo deste sinal de erro (de/dt) e sua integral ($\int e.dt$) (CAMPOS e SAITO, 2004). A variável lingüística de saída é simplesmente o sinal de controle do processo.

Outras composições, como controlador PD-nebuloso (HARRIS *et al.*, 1993) e PI-nebuloso (SHAW e SIMÕES, 1999), também podem ser utilizadas.

Os controladores PID-nebulosos, por possuírem uma lei de controle não-linear, têm a capacidade de tratar e resolver uma classe maior de problemas quando comparados ao PID clássico, porém, apresentam como desvantagem o maior número de parâmetros a ser ajustados e conseqüente tempo gasto no projeto (CAMPOS e SAITO, 2004).

Existem cinco tipos de implementações para o controlador PID-nebuloso, a escolha de uma delas é dependente da forma de se implementar a ação integral, uma vez que este tipo de ação é facilmente reproduzida em lógica nebulosa (HARRIS *et al.*, 1993).

Resumidamente, o controlador PID clássico é um algoritmo simples e robusto para muitas aplicações, e possui apenas três parâmetros de sintonia. O algoritmo nebuloso é mais complexo e possui um número maior de parâmetros a serem ajustados (universos de discurso das variáveis com suas respectivas funções de pertinência, e a base de regras). A definição de

utilização de um ou outro tipo de controlador depende, entre outras, das características de não-linearidades existentes no processo a ser controlado.

Portanto, a metodologia de ajuste através da utilização de algoritmos genéticos, apresentada neste trabalho, será aplicada a estes dois tipos de controladores, PID clássico e PD-nebuloso, por possuírem uma posição importante de aplicação em processos industriais.

O presente trabalho contempla a sintonia de controladores PI e PID a partir da busca dos melhores valores de ganho para seus parâmetros, e a sintonia de controladores PD-nebulosos, a partir da evolução das funções de pertinência das variáveis lingüísticas de entrada e saída, e através da evolução das bases de regras utilizadas, de forma simultânea em processos multivariáveis.

2.3 INTRODUÇÃO AOS ALGORITMOS GENÉTICOS

Os Algoritmos Genéticos foram introduzidos por Holland (1975) e tratam-se de algoritmos de busca baseados no mecanismo de evolução natural das espécies, teorizado por Darwin (1859) (COELHO e COELHO, 1999).

Uma das principais aplicações dos algoritmos genéticos é a utilização em problemas de otimização combinatória, nos quais existe um conjunto de elementos e deseja-se encontrar aquele que melhor se adapte a condições previamente especificadas (GOLDBERG, 1989).

Muitos problemas de engenharia podem ser modelados como problemas de otimização combinatória e sua resolução obtida através de métodos algébricos, numéricos ou heurísticos, que fazem uma busca no espaço multidimensional das variáveis do problema (LOPES, 1999). Estes métodos apresentam fraco desempenho quando a natureza do problema envolve não-linearidades, descontinuidades ou espaços de busca grandes. Nestas situações os algoritmos genéticos apresentam utilidade e robustez (LOPES, 1999).

Os algoritmos genéticos diferem dos procedimentos de busca tradicionais principalmente por não trabalharem com apenas um ponto, mas com um conjunto destes, e por utilizarem a função de otimização isoladamente, sem a necessidade de derivadas ou outros cálculos auxiliares (GOLDBERG, 1989).

Os algoritmos genéticos avaliam um conjunto de soluções e, posteriormente, combinam mecanismos de valorização das soluções mais adaptadas ao objetivo em questão,

com estruturas de combinação e reprodução. Assim, um novo conjunto de soluções é criado utilizando-se informações das soluções avaliadas anteriormente.

Variações aleatórias são combinadas com seleção polarizada pelos valores de adequação atribuídos a cada solução, desta forma, o algoritmo genético não é considerado uma busca puramente aleatória, pois explora eficientemente a informação histórica para encontrar novas soluções capazes de melhorar a resposta ao critério de desempenho estipulado (CAMPOS e SAITO, 2004).

A literatura de engenharia de controle apresenta aplicações do algoritmo genético em uma extensa faixa de configurações. São encontradas aplicações em controle clássico e moderno, controle ótimo, controle adaptativo, controle robusto e sistemas de identificação (WANG *et al.*, 2003).

2.3.1 TERMINOLOGIAS

Como os algoritmos genéticos trabalham analogamente aos mecanismos biológicos de seleção natural e princípios da genética, algumas terminologias destas áreas foram adotadas e são freqüentemente encontradas na literatura (MICHALEWICZ, 1996) (GOLDBERG, 1989):

Cromossomo ou indivíduo: vetores de caracteres (genes) que representam as variáveis do problema. Cada cromossomo representa uma possível solução para o problema.

Gene: é a unidade básica do cromossomo, o caractere que descreve uma determinada variável do problema.

Alelo: determina as possíveis variações de um gene.

População: conjunto de cromossomos, inserido no espaço de busca do problema.

Geração: número da iteração que o algoritmo genético executa.

Operadores Genéticos: operações que o algoritmo genético realiza sobre os cromossomos com o objetivo de explorar o espaço de busca.

Função de Avaliação: é a função que se quer otimizar. Representa as características do problema e é usada para avaliar o nível de aptidão dos cromossomos.

Nível de Aptidão: representa a proximidade entre determinado cromossomo e a solução requerida pela função de avaliação.

Recombinação: consiste na troca (evento aleatório) de informações entre dois cromossomos.

Mutação: consiste na troca (evento aleatório) da característica de um gene (variável) em determinado cromossomo.

2.3.2 ESTRUTURA DOS ALGORITMOS GENÉTICOS

A configuração básica da rotina de um algoritmo genético pode ser estruturada da seguinte forma (MICHALEWICZ, 1996) (GOLDBERG, 1989):

- i. Gerar aleatoriamente a população inicial de parâmetros com n soluções para o problema.
- ii. Avaliar o grau de aptidão em relação ao problema de cada solução, classificando-as de acordo com este critério.
- iii. Selecionar as soluções com maior grau de aptidão aplicando-se estratégia de seleção pré-determinada.
- iv. Aplicar os operadores genéticos nas soluções selecionadas gerando uma nova população.
- v. Repetir os passos (ii) a (iv) até que um critério de parada seja satisfeito.

2.3.3 REPRESENTAÇÃO E CODIFICAÇÃO

O primeiro procedimento para a utilização dos algoritmos genéticos é a representação cromossômica dos indivíduos da população.

A representação dos indivíduos no algoritmo genético pode ser feita de muitas maneiras, dependendo do problema a ser tratado, porém basicamente existem três principais métodos de codificação (MICHALEWICZ, 1996):

- Representação por código binário: os valores numéricos reais em base decimal são transformados para a base binária. Os cromossomos então, são representados por uma cadeia de *bits*.
- Representação por código *gray*: é similar ao código binário, porém com ordenamento numérico diferente. O código *gray* se baseia na propriedade de que quaisquer pontos próximos entre si dentro do espaço do problema diferem-se somente por um *bit*,

diferentemente do código binário, no qual números subseqüentes podem possuir diferenças de mais de um *bit*.

- Representação por ponto flutuante: cada cromossomo é codificado como um vetor de números de pontos flutuantes de mesmo tamanho que o vetor solução. Cada parâmetro é forçado a se situar dentro de determinada faixa e os operadores genéticos precisam ser projetados de maneira a respeitar esta restrição.

No algoritmo proposto por Holland (1975), denominado como algoritmo genético clássico ou canônico - um dos mais utilizados e conhecidos - as soluções são codificadas em arranjos binários de tamanho fixo (GOLDBERG, 1989).

Porém, segundo Michalewicz (1996), a representação binária possui algumas desvantagens quando aplicada em problemas de grande dimensão, e quando aplicada em problemas de grande precisão. Neste último caso, o tamanho da cadeia de bits necessária para atender a precisão de vários dígitos depois do ponto decimal pode se tornar grande o suficiente para inviabilizar sua utilização.

Assim, a representação binária não é universalmente aceita na literatura (COELHO e COELHO, 1999), alguns pesquisadores indicam que a representação ponto flutuante ou real, como também é chamada, apresenta melhor desempenho para aplicações que necessitem de tratamento de valores contínuos, pois apresenta mais compatibilidade, precisão e rapidez de execução. A representação binária deve ser somente utilizada em aplicações que requeiram o tratamento de valores discretos (COELHO e COELHO, 1999).

2.3.4 GERAÇÃO DA POPULAÇÃO INICIAL

A população inicial deve ser gerada de forma a conter cromossomos suficientemente variados (GOLDBERG, 1989), para que o algoritmo tenha facilidade em percorrer todos os sentidos no espaço de busca. Para se obter esta variabilidade, a geração da população inicial é normalmente realizada de forma aleatória.

Em algumas ocasiões, nas quais existe algum conhecimento sobre a solução do problema, é interessante a inclusão de indivíduos que representem este conhecimento heurístico. Porém esta prática deve ser realizada com cuidado, pois, segundo Fabro (2003) isto pode impedir o algoritmo de obter soluções melhores que não estejam presentes na população inicial.

2.3.5 AVALIAÇÃO DO NÍVEL DE APTIDÃO

A função de avaliação tem por objetivo avaliar cada cromossomo estabelecendo um valor numérico que representa o quão distante cada um deles está da solução ideal. A função de avaliação possui como entrada uma cadeia de bits ou um vetor (o cromossomo) e como saída um valor real (o nível de aptidão).

Portanto, a função de avaliação codifica o conhecimento sobre o problema e permite quantificar cada solução comparativamente. Este é o único critério utilizado para o direcionamento da busca (FABRO, 2003).

Na literatura de engenharia de controle, é comum encontrar aplicações que utilizam uma função de avaliação que aplica um dos seguintes índices de desempenho de sistemas de controle em malha fechada, ou composição destes (CAMPOS e SAITO, 2004):

- IAE - *Integral of Absolute Value of Error*
(Integral do módulo do erro):

$$\int |e(t)| dt$$

- ISE - *Integral of Error Squared*
(Integral do erro quadrático):

$$\int e^2(t) dt$$

- ITAE - *Integral Time Absolute Error*
(Integral do módulo do erro multiplicado pelo tempo):

$$\int t|e(t)| dt$$

- ITSE - *Integral Time Squared Error*
(Integral do erro Quadrático Ponderado pelo Tempo):

$$\int t.e^2(t)dt$$

- RPE - *Relative Probable Error*
(Erro de previsão relativo):

$$\frac{\int e^2(t)dt}{\int ref^2(t)dt}$$

Nas quais, $e(t)$ é o erro de regime em malha fechada e $ref(t)$ é a referência do processo.

Estes índices de desempenho são comumente utilizados na prática e na literatura para avaliar controladores (ASTRÖM, e WITTENMARK, 1995) (HARRIS *et al.*, 1993).

2.3.6 MÉTODOS DE SELEÇÃO

O processo de seleção ocorre após a aplicação da função de avaliação e conseqüente determinação do nível de aptidão de cada cromossomo. O processo de seleção normalmente é baseado no princípio da sobrevivência dos melhores indivíduos, assim, os cromossomos com melhores níveis de aptidão possuem uma maior probabilidade de serem mantidos e selecionados para a etapa de reprodução. Da mesma forma, os cromossomos com baixos níveis de aptidão possuem pouca probabilidade de permanecer e, conseqüentemente, podem ser eliminados da população.

2.3.6.1 Seleção por Roleta

O algoritmo genético clássico utiliza um esquema de seleção de indivíduos chamado seleção por roleta (MICHALEWICZ, 1996). Neste método cada indivíduo ocupa, em uma

roleta, uma área proporcional ao seu nível de aptidão. Assim, aos indivíduos com maior aptidão é associada uma fatia maior da roleta e aos indivíduos com menor aptidão, fatias menores. Em seguida faz-se a simulação do giro da roleta n vezes, selecionando-se os n indivíduos que se manterão na etapa seguinte. Os mais aptos possuem uma probabilidade maior de serem selecionados, podendo, inclusive, serem selecionados mais de uma vez, enquanto os menos aptos, com uma probabilidade menor, podem desaparecer logo após as primeiras gerações.

O método de seleção por roleta é o método mais comumente utilizado, porém, apresenta algumas limitações. Este tipo de seleção leva o algoritmo a diminuir a diversidade da população, e isto ocasiona, em determinadas situações, a convergência prematura das soluções (FABRO, 2003).

Um outro problema é que, como este tipo de seleção trabalha com probabilidades, é possível que um indivíduo com alto nível de aptidão não seja selecionado, e uma solução interessante se perca nas primeiras gerações.

Devido a estes problemas, outros métodos de seleção foram desenvolvidos, como seleção por torneio, seleção por ordenamento, seleção bi-classista, técnica estilista (BLICKLE e THIELE, 1995) (GOLDBERG, 1989).

2.3.6.2 Seleção por Torneio

Geram-se grupos aleatórios de indivíduos. O indivíduo com o maior nível de aptidão no grupo é selecionado, enquanto que os demais são descartados.

Este método de seleção apresenta a vantagem de não acarretar a convergência prematura do algoritmo e dificultar a estagnação do processo.

2.3.6.3 Seleção por Ordenamento

O método de seleção por ordenamento enumera os indivíduos de acordo com os seus respectivos níveis de aptidão. Para a determinação da probabilidade de seleção podem ser utilizados mapeamentos lineares ou exponenciais.

Este método também não acarreta a convergência prematura do algoritmo, porém, apresenta como desvantagem o esforço computacional extra necessário para efetuar

ordenamentos constantes de toda a população.

2.3.6.4 Seleção Bi-Classista

A seleção bi-classista ordena os indivíduos da população e seleciona uma porcentagem pré-determinada de melhores indivíduos, e uma porcentagem de piores indivíduos, objetivando manter a diversidade em todas as gerações.

2.3.6.5 Técnica Elitista

Esta técnica é utilizada em conjunto com algum método de seleção, normalmente a roleta, com o objetivo de aumentar a velocidade de convergência do algoritmo e garantir que determinado número de indivíduos com bom nível de aptidão sejam repassados para a geração seguinte.

A técnica elitista envia diretamente certo número de melhores indivíduos da população corrente para a próxima geração, evitando, assim, a possível perda de boas soluções no processo de seleção.

Em muitas implementações costuma-se utilizar o elitismo de pelo menos o melhor indivíduo da população.

A desvantagem da utilização da técnica elitista é a possibilidade de forçar a busca, devido à reprodução maior deste indivíduo durante as evoluções, o que pode gerar a convergência prematura do algoritmo genético.

Mas, alternativamente a este procedimento, existe a solução de manter as cópias dos melhores indivíduos obtidos durante as evoluções isolados do corpo principal do programa, conforme sugestão apresentada neste trabalho.

Neste caso, o elitismo mantém determinado número de cópias de bons elementos dentro de uma casta isolada do programa principal, que não participam do processo de seleção e não sofrem alterações dos operadores genéticos. Além disto, dentro desta casta não existem soluções repetidas.

Assim, a casta elitista, neste trabalho, além de ser responsável pela garantia de transmissão de bons indivíduos para a população seguinte, tem a função de preservar o conjunto de melhores soluções obtidas até o encerramento da rotina.

2.3.7 OPERADORES GENÉTICOS

O processo de seleção isoladamente não cria uma nova geração, apenas seleciona os indivíduos mais aptos para fazerem parte do grupo que irá construir a próxima população.

A geração de novos indivíduos, e conseqüentemente, da nova população, é feita através da utilização de operadores genéticos. Estes operadores tentam criar novas e melhores soluções, a partir das soluções existentes (selecionadas), encaminhando a busca a pontos cada vez mais próximos do critério de desempenho.

A função dos operadores genéticos é modificar os cromossomos, através de sucessivas gerações, com o objetivo de encontrar o melhor resultado no final do processo. Os operadores diversificam a população, resguardando e tentando aprimorar as características boas dos cromossomos já encontrados.

Os operadores genéticos são controlados por parâmetros que definem a probabilidade de suas aplicações. Estes parâmetros são configurados no momento do projeto e seus ajustes influenciam o desempenho do algoritmo.

Os operadores genéticos utilizados pelo algoritmo são recombinação e mutação (MICHALEWICZ, 1996) (GOLDBERG, 1989), explanados a seguir.

2.3.7.1 Operador de Recombinação

O operador de recombinação cria novos cromossomos através da combinação de dois ou mais indivíduos selecionados aleatoriamente. O objetivo desta aplicação é a troca de informação entre diferentes soluções candidatas (MICHALEWICZ, 1996) (GOLDBERG, 1989).

Este operador pode ser utilizado de maneiras distintas, entre as quais, as mais comuns são:

- Recombinação ponto único: um ponto de cruzamento é escolhido e a partir dele as informações genéticas dos cromossomos aleatórios são trocadas.
- Recombinação multi-pontos: é uma generalização da idéia de troca de material genético, na qual muitos pontos de cruzamento podem ser utilizados.
- Recombinação uniforme: não utiliza pontos de cruzamento, mas determina através de um parâmetro global qual a probabilidade de cada variável ser herdada do cromossomo original.

Segundo Von Zuben (2000) não há nenhuma comprovação de que alguma maneira de utilização do operador de recombinação apresente um desempenho superior às demais. Apenas é possível verificar que cada maneira de se aplicar o operador é particularmente eficiente para uma determinada classe de problemas, e para outras, não.

2.3.7.2 Operador de Mutação

O operador de mutação tem como objetivo manter e propiciar a diversidade genética da população (MICHALEWICZ, 1996) (GOLDBERG, 1989).

Este operador implica na alteração aleatória de uma ou mais características de um cromossomo escolhido, propiciando assim, a introdução de novos elementos na população.

A utilização deste operador visa resgatar material genético perdido e inserir material não explorado, prevenindo desta maneira a convergência prematura do algoritmo para soluções sub-ótimas (COELHO, COELHO, 1999).

2.3.8 CRITÉRIOS DE PARADA

A finalização ideal do algoritmo genético seria a interrupção do procedimento somente no momento em que a solução global fosse encontrada. Porém, a maneira de se identificar este ponto global é desconhecida na maioria dos casos (FABRO, 2003).

Devido a isto, é necessária a estipulação de um critério de parada que pode ser feita de diversas formas, como por exemplo, a observação da convergência da população, que ocorre quando praticamente todos os indivíduos são cópias idênticas da mesma seqüência de genes (GOLDBERG, 1989).

A determinação de um número máximo de gerações, ou limitação do tempo de processamento, também podem ser utilizados.

2.3.9 CONFIGURAÇÃO DOS PARÂMETROS DE CONTROLE

Existem três importantes parâmetros de controle que influenciam o desempenho do algoritmo genético: tamanho da população, probabilidade de recombinação e probabilidade de mutação (MICHALEWICZ, 1996) (GOLDBERG, 1989). A configuração adequada destes

parâmetros é um dos passos importantes no momento do projeto, pois a eficiência do algoritmo depende disto.

Essa configuração é determinada heurísticamente. Apesar de diversas pesquisas na área, não existe uma regra determinística para o projetista estipular estes parâmetros de maneira a obter uma adequada relação quanto aos tópicos de diversidade na população e a capacidade de convergência do algoritmo (COELHO e COELHO, 1999).

Algumas técnicas adaptativas de ajuste de parâmetros vêm sendo sugeridas por pesquisadores, mas ainda nenhuma destas abordagens apresentou uma melhoria significativa no desempenho da busca (LAST e EYAL, 2005).

Mas, na literatura é possível encontrar algumas recomendações. Srinivas e Patnaik (1994) comentam que aplicações típicas de algoritmos genéticos utilizam população entre 30 e 200 indivíduos, probabilidade de recombinação entre 0.5 e 1.0, e probabilidade de mutação entre 0.001 e 0.05.

2.3.9.1 Tamanho da População

O tamanho da população é um parâmetro que deve ser definido considerando-se dois aspectos importantes (FABRO, 2003):

- Cobertura do espaço de busca da solução do problema.
- Tempo computacional.

Quanto maior a quantidade de indivíduos, maior será a diversidade genética e, portanto, maior será a probabilidade de se encontrar soluções próximas ao ótimo global. Por outro lado, quanto maior a população, maior o tempo de processamento utilizado pelo algoritmo, o que pode dificultar algumas aplicações (FABRO, 2003). Portanto, o equilíbrio entre estes dois parâmetros deve ser observado no momento do projeto.

2.3.9.2 Probabilidade de Recombinação

A probabilidade de recombinação indica com qual taxa o operador de recombinação atua sobre indivíduos selecionados na população. O aumento deste valor possibilita a introdução mais rápida de novos indivíduos nas gerações.

Valores baixos de probabilidade de recombinação podem ocasionar uma convergência muito lenta do algoritmo, e valores altos podem acarretar a retirada rápida de indivíduos com boas aptidões, gerando perdas de soluções.

2.3.9.3 Probabilidade de Mutação

A probabilidade de mutação indica com qual taxa o operador de mutação irá atuar sobre indivíduos selecionados na população. O cuidado a ser tomado é a não utilização de taxas muito altas, pois isto pode ocasionar uma busca essencialmente aleatória do algoritmo.

2.4 ALGORITMOS GENÉTICOS NA ENGENHARIA DE CONTROLE

Na engenharia de controle, os algoritmos genéticos estão sendo principalmente utilizados no projeto de diferentes tipos de controladores, com o objetivo de melhorar a sintonia de seus parâmetros.

Serão apresentadas a seguir, algumas aplicações atuais que obtiveram sucesso em suas implementações, e que exemplificam a variedade de processos e abordagens, nos quais os algoritmos genéticos podem ser empregados com grande aproveitamento.

2.4.1 CONFIGURAÇÃO DE PARÂMETROS DO CONTROLADOR PID

O'mahony *et al.* (2000) aplicaram algoritmos genéticos para o ajuste de controladores PI e PID em alguns sistemas SISO considerados de difícil sintonia. Demonstraram desta forma, que a técnica é independente do processo de modelagem do sistema, pois utiliza-se somente do sinal de erro (referência/saída), e conseqüentemente pode ser utilizada em uma grande variedade de problemas industriais. Nesta aplicação, foram utilizadas isoladamente três funções de avaliação correspondentes aos critérios de otimização ISE, IAE e ITAE, para comparação dos resultados obtidos. Os três critérios apresentaram valores de ajuste dos controladores com desempenho similar. Os resultados da sintonia demonstraram que o algoritmo genético superou as dificuldades associadas a algumas tradicionais regras de sintonia baseadas em otimização (ZHUANG e ATHERTON, 1993), produzindo resultados satisfatórios para os sistemas utilizados.

A utilização de algoritmos genéticos para a sintonia de um controlador PI aplicado a um modelo de sistema SISO não-linear é apresentada por Herrero *et al.* (2002). Em sistemas não-lineares, com técnicas tradicionais de ajuste, é necessário estabelecer zonas de operação nas quais o sistema pode ser linearizado e o ajuste é executado para cada uma delas separadamente. A metodologia utilizada por Herrero *et al.* (2002) obteve a configuração do controlador levando-se em conta todas as características do processo, através da utilização de algoritmos genéticos, que avaliaram os requisitos estabelecidos para a saída do sistema com a aplicação do índice de minimização ISE. O processo térmico utilizado apresentava não-linearidades, saturação, erros de modelagem e ruídos, e o algoritmo genético apresentou valores de sintonia com bom desempenho para o controlador PI.

Lin *et al.* (2004) apresentam um controlador PI com ajuste de ganho *on line*, através da utilização de algoritmos genéticos, para o controle de posição de um motor de indução linear em um sistema de direção auxiliar. A função de avaliação foi composta basicamente pelo erro entre o sistema e sua referência. Os resultados das simulações demonstraram bom desempenho do controlador, e robustez com relação a variações de parâmetros da planta e perturbações externas.

Uma diferente abordagem para sintonia dos parâmetros do controlador PID é apresentada por Bandyopadhyay *et al.* (2001). Um mecanismo de inferência nebuloso é usado para a predição dos valores futuros da saída do controlador PID, enquanto valores da base de regras são construídos pelos algoritmos genéticos. A função de avaliação utilizou o critério de otimização IAE. Esta metodologia foi aplicada a processos SISO de primeira e segunda ordem com tempo morto. Os resultados mostraram que esta metodologia apresenta melhor eficiência quando comparada a técnica de *Ziegler-Nichols*.

Vlachos *et al.* (2002) apresentaram uma solução para o problema de controle padrão da Shell (PRETT e MORARI, 1987) proposto por esta empresa com o objetivo de disponibilizar um teste realístico para avaliação de novas teorias de controle e tecnologias. A solução incluía dois controladores PID inseridos no processo multivariável sob arquitetura descentralizada, sintonizados automaticamente por algoritmos genéticos. A função de avaliação do algoritmo genético foi construída para verificar diretamente as características geométricas da curva de resposta das saídas. Os resultados obtidos com esta metodologia apresentaram bom desempenho.

2.4.2 APLICAÇÕES EM CONTROLE ROBUSTO

Herreros *et al.* (2002) utilizaram algoritmos genéticos para solução de problemas de otimização multiobjetivo existentes no projeto de controladores robustos H_2 e H_∞ . O projeto de um controlador robusto é um problema de equilíbrio entre objetivos conflitantes que abrangem características de perturbações, acompanhamento de referência, estabilidade frente a dinâmicas não modeladas, entre outros. Segundo o autor, metodologias gerais para a resolução deste tipo de problema não são facilmente encontradas na literatura devido à complexidade dos problemas multiobjetivos. Os resultados da utilização do algoritmo genético mostraram que sua aplicação para o projeto desta classe de problemas é uma alternativa que traz benefícios significativos.

Kitsios e Pimenides (2002) apresentam um trabalho que demonstra a discrepância existente entre a teoria de controle H_∞ e aplicações práticas, comentando desta maneira a dificuldade em implementar controle H_∞ ótimo nos problemas de engenharia reais, através das técnicas de projeto tradicionais existentes, tais como teorema de *Nehari* e resolução das equações de *Riccati*, pois estas abordagens geram um controlador de ordem superior à ordem da planta. Devido a estas observações, foi proposta a aplicação de um algoritmo genético simples para o projeto da estrutura de um controlador sub-ótimo H_∞ para o controle de uma coluna de destilação binária. A metodologia apresentada demonstrou sucesso na construção de controladores de baixa ordem, e a aplicação em uma planta de difícil tratamento comprovou a utilidade da técnica.

Em controle preditivo, os algoritmos genéticos também são utilizados. Potocnik e Grabec (2002) apresentaram uma estratégia de controle preditivo para modelos não-lineares utilizando algoritmos genéticos como otimizador. A metodologia é aplicada no controle de um processo de corte instável e não-linear. Neste caso, utilizou-se abordagem neural para modelagem do processo e os algoritmos genéticos para otimização das restrições do controle.

Blasco *et al.* (2001) apresentaram um trabalho mostrando como combinar controle preditivo e algoritmos genéticos para superar problemas em sistemas complexos como não-linearidades, restrições, interferências, entre outros. A aplicação foi feita em um controle de climatização em uma estufa, e os algoritmos genéticos foram utilizados para a procura da melhor lei de controle a ser utilizada.

2.4.3 APLICAÇÕES EM CONTROLE ÓTIMO

Robandi *et al.* (2001) aplicaram algoritmos genéticos para projetar os elementos das matrizes Q e R de um Controlador Linear Quadrático (LQR). Estas matrizes, por determinarem o desempenho de saída do sistema, são os componentes mais importantes neste tipo de controle. O controlador otimizado com algoritmos genéticos foi aplicado a um modelo de sistema de potência com múltiplos geradores. Os resultados mostraram que esta metodologia apresentou um desempenho melhor que as técnicas tradicionais utilizadas para projeto de matrizes de controladores LQR: tentativa e erro e método de *Bryson*.

Para o projeto de controle Linear Quadrático Gaussiano (LQG), os algoritmos genéticos também são usados para encontrar os melhores valores para a matriz de fatores de peso. Mei e Goodall (2000) apresentaram um desenvolvimento de controle de direção para veículos ferroviários utilizando algoritmos genéticos para ajuste fino destes fatores de peso.

2.4.4 APLICAÇÕES EM CONTROLE INTELIGENTE

Em controladores nebulosos, os algoritmos genéticos são normalmente utilizados de maneira a adequar as funções de pertinência das variáveis lingüísticas, objetivando a melhor atuação do controle, mesmo durante alterações ocorridas no funcionamento da planta. Podem ser utilizados também para a adequação ou construção da base de regras a ser utilizada pelo controlador, ou para a evolução simultânea destas duas estruturas, base de regras e funções de pertinência.

Em redes neurais artificiais os algoritmos genéticos também são utilizados. Uma das etapas de trabalho de uma rede neural é o processo de treinamento que normalmente é realizado através de algum método baseado no gradiente. Porém, tais métodos apresentam determinadas limitações em alguns casos, pois não conseguem efetuar uma busca efetivamente global. Portanto, os algoritmos genéticos vêm sendo estudados para a aplicação no aprendizado de redes neurais, com o objetivo de proporcionar uma melhor procura no espaço de busca (AZEVEDO, 1999).

Os algoritmos genéticos também estão sendo utilizados para a otimização do número de neurônios na camada intermediária da rede neural, determinando assim boas arquiteturas com múltiplas camadas para uma determinada tarefa (AZEVEDO, 1999).

É comum encontrar também aplicações de controle híbridas, que agrupam sistemas nebulosos e redes neurais artificiais, e que utilizam os algoritmos genéticos para a procura dos diferentes parâmetros de configuração destas abordagens. Algumas aplicações híbridas também utilizam o algoritmo genético para solução de problemas de controle multi-objetivo.

Medeiros *et al.* (2001) apresentaram a utilização de algoritmos genéticos para a otimização de cinco funções de pertinência triangulares de duas variáveis linguísticas de entrada de um controlador nebuloso aplicado a um simulador de controle de pressão arterial de pacientes em pós-operatório. Este é um sistema SISO, no qual a pressão arterial é monitorada e mantida dentro de uma faixa especificada através de infusão de um medicamento vaso-dilatador. A função de avaliação utilizou o critério de otimização IAE.

Afzalian e Linkens (2000) apresentaram um trabalho de ajuste das funções de pertinência gaussianas de duas entradas e da saída de um sistema nebuloso através da utilização de algoritmos genéticos. Este sistema compunha um controlador neuro-nebuloso aplicado a um estudo de caso de um sistema elétrico para extinção de oscilações de baixa frequência em um rotor de um gerador síncrono, obtendo melhoras na resposta do sistema após esta implementação. A função de avaliação também utilizou o critério de otimização IAE.

Altinten *et al.* (2003) apresentou um controlador nebuloso para sistema SISO de controle da temperatura em um reator de polimerização, empregando algoritmos genéticos para encontrar os melhores parâmetros das cinco funções de pertinência triangulares das duas entradas e da saída do controlador. Os resultados mostraram uma grande eficiência do algoritmo na melhoria do desempenho deste controle. O critério de otimização IAE foi também utilizado nesta aplicação.

Arslan e Kaya (2001) apresentaram uma metodologia de ajuste de funções de pertinência com a utilização de algoritmos genéticos que pode ser aplicada a qualquer formato geométrico destas funções. A metodologia foi aplicada a sistemas nebulosos com uma entrada e uma saída.

Chiang e Su (2004) apresentaram um controlador com plano de fase nebuloso utilizando *Improved Genetic Algorithm* (IGA), ou algoritmos genéticos aperfeiçoados, para o controle ótimo de posição e velocidade de um motor de indução. O IGA é um algoritmo genético tradicional que utiliza um operador de direção que melhora sua busca, e foi utilizado para o ajuste das funções de pertinência das variáveis de entrada e saída do controle nebuloso.

Uma comparação apresentada neste artigo mostra que o IGA realmente possui um desempenho melhor em relação ao algoritmo genético tradicional para o exemplo apresentado.

Fabro e Arruda (2004) apresentaram uma estratégia de controle baseada em modelo para sistemas multivariáveis acoplados, através do uso das três técnicas da inteligência computacional, redes neurais artificiais, sistemas nebulosos e algoritmos genéticos. A metodologia apresentada associa cada variável a ser controlada a uma rede neural preditora e a um controlador nebuloso. Os algoritmos genéticos são aplicados para a evolução das funções de pertinência das variáveis dos controladores nebulosos utilizados nesta arquitetura. A metodologia foi aplicada ao controle de um processo de fermentação alcoólica que apresentava dificuldades como não linearidades, fase não-mínima e tempo de acomodação.

Chan *et al.* (2000) apresentam o projeto de um controlador lógico nebuloso com a base de regras obtida através de algoritmos genéticos. O controlador foi aplicado a um sistema SISO de equilíbrio esfera-suporte. O controlador nebuloso foi composto por três entradas (das quais, duas com cinco atributos, e uma com três atributos) e uma saída (descrita por sete funções de pertinência). A codificação foi efetuada de forma que o algoritmo genético buscava apenas valores para metade da base de regras, que posteriormente era espelhada para completar toda a estrutura. A função de avaliação utilizou o critério de otimização ITAE. Um controlador KFC (*Kalman Filter Controller*) e um controlador nebuloso sintonizado manualmente foram utilizados para comparação de resultados, e a arquitetura que se utilizou do algoritmo genético apresentou melhor robustez.

Medeiros *et al.* (2003) utilizaram algoritmos genéticos para gerar a base de regras de um controlador nebuloso aplicado a um sistema SISO de controle para isolamento de vibrações. Nesta aplicação, o controlador nebuloso foi composto por duas entradas e uma saída com cinco funções de pertinência cada. A codificação foi efetuada para cada combinação das entradas, não sendo adotado, portanto, o espelhamento de regras. A função de avaliação utilizou o critério IAE.

Gürocak (1999) apresentou uma metodologia diferente de sintonia de controladores PD-nebulosos através da evolução de suas bases de regras. A metodologia trata a base de regras como uma função multi-objetivo e aplica algoritmos genéticos para a procura dos melhores parâmetros. A proposta foi aplicada a dois processos SISO, sistema de controle de

posição e pêndulo invertido, e a função de avaliação foi baseada no erro de regime (referência/saída) do processo.

Pal e Pal (2003) propuseram um método de geração de regras baseado em um algoritmo genético auto-organizável para controladores lógico nebulosos. A metodologia consiste de três estágios. O primeiro estágio seleciona regras requeridas para controlar o sistema em torno dos valores de referência. O segundo estágio inicia com as regras resultantes do primeiro, aumentando sua extensão de operação para todo o espaço de entrada. Então, o terceiro estágio refina a base de regras através da retirada de redundâncias, alteração de regras existentes e inclusão de novas. Esta técnica foi aplicada a dois sistemas, pêndulo invertido e caminhão com reboque, ambos sistemas SISO, através da utilização de um controlador composto por duas entradas e uma saída com sete funções de pertinência cada. A função de avaliação utilizou o critério ITAE.

Em Li e Shieh (2000) um controlador PID nebuloso otimizado por algoritmos genéticos foi estudado para eliminar o erro de um sistema SISO de fase não-mínima e melhorar a resposta transitória. O controlador utilizado empregava um controle de dois estágios composto por um controle PI, que foi utilizado para cancelar os efeitos de zeros instáveis, e por um controle PD, que foi utilizado para reduzir o sobre-sinal. A base de regras dos controladores PI e PD foi obtida por algoritmos genéticos. A codificação, para duas entradas e uma saída com cinco funções de pertinência cada, foi efetuada com a utilização de espelhamento de regras. A função de avaliação foi baseada no critério IAE.

Lee e Zak (2002) apresentaram o projeto de um controlador genético-neuro-nebuloso para o controle de um sistema de freios ABS (*Antilock-Brake-System*). O controlador consiste de um otimizador neural não-derivativo e de componentes lógicos nebulosos com base de regras sintonizada através de algoritmos genéticos.

Homaifar e McCormick (1995) apresentaram a proposta de utilização de algoritmos genéticos para a sintonia simultânea das funções de pertinência e da base de regras de controladores nebulosos. O cromossomo utilizado carrega as informações necessárias para o estabelecimento destas duas estruturas. A metodologia foi aplicada a dois sistemas SISO: *cart controller* e *truck-backing controller*. Da mesma forma, Rivas *et al.* (2003) apresentaram uma técnica similar de sintonia paralela destas estruturas que pode ser aplicada a qualquer sistema nebuloso. A função de avaliação utilizada foi baseada no critério MSE (*Mean Square Error*).

Chiou e Lan (2005) apresentaram uma abordagem diferente de sintonia simultânea das funções de pertinência e da base de regras de controladores nebulosos. Considerando que para a evolução da base de regras e das funções de pertinência simultaneamente é necessária a utilização de um cromossomo com grande número de genes, e isto pode prejudicar o desempenho da busca, Chiou e Lan (2005) empregaram algoritmos genéticos para a evolução destas duas estruturas de forma seqüencial. O algoritmo foi estruturado para trabalhar em dois diferentes níveis interativos. O nível superior procura uma solução para a composição da base de regras utilizando o ajuste das funções de pertinência obtidos no nível inferior. Seqüencialmente, o nível inferior determina as características das funções de pertinência utilizando as regras obtidas no nível superior. A metodologia foi aplicada a um modelo de controle de tráfego.

Lin (2004) introduziu um modelo de sistema de controle neural-nebuloso construído através de um algoritmo de aprendizagem híbrido que combina algoritmos genéticos e o método dos mínimos quadrados. O algoritmo genético é utilizado para a construção das funções de pertinência de entrada do sistema nebuloso e o método dos mínimos quadrados é utilizado para sintonia dos parâmetros da base de regras. A proposta foi aplicada a um controle de temperatura no qual determinados valores precisam ser alcançados rapidamente sem sobre-elevações. A metodologia foi comparada à utilização de controladores PID e controladores nebulosos tradicionais, mostrando-se mais robusta.

Kiguchi *et al.* (2002) apresentam um método eficaz de estratégia de ajuste de um controlador de força nebuloso-neural para um manipulador de robô em um ambiente desconhecido. As regras de controle de força são automaticamente ajustadas de maneira *on-line* através de redes neurais artificiais, as quais são construídas de forma *off-line* por algoritmos genéticos, de acordo com as propriedades do ambiente. A eficiência deste método foi comprovada através de um simulador específico.

Son *et al.* (2004) propuseram um modelo preditivo da força de rotação de vários processos de rolamento a quente, utilizando redes neurais artificiais. Foram utilizados algoritmos genéticos para a procura da arquitetura ótima da rede neural que minimizasse erros de predição.

Sarimveis e Bafas (2003) introduziram uma diferente técnica de controle preditivo nebuloso baseada no modelo nebuloso dinâmico do processo a ser controlado, que é usado para a predição do comportamento futuro das variáveis de saída. A técnica foi aplicada a um

problema de otimização não-linear, que foi resolvido de forma *on line* através da utilização de algoritmos genéticos. A metodologia foi aplicada a um reator químico com uma entrada e uma saída.

Chen *et al.* (2002) apresentaram uma proposta de metodologia integrada, utilizando algoritmos genéticos e redes neurais artificiais como ferramentas para auxílio do controlador lógico nebuloso. Com esta abordagem híbrida, simultaneamente são geradas as funções de estado representativas do sistema, são buscados ajustes para a estratégia de controle multi-objetivo, e as regras de controle *fuzzy* são sintonizadas. Esta técnica foi aplicada ao controle de combustão de incineradores, mostrando-se eficiente.

Chen e Chiang (2004) apresentaram uma nova abordagem para sistemas de controle inteligente com aplicação de várias técnicas agrupadas. O método consiste em quatro funções básicas: controlador, receptor, adaptador multi-objetivo e progressor. Uma rede neural-nebulosa de cinco camadas é aplicada para implementar o controlador. O receptor é usado para avaliar o desempenho do sistema. O adaptador multi-objetivo compreende dois elementos: explorador de ações e gerador de regras, e pode gerar uma diversidade de novos ajustes de ações para se adaptar em diferentes meios. Os algoritmos genéticos multi-objetivo baseados na otimização de Pareto são utilizados neste ponto para implementar a exploração das ações visando o encontro de ajustes de ações múltiplas. O gerador de regras é aplicado para transformar o ajuste de ação em regras nebulosas. O progressor utiliza a técnica de *Simulated Annealing* para realizar sua busca. Esta abordagem híbrida foi aplicada no planejamento de rota de um robô móvel, mostrando eficiência em diferentes ambientes simulados.

Wang *et al.* (2005) apresentam um novo método baseado em algoritmos genéticos hierárquicos multi-objetivos (MOHGA) para extração de conhecimento interpretável da base de regras nebulosa. Este método é uma derivação do uso de algoritmos genéticos multi-objetivos (MOGA), no qual os genes do cromossomo são arrançados em genes de controle e genes de parâmetro. Estes genes são disponibilizados uma forma hierárquica de maneira que os genes de controle podem manipular os genes de parâmetro de uma maneira mais eficaz. A eficácia desta formulação permite que o algoritmo seja utilizado para se obter modelos nebulosos otimizados. A metodologia foi aplicada em quatro exemplos: sistema dinâmico não-linear sintético, sistema estático não-linear, sistema de *Lorenz* e sistema de *Mackey*. Os

resultados das simulações mostraram que a técnica é prática e eficaz para extração de conhecimento.

2.5 CONCLUSÃO

Este capítulo apresentou a estrutura e os parâmetros de sintonia dos controladores PID e PD-nebulosos utilizados no presente trabalho.

Os algoritmos genéticos também foram introduzidos com explicação de suas características, estrutura de rotina e parâmetros de configuração, como também apresentado o levantamento bibliográfico da utilização desta técnica em diversas áreas da engenharia de controle.

As diferentes aplicações de algoritmos genéticos, citadas neste levantamento bibliográfico, são apenas alguns exemplos dos muitos encontrados na literatura atualmente.

Isso demonstra que a utilização de algoritmos genéticos está crescendo de forma segura e se firmando como uma importante técnica alternativa para busca de soluções de problemas de controle multi-objetivos e para sintonia de controladores.

O escopo deste trabalho abrange a sintonia de controladores PID e controladores PD-nebulosos em processos multivariáveis, sob arquitetura de controle descentralizada, através da utilização de algoritmos genéticos, e com a aplicação de uma função de avaliação que comporta diferentes critérios de desempenho.

Com relação à sintonia de controladores PID e controladores nebulosos, o levantamento bibliográfico apresentou a abordagem aplicada principalmente a processos monovariáveis, e com a utilização de funções de avaliação baseadas em apenas um critério de desempenho.

Com relação à sintonia de controladores PID, a aplicação de Vlachos *et al.* (2002) apresenta uma similaridade com a metodologia apresentada neste trabalho, pois os algoritmos genéticos foram utilizados para sintonia conjunta dos controladores sob arquitetura desacoplada. Porém, existem duas importantes diferenças. Primeiramente, a função de avaliação aplicada. Os autores utilizaram uma função de avaliação do algoritmo genético baseada diretamente na curva de resposta das saídas. Foram definidas áreas no plano cartesiano que limitavam valores de sobre-sinal e oscilações, e a função de avaliação tinha por objetivo principal verificar se as soluções geradas pelo algoritmo genético situavam-se dentro

desta área definida. A segunda diferença, é que a aplicação de Vlachos *et al.* (2002) inclui apenas a sintonia de dois controladores. Neste trabalho, uma das simulações a ser apresentada contempla a sintonia de cinco controladores de forma simultânea.

Com relação à sintonia de controladores nebulosos, a aplicação que mais se relaciona com a proposta apresentada neste trabalho, é a de Fabro e Arruda (2004) que também tratam de controladores sob arquitetura desacoplada em processos multivariáveis. Porém, os autores utilizam uma função de avaliação mais simples que a apresentada neste trabalho, e apresentam apenas a evolução das funções de pertinência.

Portanto, o objetivo deste trabalho, que é a aplicação de algoritmos genéticos para a sintonia conjunta destes dois tipos de controladores sob configuração descentralizada em sistemas multivariáveis acoplados, com a utilização de uma função de avaliação mais estruturada, é um complemento às pesquisas já existentes nesta área.

3.1 INTRODUÇÃO

Os sistemas de controle industriais envolvem, em sua maioria, o controle de múltiplas variáveis de entrada e saída de processos. O uso de múltiplos controladores, um para cada variável a ser controlada (Figura 3.1), é uma das estratégias utilizadas nestes tipos de plantas, em substituição à utilização de um único controlador multivariável (controlador multivariável pleno), pois um sistema multivariável controlado por várias malhas de controladores independentes é mais fácil de se implementar na prática (FABRO e ARRUDA, 2004). Nesta estratégia, considera-se que o processo multivariável é composto por n saídas independentes que podem ser controladas por n controladores monovariáveis (MARLIN, 1995), conforme Figura 3.1.

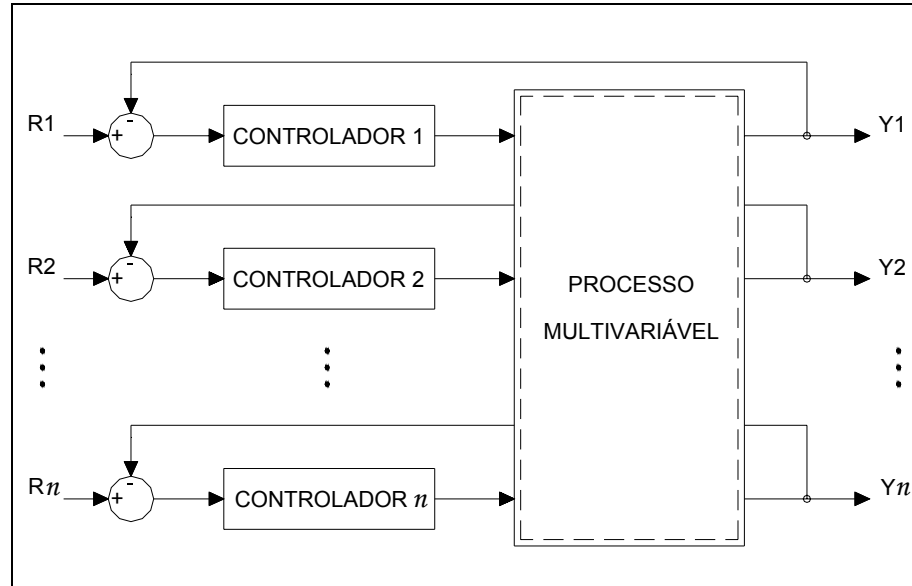


Figura 3.1- Arquitetura de controle desacoplado.

No entanto, a maior parte dos processos reais são multivariáveis com acoplamento entre suas variáveis, o que significa que uma variável controlada (saída do processo) sofre influência de várias variáveis manipuladas (entradas do processo). Neste caso, a sintonia dos n controladores, como descrito anteriormente, não é uma tarefa trivial. Existe a dificuldade de

mensurar a contribuição de cada variável manipulada em cada uma das variáveis de saída. A modificação no parâmetro de um controlador pode melhorar o desempenho de uma variável específica, mas por outro lado, piorar sensivelmente o desempenho de outras variáveis.

Assim, o primeiro passo para realizar a síntese de um controle multivariável desacoplado é escolher as variáveis controladas e as variáveis manipuladas, de modo que as diversas malhas que comportam o sistema de controle multi-malhas apresentem a menor interação possível entre as variáveis.

O estudo sobre a formação dos pares entrada/saída é em geral baseado na análise do índice de *Niederlinsk* e na análise da matriz de ganho relativo RGA (*Relative Gain Array*) (LUYBEN, 1990).

É possível eliminar os pares de variáveis indesejáveis (por exemplo, aqueles que geram instabilidade ou comportamento de fase não-mínima) através do índice de *Niederlinsk* e, em seguida, escolher os melhores pares possíveis, utilizando a matriz RGA. Na seqüência, a síntese dos controladores monovariáveis pode seguir procedimentos de complexidade crescente dependendo do tipo de comportamento desejado para a malha fechada em análise. Apesar da matriz RGA fornecer uma idéia da dimensão do acoplamento entre malhas, o problema de sintonia conjunta dos vários controladores permanece em aberto.

Portanto, propõe-se neste trabalho o uso da técnica de algoritmos genéticos (HOLLAND, 1975) para a procura direta dos diferentes parâmetros de configuração dos controladores empregados, de maneira simultânea.

Para a utilização desta metodologia, após a seleção das malhas e do tipo de controlador a ser adotado em cada malha, existem dois principais passos a serem determinados.

Primeiramente é necessário efetuar a representação cromossômica (MICHALEWICZ, 1996) de todos parâmetros dos controladores a serem ajustados. Cada tipo de controlador possui diferentes parâmetros de configuração, os quais devem ser repassados corretamente para a rotina utilizada pelo algoritmo genético. Esta representação carrega os dados que são utilizados como variáveis de procura pelo algoritmo genético.

A segunda determinação importante é a construção de uma função de avaliação (MICHALEWICZ, 1996) capaz de verificar corretamente quais são os melhores conjuntos de parâmetros de sintonia dos controladores. A função de avaliação permite quantificar e

comparar cada uma das soluções encontradas. Este é o critério utilizado para o direcionamento da busca pelo algoritmo genético.

O estabelecimento destas duas etapas principais interfere diretamente no desempenho da metodologia. Os parâmetros repassados para o algoritmo genético devem ser suficientes para a sintonia dos controladores utilizados, e a função de avaliação deve representar corretamente os objetivos de controle a serem alcançados.

Para a comprovação da metodologia, foram utilizados neste trabalho dois tipos de controladores distintos. O primeiro é o controlador PID (proporcional-integral-derivativo), largamente empregado no meio industrial. Neste tipo de controlador, a ação proporcional atua diretamente sobre o ganho do sistema, a ação integral está ligada à melhoria da precisão da resposta e a ação derivativa antecipa o erro atuante produzindo uma correção prévia (OGATA, 1998).

Mais de 90% dos laços de controle utilizados atualmente são compostos por este tipo de controlador, destes a maioria são controladores PI (ASTRÖM e HÄGGLUND, 2001).

O controlador nebuloso foi o segundo tipo de controle utilizado neste trabalho, pois, apesar de recente, tem encontrado larga aplicabilidade na indústria (ABILOV *et al.*, 2002) (LIANG, *et al.*, 2003) (PRECUP *et al.*, 2003) e vem sendo considerado uma alternativa bastante viável para processos complexos com grandes não-linearidades, além de não necessitar da modelagem exata do processo (PEDRYCZ, 1993).

O controle nebuloso procura emular as ações de um operador humano através de uma representação descritiva e experimental dos modelos de operação da planta, para então produzir as ações de controle desejadas sem a necessidade de utilização da modelagem do processo como em outras técnicas clássicas de controle (CAMPOS e SAITO, 2004). Sua estrutura é composta por variáveis lingüísticas que representam as características do processo que se quer controlar, e uma base de regras que determina a ação de controle necessária para cada condição.

Este capítulo irá apresentar os detalhes de implementação do algoritmo genético para a sintonia dos controladores PID e dos controladores nebulosos que fazem parte da metodologia proposta neste trabalho.

3.2 PRINCIPAIS PARÂMETROS DO ALGORITMO GENÉTICO

O algoritmo genético utilizado para sintonia dos controladores é formulado com algumas características diferentes das normalmente encontradas na literatura com relação à função de avaliação e ao elitismo utilizado. Diferentemente de aplicações tradicionais encontradas na literatura (COELHO e COELHO, 1999) (O'MAHONY *et al.*, 2000) que, para a avaliação das soluções encontradas pelo algoritmo genético, utilizam isoladamente critérios de otimização clássicos como ISE, ISA ou RPE, este trabalho apresenta uma função de avaliação mais abrangente, composta pelos critérios ITSE (Integral do Erro Quadrático Ponderado pelo Tempo) e de variância mínima para os sinais de saída e de controle, que são critérios universais que, quando utilizados conjuntamente, são capazes de representar as características principais das respostas do processo, o que gera bons resultados para sintonia de controladores em geral.

A segunda abordagem diferente apresentada neste trabalho é a utilização de uma casta elitista (GOLDBERG, 1989) que possui uma função que vai além da simples garantia de transmissão de bons indivíduos para a população seguinte, objetivando, também, o resguardo de um conjunto de soluções com bom nível de adequação.

Durante a evolução do algoritmo genético são geradas diferentes soluções que podem atender satisfatoriamente os requisitos desejados, as diferenças existentes entre estas soluções são relacionadas principalmente a pequenas variações nos valores de sobre-sinal, velocidade de resposta e erro de estado estacionário. De acordo com as configurações utilizadas na função de avaliação, apenas uma solução será eleita como a melhor, e as demais, serão perdidas no momento da convergência do algoritmo ou através da atuação dos operadores genéticos.

As alterações sugeridas neste trabalho, com relação à casta elitista, visam aproveitar todo o processo de avaliação efetuado pelo algoritmo genético, e salvar todas as potenciais soluções encontradas durante o processo de busca.

Esta abordagem gera opção de escolha e flexibilidade, pois ao final da simulação, são disponíveis não apenas uma, mas um conjunto de soluções potenciais, que podem ser estudadas pelos operadores da planta.

3.2.1 FUNÇÃO DE AVALIAÇÃO

O nível de aptidão dos indivíduos é avaliado a partir da minimização da seguinte função de avaliação:

$$f = [x * \int_{t_0}^{t_n} te^2(t)dt] + k_1 * [w * \sigma^2(y(t))] + k_2 * [z * \sigma^2(u(t))]$$

Na qual:

k_1, k_2 → fatores de escala;

e → erro (referência/saída do processo);

t → tempo;

$\sigma^2(y(t))$ → variância da saída $y(t)$;

$\sigma^2(u(t))$ → variância do sinal de controle $u(t)$;

w, x, z → fatores de ponderação com faixa entre [0 1] especificado pelo

projetista.

Esta função de avaliação propõe a utilização do critério da Integral do Erro Quadrático Ponderado pelo Tempo (ITSE) em conjunto com critérios de variância mínima aplicados ao sinal de controle $u(t)$ e à saída $y(t)$ do processo (ASTRÖM e WITTENMARK, 1995).

A utilização do critério ITSE possibilita uma penalização mais severa para os erros de estado estacionário gerados pela resposta ao degrau, desta forma, a busca se direciona a soluções que possibilitem acompanhamento de referência sem erro de regime.

O segundo membro da função de avaliação objetiva diminuir oscilações que possam ocorrer na saída do sistema, a partir da minimização da variância observada no sinal de saída $y(t)$ do processo, este critério é importante para o desempenho do sistema em malha fechada na presença de perturbações aleatórias.

O terceiro membro, que aplica a minimização da variância do sinal de controle $u(t)$, tem por objetivo possibilitar a procura por uma sintonia que gere sinais de controle que não apresente o fenômeno de *ringing* (ASTRÖM e WITTENMARK, 1995).

Os fatores de escala k_1 e k_2 são necessários para situar os valores encontrados pelas parcelas 2 e 3 da função de avaliação na mesma ordem de grandeza dos valores encontrados

na primeira parcela. Este escalonamento é necessário para que nenhum critério se sobreponha, suprimindo a influência dos demais. No momento do projeto, é necessária a observação das características das respostas do processo a ser controlado, para um correto dimensionamento destes fatores. Para tanto, pode-se aplicar um degrau na entrada do processo com magnitude igual aos valores de referência solicitados no projeto, e verificar a amplitude do erro e da variância da saída em malha fechada.

Os fatores de ponderação w , x e z possibilitam que o projetista possa exercer sua preferência de acordo com objetivos de controle distintos, atribuindo pesos diferenciados de acordo com a necessidade. Por exemplo, para grandes valores de z ou w em relação ao fator x , o resultado do algoritmo de busca favorece os indivíduos, e portanto os controladores, que possuem pouca ou nenhuma variação no sinal de saída, mas que podem apresentar algum erro de estado estacionário. Da mesma forma, para uma ponderação x maior que w e z , os indivíduos que possuam erro de estado estacionário maior serão mais rapidamente eliminados que indivíduos mais próximos ao valor de referência que apresentem variações de pequena amplitude nos sinais de controle e saída. Desta forma, dependendo das características do processo a ser controlado e do principal objetivo de sintonia – diminuição do sobre-sinal, aumento da velocidade de resposta, diminuição do erro de estado estacionário, suavização do transitório – estes fatores podem ser estudados e utilizados como ferramenta auxiliar na sintonia dos controladores.

Para um processo com n saídas, a função de avaliação deve ser aplicada de forma independente para cada uma delas. O equilíbrio das respostas obtidas determina qual indivíduo apresenta o melhor desempenho, considerando todas as saídas simultaneamente. Este equilíbrio pode ser determinado a partir do somatório do valor obtido para cada saída, ou a partir de qualquer outro tipo de soma ponderada. Neste trabalho, o conjunto de parâmetros de sintonia escolhido para os controladores é aquele que minimiza o seguinte critério de desempenho:

$$J = \sqrt{(f_1)^2 + (f_2)^2 + \dots + (f_i)^2 + \dots + (f_n)^2}$$

Sendo f_i o resultado da aplicação da função de avaliação à saída i .

A otimização desta função de avaliação tem assegurado bons resultados mesmo para sistemas fortemente acoplados, e pode ser utilizada em diferentes processos.

Uma modificação pode ser incluída a fim de permitir uma priorização das malhas de controle, como mostrado a seguir:

$$J = \sqrt{q_1(f_1)^2 + q_2(f_2)^2 + \dots + q_i(f_i)^2 + \dots + q_n(fn)^2}$$

A escolha do coeficiente de ponderação $q_i > 1$ garante que a saída i terá maior influência no resultado, e a sintonia a ser implementada será aquela que minimiza a malha i . Este coeficiente de ponderação também pode ser utilizado para escalonar saídas que tenham valores de referência de diferentes magnitudes.

3.2.2 ELITISMO E MÉTODO DE SELEÇÃO

Neste trabalho, a casta elitista além de ser responsável pela garantia de transmissão de bons indivíduos para a população seguinte, tem a função preservar um conjunto de soluções com bom nível de aptidão.

A casta elitista foi projetada para guardar um número significativo de bons elementos durante toda a evolução do algoritmo. Desde a primeira geração, os melhores indivíduos são guardados e só podem ser substituídos por outros de melhor desempenho comprovado.

Dentro da casta elitista, não ocorrem as operações de mutação e recombinação, exatamente para não existir o risco de uma alteração mal sucedida em uma solução boa. As operações genéticas ocorrem somente nas castas de trabalho do algoritmo genético, nas quais existem cópias dos elementos guardados na casta elitista.

A casta elitista tem a função de manter os melhores indivíduos encontrados durante toda a evolução, mesmo no momento da convergência total de um único elemento nas demais castas do programa.

Para escolha dos indivíduos em cada população foi empregado o método de seleção por roleta (GOLDBERG, 1989), com elitismo de 10% do tamanho da população. Foram determinadas quatro castas com distribuição conforme Tabela 3.1. A casta elitista é composta por 10% do tamanho da população, e abriga os melhores elementos da geração anterior, sem que haja repetição de uma mesma solução. A casta de reprodução é formada pela reprodução dos 20% melhores elementos da população corrente, podendo haver repetições. A casta intermediária é formada pela transmissão direta de 50% da população corrente referente aos

indivíduos com nível de aptidão intermediário. A última casta é composta pelas soluções menos adequadas da população corrente, que sofrem um processo de eliminação e são transmitidas apenas em parte para a nova geração.

	População corrente		Próxima geração	Casta
Maior nível de aptidão ↑			10%	Casta Elitista
	20%	→	25%	Casta de reprodução
	50%	→	50%	Casta intermediária
	30%	→	15%	Casta de eliminação

Tabela 3.1- Distribuição das castas.

A Figura 3.2 apresenta o procedimento utilizado pelo algoritmo genético para a construção das castas descritas.

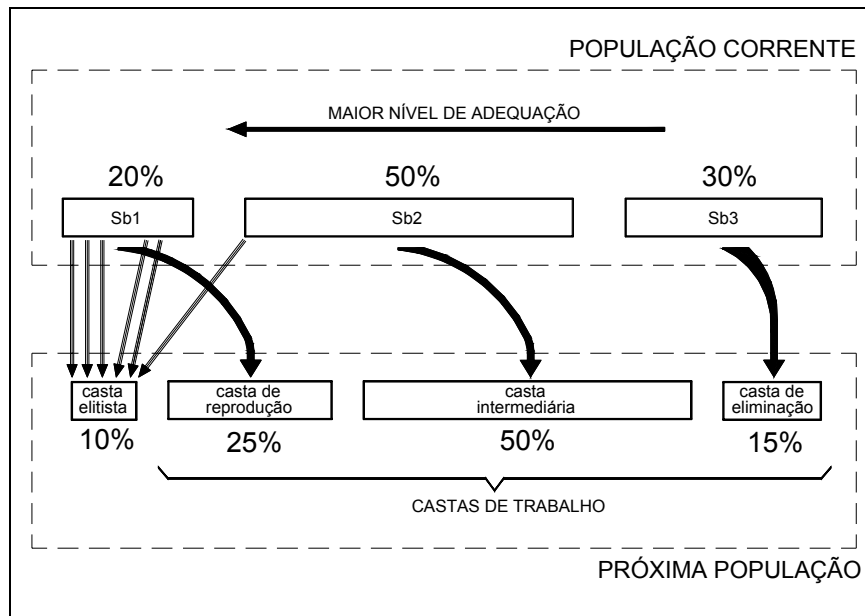


Figura 3.2- Construção das castas

Primeiramente os indivíduos da população corrente, após avaliados, são ordenados de acordo com seus níveis de aptidão, e, então, a população é subdividida em três partes correspondentes a 20, 50 e 30% do tamanho total da população. A seguir, o algoritmo repassa os indivíduos com melhor nível de aptidão para a casta elitista da população seguinte, até completar o número de 10% do tamanho da população, sem que haja indivíduos iguais. Como

podem existir indivíduos repetidos dentro da subdivisão Sb1 (20% melhores da população corrente), a casta elitista pode ser formada por elementos das outras subdivisões. Posteriormente os indivíduos da subdivisão Sb1 são reproduzidos através da atuação da roleta (GOLDBERG, 1989) formando a casta de reprodução. Os indivíduos da subdivisão Sb2 são repassados diretamente para a casta intermediária, e, finalmente, alguns indivíduos da subdivisão Sb3 sofrem eliminação, também através da utilização da roleta (GOLDBERG, 1989), gerando a casta de eliminação.

Após este procedimento, são utilizados os operadores genéticos de mutação e recombinação somente nas castas de trabalho do algoritmo genético (Figura 3.2), para a finalização da construção da nova geração. Após formada, a nova geração tem todos os seus indivíduos avaliados, ordenados e posteriormente subdivididos nas três partes (Sb1, Sb2 e Sb3) para a continuação do ciclo de busca.

Com a utilização da metodologia apresentada, ao final da simulação, são disponíveis na casta elitista, não apenas um, mas vários indivíduos que formam o conjunto das melhores soluções encontradas pelo algoritmo genético.

Em sistemas de controle é comum encontrar várias soluções que são interessantes sob diferentes aspectos. As características de velocidade, sobre-sinal, erro de estado estacionário e estabilidade da resposta normalmente são contraditórias, de tal forma que, em alguns sistemas, é impossível uma solução que atenda a todos estes requisitos satisfatoriamente. Por exemplo, em muitos casos, a solução que apresenta a resposta mais rápida é aquela que apresenta o maior valor de sobre-sinal.

Portanto, ao visualizar um conjunto de soluções possíveis, o operador tem flexibilidade e opção de escolha, podendo trabalhar com uma ou mais soluções de acordo com seu interesse.

3.2.3 CRITÉRIO DE PARADA

Diferentemente de aplicações clássicas, nas quais o critério de parada é baseado na convergência da população através da estipulação de uma diversidade mínima a partir da qual o final o algoritmo pode ser estabelecido, para a utilização da metodologia apresentada neste trabalho, deve-se arbitrar um número mínimo de gerações que, após decorridas, os resultados

obtidos devem ser analisados para a determinação do encerramento da simulação ou sua retomada até um novo número de gerações.

A metodologia apresentada neste trabalho visa o encontro de um conjunto de soluções potenciais ao problema, em substituição ao fornecimento de uma única solução. O critério de diversidade mínima não se adapta ao objetivo desta metodologia, pois não é necessário aguardar a convergência de um único indivíduo nas castas de trabalho do programa, para o estabelecimento do encerramento da rotina.

Com relação à situação inversa, se for arbitrado um número de gerações maior que o necessário para o encontro do conjunto suficiente de soluções, não ocorrerão perdas, pois a casta elitista mantém a diversidade de soluções independente do número de gerações estipulado.

Portanto, o arbitramento do número inicial de gerações e a análise do resultado obtido, são mais adequados para a definição do encerramento ou continuação da rotina, nesta metodologia proposta.

3.3 SINTONIA DE CONTROLADORES PID

O processo de sintonia de controladores PID, através da metodologia proposta neste trabalho, é feito diretamente pela busca dos melhores valores para cada um dos parâmetros K_p , K_i , e K_d através da utilização de algoritmos genéticos, em substituição aos métodos clássicos como *Ziegler Nichols* (OGATA, 1998) e *Biggest Log Modulus* (LUYBEN, 1986), entre outros.

A rotina do algoritmo genético para esta finalidade é simples, a representação cromossômica não é complexa e, como os cromossomos não são grandes, o encontro de soluções ocorre rapidamente.

3.3.1 REPRESENTAÇÃO CROMOSSÔMICA

Para a sintonia do controle PI e PID, foi definida a utilização de cromossomos com número de genes igual ao número de parâmetros de configuração (K_p , K_i , K_d) multiplicado pelo número de controladores existentes na planta, isto é, o número de malhas simples a serem sintonizadas.

A representação dos genes é feita por ponto flutuante, e a faixa de variação é determinada isoladamente para cada gene que compõe o cromossomo.

Esta determinação é feita a partir de ensaios preliminares que visam encontrar valores de ganhos últimos das malhas, através do método do período crítico. Nestes ensaios, aplica-se um degrau na entrada do sistema e aumenta-se gradativamente a amplitude dos ganhos dos parâmetros dos controladores utilizados até o surgimento de instabilidades nas respostas do processo (OGATA, 1998).

Os valores de amplitude de ganho encontrados são utilizados como limitador da faixa de variação de cada parâmetro para a geração da população inicial da rotina.

3.3.2 OPERAÇÕES DE MUTAÇÃO E DE RECOMBINAÇÃO

As operações de mutação e de recombinação para sintonia de controladores PID é executada de maneira simples.

A mutação sorteia genes dentro de uma população substituindo totalmente seus valores por outros gerados de maneira aleatória. Para que exista uma segurança quanto à possibilidade dos espaços de busca não terem sido bem dimensionados, o operador de mutação é projetado para sortear números aleatórios dentro e fora da faixa de variação pré-determinada. Para tanto, a faixa de variação é aumentada em três vezes (valor arbitrário), e os sorteios ocorrem na proporção de 5 (faixa de variação original) para 1 (faixa de variação três vezes maior).

Desta maneira, o algoritmo fica aberto a soluções diferentes das esperadas, mas, se alguma dessas soluções causar instabilidade da malha, terá um baixo nível de aptidão e portanto, será eliminada em poucas gerações através do método de seleção utilizado pelo algoritmo genético.

A operação de recombinação, além de sortear dois cromossomos aleatoriamente dentro da população, sorteia também o ponto de quebra e troca entre as duas soluções, sendo este ponto, portanto, diferente em cada atuação desta operação.

3.4 SINTONIA DE CONTROLADORES NEBULOSOS

Controladores nebulosos possuem duas principais estruturas que interferem diretamente no desempenho do sistema: as características das funções de pertinência, e a base de regras utilizada pelos controladores.

Conforme apresentado no capítulo 2, existem três abordagens diferentes para sintonia automática destas estruturas através de algoritmos genéticos. A primeira delas procura o melhor formato e posições das funções de pertinência dentro do universo de discurso utilizado. A segunda utiliza o algoritmo genético para desenvolver a base de regras necessária ao controle nebuloso. A terceira metodologia sintoniza de forma paralela as duas estruturas procurando as melhores características das funções de pertinência e a base de regras utilizada pelo controlador.

Neste trabalho, com o intuito de comparar o desempenho do algoritmo genético para diferentes tipos de sintonia, desenvolve-se duas propostas de sintonia de controladores nebulosos. A primeira utiliza a metodologia de evolução da base de regras dos controladores nebulosos com funções de pertinência igualmente distribuídas no universo de discurso das variáveis; e a segunda, a evolução das funções de pertinência dos controladores nebulosos com base de regras definida a priori.

Cada metodologia requer uma rotina de algoritmo genético diferenciada, além disso, a manipulação da base de regras e das funções de pertinência exercem influências distintas sobre o processo a ser controlado, e o desempenho do algoritmo genético e os resultados obtidos são diferentes para cada uma destas técnicas.

Esta diferença de desempenho, e as vantagens e desvantagens de cada metodologia, serão evidenciados durante a análise dos resultados de simulação.

3.4.1 REPRESENTAÇÃO CROMOSSÔMICA DA BASE DE REGRAS

A base de regras representa as ações de controle a serem tomadas mediante todas as combinações possíveis de variações verificadas nas variáveis lingüísticas de entrada.

O número de funções de pertinência de uma variável lingüística determina o número de variações desta entrada considerada pelo controlador. Portanto, para o estabelecimento de uma base de regras completa, é necessário criar regras para todas as combinações possíveis das funções de pertinência das variáveis lingüísticas de entrada.

Um controle composto por duas variáveis de entrada e uma variável de saída com cinco funções de pertinência cada, pode possuir uma base de regras com 25 linhas ($5^2 = 25$ linhas). A representação cromossômica deste controlador deve conter, portanto, 25 genes correspondentes a cada combinação existente na base de regras. Para a sintonia de dois controladores, o cromossomo deve possuir 50 genes, que combinados aos 5 alelos possíveis, ocasionam um espaço de busca maior que 300 milhões.

Para a busca de uma solução factível neste espaço, é necessária a utilização de um número elevado de elementos e de gerações, o que pode inviabilizar o uso do algoritmo genético devido ao tempo computacional necessário para a avaliação de um número extenso de soluções. Portanto, torna-se necessário o estabelecimento de algumas simplificações nesta representação.

Um controlador nebuloso PD (proporcional-derivativo) utiliza, como variáveis lingüísticas de entrada, o erro (diferença entre o valor de referência e a saída do processo), e a variação do erro (diferença entre o erro no instante atual e no instante anterior). As funções de pertinência destas variáveis lingüísticas podem ser definidas como NG (negativo grande), NP (negativo pequeno), ZE (zero), PP (positivo pequeno) e PG (positivo grande) (HARRIS *et al.*, 1993).

Com estas características, a base de regras para um controlador PD-nebuloso é apresentada na Tabela 3.2 (HARRIS *et al.*, 1993).

		Variação do erro (Δe)				
		NG	NP	ZE	PP	PG
Erro (e)	NG	NG	NG	NG	NP	ZE
	NP	NG	NG	NP	ZE	PP
	ZE	NG	NP	ZE	PP	PG
	PP	NP	ZE	PP	PG	PG
	PG	ZE	PP	PG	PG	PG

Tabela 3.2- Base de regras para controlador PD-nebuloso.

É possível perceber nesta base de regras uma simetria entre as regras existentes para as combinações negativas e positivas de entrada. O ponto central da base de regras representado por ZE, determina o ponto base de espelhamento entre as demais regras (Tabela 3.3). Por exemplo, considerando a combinação de entrada PPxPP, a regra selecionada é PG, para o ponto simétrico a este, NPxNP, a regra selecionada é NG (Tabela 3.3).

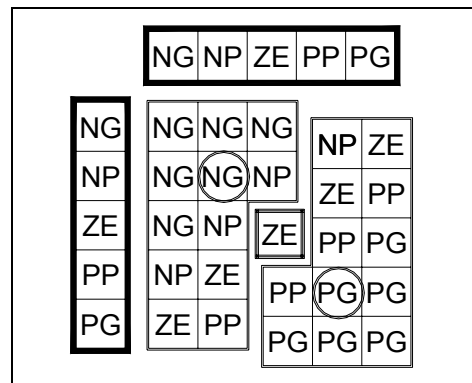


Tabela 3.3- – Simetria da base de regras para controlador PD-nebuloso.

A partir desta constatação, pode-se estabelecer na rotina do algoritmo genético a procura de uma base de regras também simétrica. A vantagem de utilizar esta simetria, é a redução do número de genes necessário dentro do cromossomo. Em substituição aos 25 genes correspondentes a todas as combinações, é possível utilizar somente 13 genes representando apenas o lado esquerdo da base de regras e o ponto central. Desta maneira, cada solução encontrada pelo algoritmo genético é espelhada para o lado direito, compondo então a base de regras completa a ser utilizada pelo controlador.

Com a utilização desta abordagem, para a sintonia de dois controladores nebulosos com a mesma configuração, são necessários cromossomos com 26 genes, possuindo como alelos possíveis números que correspondem às funções de pertinência da saída de cada controlador. Considerando que cada gene tem como alelos possíveis as cinco funções de pertinência da saída, tem-se uma combinação de 26 elementos variando de 1 a 5, o que corresponde a um espaço de busca um pouco maior que 11 milhões.

A Figura 3.2 resume os passos a serem seguidos pelo algoritmo genético para o estabelecimento da rotina nestas condições. No passo 1, a representação cromossômica é feita considerando-se apenas os pontos do lado esquerdo (x) das bases de regras e os pontos centrais (o). No passo 2, após a evolução, o cromossomo deve ser quebrado para o isolamento das partes correspondentes a cada controlador. No passo 3, as partes do cromossomo são então espelhadas para o lado direito (z) para o estabelecimento completo da base de regras. A partir de então, este resultado pode ser aplicado ao processo e avaliado pela função de avaliação.




Figura 3.3- Rotina da representação cromossômica da base de regras.

Esta representação foi utilizada nas simulações apresentadas no capítulo 4 com bons resultados.

A utilização do espelhamento das regras interfere diretamente no número de gerações utilizadas para o encontro de uma solução. Para a sintonia de um único controlador, esta abordagem pode não ser necessária, mas para a sintonia simultânea de um número maior de controladores, como é a proposta deste trabalho, esta diferença é bastante significativa.

A representação cromossômica completa da base de regras, objetivando o encontro de regras não simétricas, é recomendada para processos complexos e não-lineares nos quais a não-simetria pode se adaptar melhor às condições e características do sistema. No entanto, o algoritmo genético levará um tempo maior para encontrar uma solução adequada ao problema.

3.4.2 REPRESENTAÇÃO CROMOSSÔMICA DAS FUNÇÕES DE PERTINÊNCIA

O universo de discurso de uma variável lingüística representa o domínio de todos os possíveis valores reais que ela pode assumir. Dentro do universo de discurso, são definidos subconjuntos que delimitam regiões que classificam os diversos elementos existentes neste intervalo. As funções de pertinência têm a função de determinar com que grau um elemento pertence às regiões delimitadas no universo de discurso.

O número, o formato e a disposição das funções de pertinência sobre o universo de discurso utilizado por cada variável lingüística são parâmetros de projeto que interferem no desempenho do controlador nebuloso.

Para controladores nebulosos baseados em regras, as funções de pertinência individuais das variáveis lingüísticas de entrada do controlador, que compõem as premissas das regras na base de regras, devem ser funções do tipo pseudo-trapezoidais (Figura 3.4), definidas no conjunto dos números reais, sobre o intervalo de discurso da variável (WANG, 1997):

$$\mu_A(u, T_1, T_2, T_3, T_4, H) = \begin{cases} I(u), u \in [T_1, T_2) \\ H, u \in [T_2, T_3] \\ D(u), u \in (T_3, T_4] \\ 0, u \in R - (T_1, T_4) \end{cases}$$

Onde:

$0 \leq I(u) \leq 1$ é uma função não-decrescente no intervalo $(T_1, T_2]$

$H = I(T_2) = D(T_3)$ é uma constante no intervalo $(T_2, T_3]$

$0 \leq D(u) \leq 1$ é uma função não-crescente no intervalo $(T_3, T_4]$

$T_1 \leq T_2 \leq T_3 \leq T_4$ e $T_1 < T_4$




Figura 3.4- Representação de uma função do tipo pseudo-trapezoidal.

Por exemplo, uma variável lingüística que possui cinco atributos simétricos representados por funções de pertinências trapezoidais é mostrada na Figura 3.5. Neste caso, a representação cromossômica dos parâmetros de construção destas funções pode ser definida através da representação numérica de oito pontos ordenados conforme Figura 3.5.

Nesta codificação, são representados os pontos de construção das bases superior e inferior dos trapézios de cada função de pertinência do semi-plano esquerdo do universo de discurso. O semi-plano direito é composto através do espelhamento destes pontos.

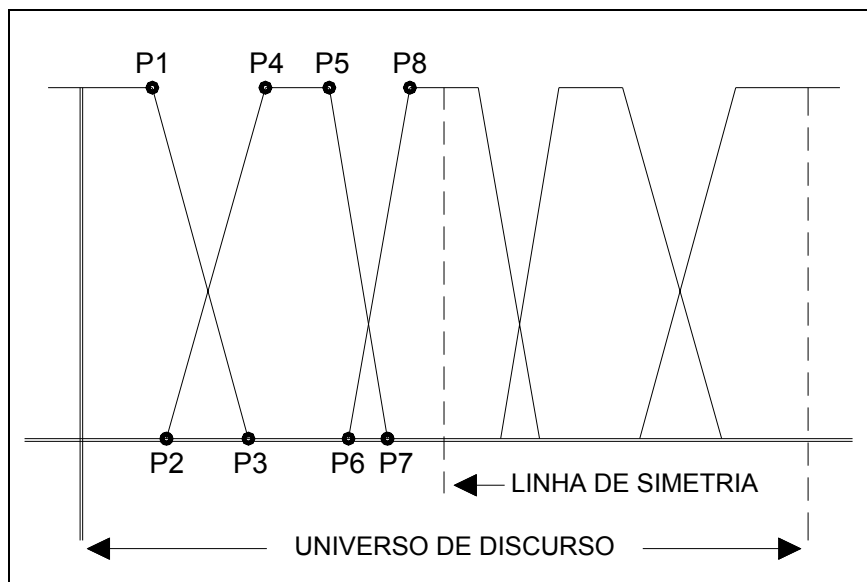


Figura 3.5- Codificação das funções de pertinência.

Com esta representação, o algoritmo genético busca aleatoriamente oito pontos ordenados dentro do semi-plano esquerdo do universo de discurso, que representam os pontos

de construção das funções de pertinência dispostos conforme apresentado na Figura 3.5. Esta disposição permite que todo o espaço do universo de discurso seja coberto por pelo menos uma função de pertinência e que sempre ocorram interseções destas funções.

Esta codificação permite a construção de funções de pertinência não simétricas, ou seja, neste caso, os trapézios construídos não são necessariamente isósceles, conforme o trapézio delimitado pelos pontos P2, P4, P5 e P7 na Figura 3.5 que não possui lados congruentes. Além disso, permite também que os pontos de intersecção entre as funções de pertinência possam ocorrer em diferentes alturas com relação ao eixo das ordenadas, conforme visualizado na Figura 3.5.

Desta forma, apesar da fixação de uma simetria na distribuição das funções de pertinência em torno de um atributo central, existe ainda flexibilidade para a formação do corpo e disposição das funções de pertinência sobre o universo de discurso.

A representação cromossômica de um controle composto por duas variáveis de entrada e uma variável de saída, com cinco funções de pertinência trapezoidais cada, é feita com a utilização de cromossomos compostos por 24 genes, que representam os oito pontos de construção das funções de pertinência de cada uma das três variáveis lingüísticas. A representação cromossômica de dois controladores nebulosos com as mesmas características é, portanto, composta por cromossomos com 48 genes.

A representação dos genes é feita por ponto flutuante, e são construídas restrições na rotina do algoritmo genético para que os conjuntos dos oito pontos sejam sempre estabelecidos, durante as evoluções, dentro do universo de discurso fixado para cada variável. Portanto, os espaços de busca de cada conjunto de oito pontos abrangem simplesmente quaisquer valores dentro dos respectivos universos de discurso.

3.4.3 OPERAÇÕES DE MUTAÇÃO E DE RECOMBINAÇÃO

A operação de mutação para sintonia de controladores nebulosos, a partir da evolução da base de regras ou das funções de pertinência, é executada através do sorteio aleatório de genes dentro de uma população, e posterior substituição de seus valores por outros situados dentro da faixa de variação pré-estabelecida para cada gene.

A operação de recombinação na rotina de evolução das bases de regras possui duas etapas distintas. A primeira etapa é executada a partir do sorteio aleatório de dois

cromossomos dentro da população e do ponto de quebra e troca entre estas duas soluções, ou seja, o ponto de quebra é diferente em cada atuação desta operação. Na segunda etapa, o ponto de quebra é fixado no centro do cromossomo, neste caso, dois cromossomos são sorteados aleatoriamente e trocam entre si inteiramente a base de regras de um dos controladores.

A operação de recombinação na rotina de evolução das funções de pertinência é composta apenas pela etapa correspondente ao sorteio aleatório de dois cromossomos dentro da população e do ponto de quebra e troca entre estas duas soluções. Esta operação respeita a seqüência dos oito pontos de cada variável lingüística, ou seja, determinado conjunto de oito pontos de certa função de pertinência é substituído completamente por outro conjunto de oito pontos desta mesma função de pertinência. Neste caso, o operador genético é projetado para visualizar dentro de um cromossomo os três conjuntos de oito pontos, para cada controlador, e as quebras para as trocas ocorrem sempre entre os conjuntos e nunca dentro deles.

4.1 INTRODUÇÃO

Para avaliação da metodologia, foram utilizados três diferentes processos: Coluna de Destilação Wood-Berry (WOOD e BERRY, 1973), Coluna de Destilação de Isopropanol (GILLES e RETZBACH, 1983) e Processo de Craqueamento Catalítico em Leito Fluidizado (PROSDÓSSIMO, 2003).

As colunas de destilação são sistemas complexos para a engenharia de controle de processos, pois apresentam características que dificultam sua estabilização, como não-linearidades, atrasos e ganhos variáveis (COELHO, 1991). As colunas de destilação Wood-Berry e de Isopropanol são modelos multivariáveis com duas entradas, duas saídas e que apresentam acoplamento entre as variáveis. Esta característica de acoplamento é importante para a validação da metodologia apresentada neste trabalho, que visa o ajuste simultâneo dos controladores independentes utilizados nas malhas do sistema, levando-se em consideração as respostas de todas as variáveis controladas envolvidas.

O Processo de Craqueamento Catalítico em Leito Fluidizado (FCC) é um processo largamente empregado na indústria de refino, responsável pela produção de derivados nobres de petróleo, como gasolina e gás liquefeito de petróleo (MELO JR., 2003). O FCC pode ser modelado para fins de controle como um sistema multivariável, com cinco entradas e cinco saídas, que apresenta grandes constantes de tempo e atraso de transporte, além de ser não linear (PROSDÓSSIMO, 2003).

As metodologias apresentadas no capítulo anterior foram aplicadas na sintonia de um conjunto de controladores para estes três processos. Porém, em cada processo empregou-se uma arquitetura de controle diferenciada.

O controle da coluna de destilação Wood-Berry foi composto inicialmente por controladores PI e, posteriormente, uma segunda simulação empregou controladores PID. A execução das duas simulações objetivou comparar a atuação do algoritmo genético para o ajuste de um número diferente de parâmetros deste controlador na sintonia de um mesmo processo.

O controle da coluna de destilação de Isopropanol foi composto por controladores nebulosos que foram inicialmente sintonizados através da evolução de suas bases de regras e, posteriormente, a título de comparação, sintonizados a partir da manipulação das funções de pertinência de suas variáveis lingüísticas. Considerando que estas abordagens requerem uma rotina de algoritmo genético com características próprias, e as influências sobre o processo a ser controlado são distintas para cada uma delas, a execução da sintonia através destas duas metodologias objetivou verificar as vantagens e desvantagens de cada uma, como também, a diferença de desempenho do algoritmo genético.

O processo de Craqueamento Catalítico em Leito Fluidizado teve duas arquiteturas de controle distintas sintonizadas por algoritmos genéticos, a primeira feita através da composição de controladores nebulosos (aplicados a duas saídas) com sintonia através da base de regras e controladores PIs (aplicados a três saídas do processo); e a segunda composta por controladores PIs aplicados a cada uma das cinco saídas do processo. A diferença da arquitetura de controle efetuada nestas duas simulações visou demonstrar a aplicabilidade do algoritmo genético para sintonia de diferentes controladores na simulação de um processo com um maior número de variáveis envolvidas.

Como ferramenta de programação foi utilizado o *software* matemático Matlab® versão 6.5. Todas as funções utilizadas na rotina do algoritmo genético foram desenvolvidas, não sendo empregada nenhuma biblioteca de funções desenvolvida em outro grupo.

Os modelos das colunas de destilação Wood-Berry e de Isopropanol foram simulados através da ferramenta *Simulink* do *software* Matlab.

A simulação do processo FCC foi executada no *software* C++ Builder 5, pois, neste ambiente, o tempo de simulação deste processo é consideravelmente menor que o verificado com a utilização do Matlab. Porém, somente a simulação do processo foi executada em C++ Builder, a rotina do algoritmo genético e a estrutura dos controladores nebulosos foi mantida no programa Matlab, devido à existência de um *toolbox* direcionado a sistemas nebulosos que facilita a implementação de controladores. Portanto, foi necessário o estabelecimento de uma comunicação entre estes dois programas.

Para todas as simulações apresentadas, foi utilizado um computador com as seguintes configurações: Athlon (TM) XP 2400+, 2 GHz, 512 MB RAM.

4.2 COLUNA DE DESTILAÇÃO WOOD-BERRY

Wood e Berry (1973) desenvolveram um modelo para uma coluna de destilação em escala piloto, utilizada na separação de metanol e água. As funções de transferência que descrevem o comportamento deste sistema são:

$$\begin{bmatrix} y_1(s) \\ y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{12,8e^{-s}}{16,7s+1} & \frac{-18,9e^{-3s}}{21,0s+1} \\ \frac{6,6e^{-7s}}{10,9s+1} & \frac{-19,4e^{-3s}}{14,4s+1} \end{bmatrix} * \begin{bmatrix} x_1(s) \\ x_2(s) \end{bmatrix}$$

As variáveis controladas do processo e seus respectivos pontos de operação são:

- Porcentagem mássica de metanol no topo ($y_1(s)$).
Referência: 96%
- Porcentagem mássica de metanol no fundo ($y_2(s)$).
Referência: 0.5%

As variáveis manipuladas do processo são:

- Vazão mássica de refluxo ($x_1(s)$) expresso em lb/min.
- Vazão mássica de vapor ($x_2(s)$) expresso em lb/min.

A unidade de tempo padrão é o minuto.

4.2.1 PROCESSO DE SINTONIA

Para o controle da coluna de destilação Wood-Berry, foram inseridos no sistema dois controladores PID conforme Figura 4.1.

O processo de sintonia dos controladores PID foi feito diretamente pela busca de melhores valores para cada um dos parâmetros K_p , K_i e K_d de cada controlador simultaneamente através da utilização de algoritmos genéticos.

Com o objetivo de se avaliar o desempenho do algoritmo genético para a sintonia deste tipo de controle, efetuou-se duas simulações distintas, na primeira, foram utilizados apenas controladores PI (seção 4.2.3) e, posteriormente, controladores PID (seção 4.2.4).

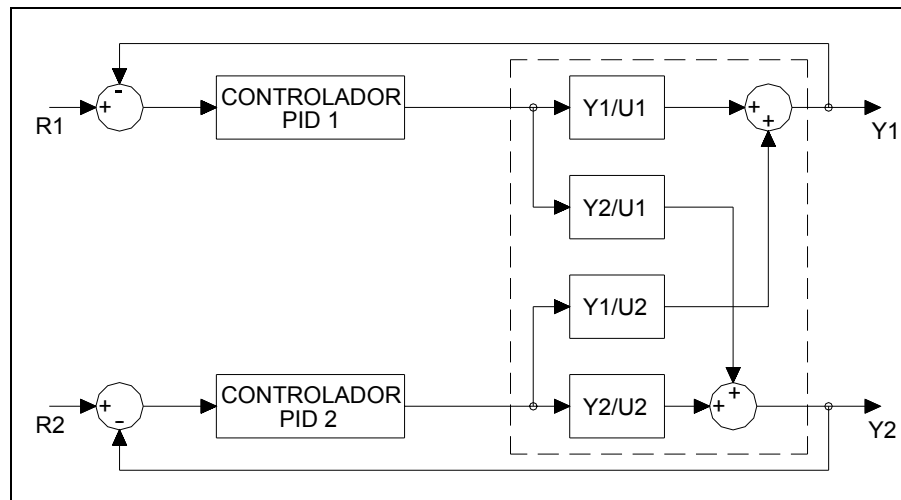


Figura 4.1- Arquitetura de controle, Coluna de Destilação Wood Berry.

4.2.2 CONFIGURAÇÕES DO AG

Para a sintonia dos controladores PI, foi definida a utilização de cromossomos com 4 genes, que representam diretamente os parâmetros K_{i1} , K_{p1} do controlador 1 e K_{i2} , K_{p2} do controlador 2. Para os controladores PID, foram utilizados cromossomos com 6 genes, representando os parâmetros K_{i1} , K_{p1} , K_{d1} , K_{i2} , K_{p2} e K_{d2} .

Para sintonia dos controladores PI, os cromossomos tiveram, como genes possíveis, números reais menores que 0.2 em módulo, visto que em uma análise preliminar, ganhos maiores que este ocasionaram instabilidade no sistema. Portanto, a faixa de variação para todos os parâmetros do controle PI foi definida como sendo entre $[-0.2$ e $0.2]$. Para os controladores PID, foi utilizado faixa de variação entre $[-0.1$ e $0.1]$ para todos os parâmetros.

Com relação às configurações do algoritmo genético, o tamanho da população foi definido em 100 indivíduos, taxa de mutação de 0.05, e taxa de recombinação de 0.10.

4.2.3 RESULTADOS OBTIDOS CONTROLE PI

O cromossomo escolhido através da evolução do algoritmo genético apresenta os seguintes valores de ganho:

$$K_{p1} = 0.13165$$

$$K_{i1} = 0.01701$$

$$K_{p2} = -0.18721$$

$$K_{i2} = -0.01563$$

As respostas do sistema com os controladores PI sintonizados pela metodologia apresentada podem ser observadas nas Figura 4.2 e 4.3, os valores referência são os pontos de operação de 96% de metanol no topo e 0.5% de metanol no fundo.

O sistema apresenta erro de estado estacionário nulo, valor de sobre-sinal próximo de zero para y_1 e de menos de 40% para y_2 , tempo de acomodação de aproximadamente 100 minutos para y_1 e para y_2 , e tempo de subida de aproximadamente 50 minutos para y_1 .




Figura 4.2- Resposta obtida y_1 , controle PI sintonizado por algoritmos genéticos.

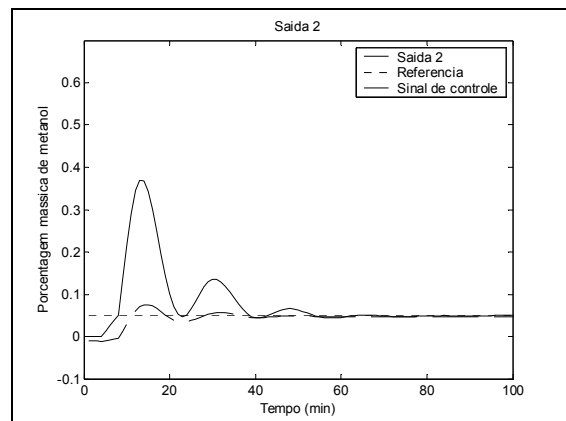


Figura 4.3- Resposta obtida y_2 , controle PI sintonizado por algoritmos genéticos.

Com o objetivo de comparar os resultados obtidos pelo algoritmo genético para esta sintonia, utilizou-se o trabalho de Tavakoli *et al.* (2005), que, para a sintonia dos controladores PI aplicados à coluna de Wood Berry, utilizou o método BLT (*Biggest Log Modulus*), proposto por Luyben (1986). Seus resultados podem ser observados nas Figuras 4.4 e 4.5, cujos valores de sintonia são $K_{p1} = 0.375$, $K_{i1} = 0.045$, $K_{p2} = -0.075$, $K_{i2} = -0.003$.

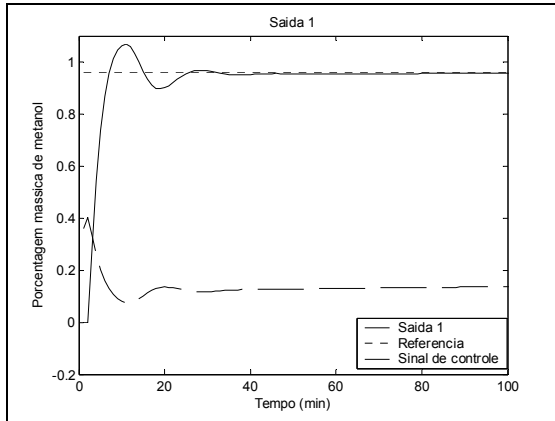


Figura 4.4- Resposta obtida y_1 , controle PI sintonizado pelo método BLT.

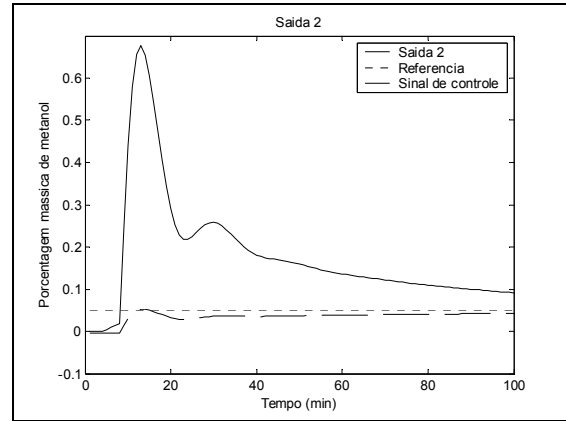


Figura 4.5- Resposta obtida y_2 , controle PI sintonizado pelo método BLT.

É possível perceber que houve uma melhoria com relação a velocidade da resposta da saída y_1 , porém, a resposta da saída y_2 apresenta o dobro do valor de sobre-sinal e não se estabiliza até o tempo de 100 min.

Portanto, os resultados obtidos com a utilização do algoritmo genético apresentam um compromisso maior entre a precisão das respostas das duas saídas simultaneamente.

4.2.4 RESULTADOS OBTIDOS CONTROLE PID

O cromossomo escolhido através da evolução do algoritmo genético apresenta os seguintes valores de ganho:

$$K_{p1} = 0,11238$$

$$K_{i1} = 0,02431$$

$$K_{d1} = 0,00639$$

$$K_{p2} = -0,12129$$

$$K_{i2} = -0,01580$$

$$K_{d2} = -0,13549$$

As respostas do sistema com os controladores PID sintonizados pela metodologia apresentada podem ser observadas nas Figuras 4.6 e 4.7, os valores referência são os pontos de operação de 96% de metanol no topo e 0.5% de metanol no fundo.

É possível perceber que o sistema apresenta erro de estado estacionário nulo, valor de sobre-sinal próximo de zero para y_1 e de menos de 40% para y_2 , tempo de acomodação de aproximadamente 100 minutos para y_1 e para y_2 , e tempo de subida de aproximadamente 20 minutos para y_1 . Comparado ao controle PI sintonizado por algoritmo genético exposto

anteriormente (Figuras 4.2 e 4.3), o sistema é mais rápido e menos oscilante no período transitório.

Com o objetivo de verificar o desempenho do sistema para diferentes requisitos, os valores de referência são alterados em três diferentes patamares, conforme Figuras 4.8 e 4.9.

Os resultados obtidos com a mudança dos valores de referência não diferem dos anteriores. Os valores de erro de estado estacionário, sobre-sinal e tempo de acomodação são similares, demonstrando que o sistema de controle pode atuar em diferentes condições.

Para verificar o comportamento do sistema de controle frente a perturbações, aplica-se na saída y_1 do processo, sinais do tipo seqüência de degraus conforme Figura 4.10. Os resultados da resposta do sistema podem ser observados nas Figuras 4.11 e 4.12. As perturbações inseridas foram compensadas pelo sistema de controle em poucas unidades de tempo, o que demonstra que a configuração utilizada é robusta a este tipo de perturbação.

Inserir-se também na saída y_1 do processo um ruído gaussiano de média zero e variância 0.01. Apesar da interferência do ruído, as saídas do processo continuaram sobre os valores de referência, conforme pode ser observado nas Figuras 4.13 e 4.14.

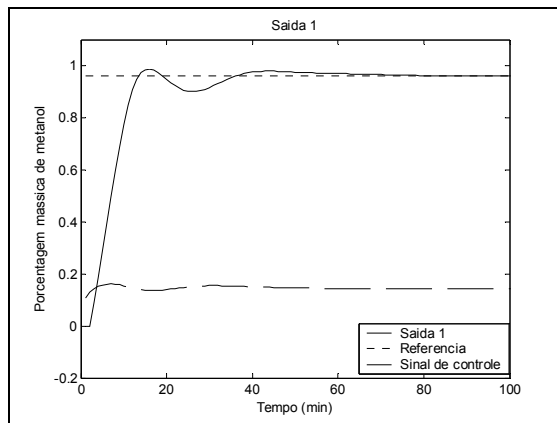


Figura 4.6- Resposta obtida y_1 , controle PID sintonizado por algoritmos genéticos.




Figura 4.7- Resposta obtida y_2 , controle PID sintonizado por algoritmos genéticos.

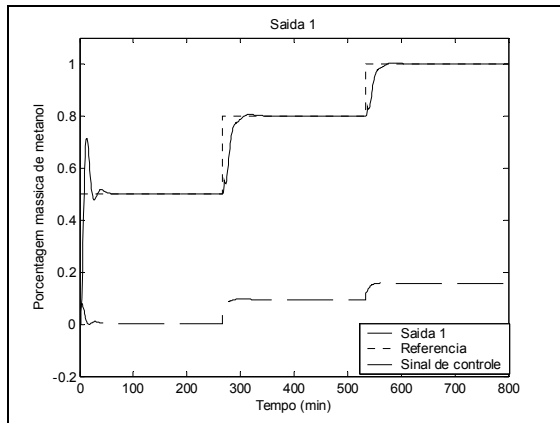


Figura 4.8- Alterações nos valores de referência, saída y1.




Figura 4.9- Alterações nos valores de referência, saída y2.

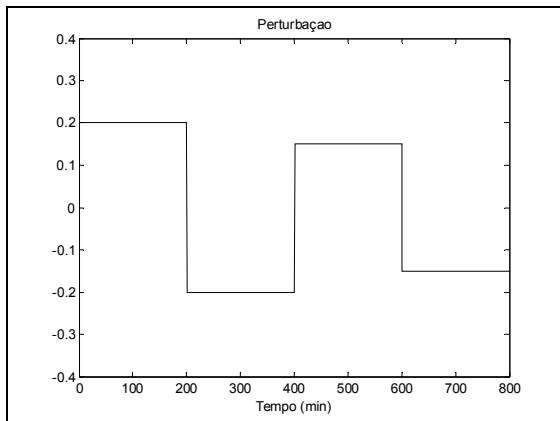


Figura 4.10- Perturbações tipo seqüência de degraus inseridas na saída y1 do processo.




Figura 4.11- Resposta obtida y1 com perturbação inserida na saída y1.




Figura 4.12- Resposta obtida y2 com perturbação inserida na saída y1.




Figura 4.13- Resposta obtida y1 com ruído inserido na saída y1.

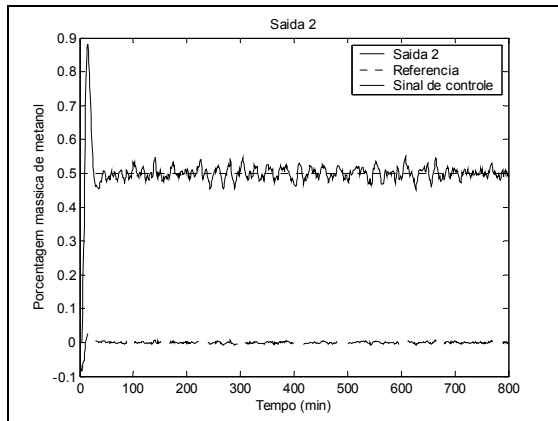


Figura 4.14- Resposta obtida y2 com ruído inserido na saída y1.

4.2.5 CONCLUSÃO

No controle da coluna de destilação Wood-Berry, a utilização de algoritmos genéticos para a sintonia dos controladores PID apresentou resultados satisfatórios. As respostas apresentadas se comparam às obtidas pelo método BLT e demonstram melhora em relação a algumas características como diminuição do sobre-sinal e das oscilações no período transitório.

Com relação às simulações distintas para controle PI e PID, a diferença no tamanho do cromossomo, de 4 para 6 genes, não comprometeu o desempenho do algoritmo genético, que encontrou o conjunto de soluções em poucas gerações.

O tempo computacional para esta simulação pode ser considerado baixo, portanto, se houvesse a necessidade de um aumento no espaço de busca utilizado, ou no número de gerações para a busca da melhor solução, isto poderia ser implementado sem comprometer o desempenho do algoritmo genético.

4.3 COLUNA DE DESTILAÇÃO DE ISOPROPANOL

A coluna de destilação extrativa industrial de Isopropanol é usada para separar água de isopropanol existentes na alimentação, utilizando como agente extrante o *glycol* que é introduzido no topo da coluna. O produto de topo é o isopropanol puro e o de fundo é o *glycol*. Gilles e Retzbach (1983) propuseram um modelo de ordem reduzida que representa os perfis de concentração e temperatura no interior desta coluna.

O modelo por representação de estado utilizado neste trabalho é apresentado abaixo.

$$x(t) = \begin{bmatrix} -30,3 & 0 & 0 & 0 \\ 0,12 * 10^{-3} & -6,02 & 0 & 0 \\ 0 & -3,77 & 0 & 0 \\ 0 & -2,80 & 0 & 0 \end{bmatrix} * x(t) + \begin{bmatrix} 6,15 * 10^5 & 0 \\ 0 & 0 \\ 0 & 3,04 \\ 0 & 0,052 \end{bmatrix} * u(t)$$

$$y(t) = \begin{bmatrix} 0 & 0 & -7,3 & 0 \\ 0 & 0 & 0 & -2,5 \end{bmatrix} * x(t) + \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix} * u(t)$$

Em dois pontos ao longo da coluna ocorrem variações acentuadas de concentração e temperatura. No primeiro ponto (Posição A), ocorre a separação entre a água e o isopropanol, e no segundo ponto (Posição B), a separação entre água e *glycol*. Estas posições são dependes das variáveis manipuladas do sistema.

Foram determinadas as quatro funções de transferência que representam o comportamento do sistema a partir das matrizes de estado apresentadas. A matriz de transferência obtida foi:

$$\begin{bmatrix} y_1(s) \\ y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{-7.1054.e^{-15}.s^3 + 2.8421.e^{-14}.s^2 + 2.031.e^3.s}{s^4 + 3.632.e.s^3 + 1.824.e^2.s^2} & \frac{-2.2192.e.s^3 - 8.0601.e^2.s^2 - 4.0479.e^3.s}{s^4 + 3.632.e.s^3 + 1.824.e^2.s^2} \\ \frac{2.2737.e^{-13}.s^2 + 5.1660.e^3.s}{s^4 + 3.632.e.s^3 + 1.824.e^2.s^2} & \frac{-1.2999.s^3 - 4.7215.e.s^2 - 2.3712.e^2.s}{s^4 + 3.632.e.s^3 + 1.824.e^2.s^2} \end{bmatrix} * \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

As variáveis controladas do processo e seus respectivos pontos de operação são:

- Posição A ($y_1(s)$):
 - Referência inicial: 0.25
 - Tempo de 2 horas: 0.50

- Posição B ($y_2(s)$):
Referência inicial: 0.50
Tempo de 4 horas: 1.00

As variáveis manipuladas do processo são:

- Taxa de vapor de aquecimento.
- Taxa de vapor lateral.

A unidade de tempo padrão é a hora.

4.3.1 ANÁLISE PRELIMINAR

Os controladores nebulosos foram inseridos no sistema sob a arquitetura de controle desacoplado conforme Figura 4.15.

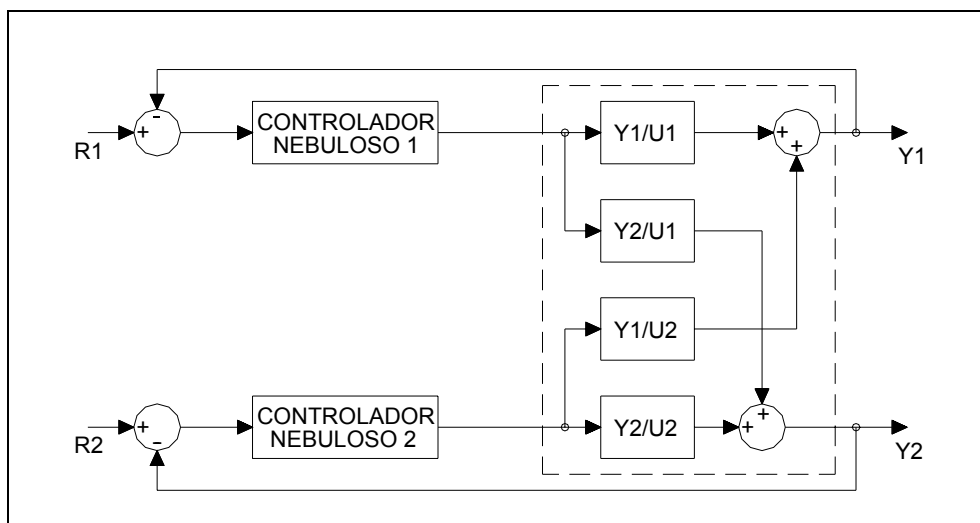


Figura 4.15- Arquitetura de controle, Coluna de Destilação Isopropanol.

Com o objetivo de comparar as respostas obtidas pelo algoritmo genético, verifica-se inicialmente o comportamento do sistema com a utilização, nos dois controladores, da base de regras padrão para controladores PD-nebulosos (HARRIS *et al.*, 1993) apresentada no capítulo 3 (Tabela 3.2), e cuja superfície de controle para este sistema pode ser observada na Figura 4.16.

Com relação à estrutura dos controladores nebulosos utilizados, cada um é composto por uma saída para atuação do sinal de controle (u) e duas entradas representadas pelas variáveis lingüísticas, erro (e), que é a diferença entre o valor de referência e a saída do processo; e variação do erro (Δe), que é a diferença entre o erro (e) no instante atual (t) e no instante anterior ($t-1$) do processo.

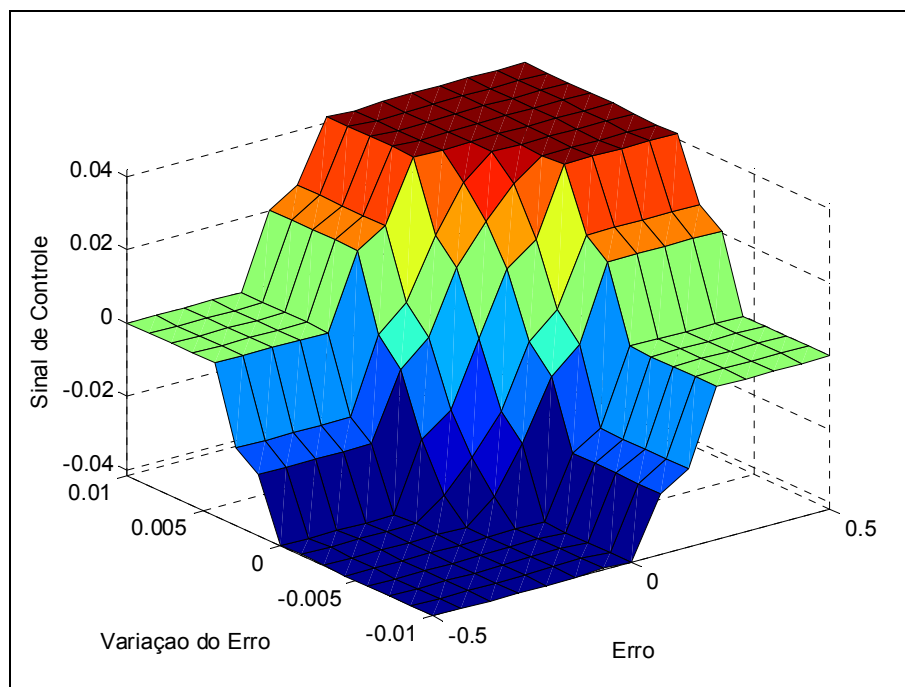


Figura 4.16- Superfície de controle gerada pela base de regras para controladores PD-nebulosos.

As variáveis lingüísticas foram compostas por cinco funções de pertinência, definidas por NG (negativo grande), NP (negativo pequeno), ZE (zero), PP (positivo pequeno) e PG (positivo grande). O universo de discurso e a disposição das funções de pertinência foram estabelecidos conforme as Figuras 4.17 a 4.22.

A máquina de inferência é do tipo Mandani, as regras aplicadas ao sistema são do tipo modo afirmativo (*modus ponens*), a agregação das regras é dada pelo operador de máximo e a implicação das regras pelo operador mínimo.




Figura 4.17- Variável lingüística *erro*, controlador 1.

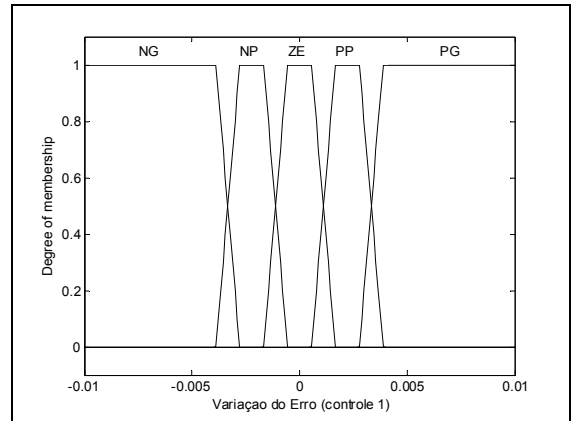


Figura 4.18- Variável lingüística *variação do erro*, controlador 1.

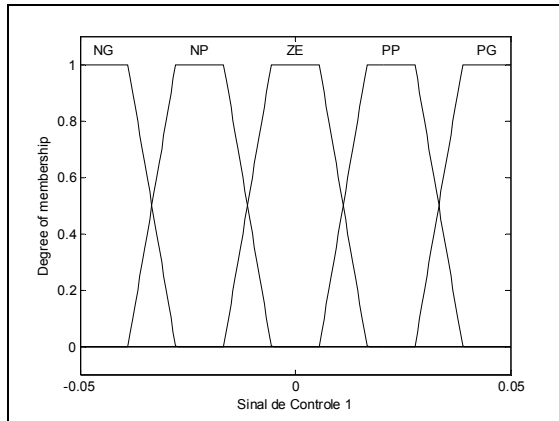


Figura 4.19- Variável lingüística *sinal de controle*, controlador 1.




Figura 4.20- Variável lingüística *erro*, controlador 2.




Figura 4.21- Variável lingüística *variação do erro*, controlador 2.




Figura 4.22- Variável lingüística *sinal de controle*, controlador 2.

As respostas do sistema com a utilização da base de regras para controlador PD-nebuloso podem ser observadas na Figuras 4.23 e 4.24, os valores de referência utilizados foram os valores finais de operação de 0,50 para a saída y_1 e 1,00 para a saída y_2 . É possível perceber que, nestas condições, o sistema apresenta um tempo de subida de aproximadamente 3,50 horas para as duas saídas e erro de estado estacionário de 6% na saída y_2 .

As respostas obtidas para os dois valores de referência que formam o ciclo de operação do sistema podem ser observadas nas Figura 4.25 e 4.26. A saída y_1 apresenta uma forte deficiência no início do ciclo, pois não segue a referência fixada no valor de 0,25 até as 2 horas iniciais do processo. Além disso, apresenta uma oscilação no momento da mudança do valor de referência da saída y_2 que decresce o sinal em até 28%. A saída y_2 apresentou melhores resultados, acompanhando os valores de referência com apenas uma pequena oscilação no momento da mudança de referência da saída y_1 , porém apresentou uma resposta lenta com tempo de subida de aproximadamente 2 horas.

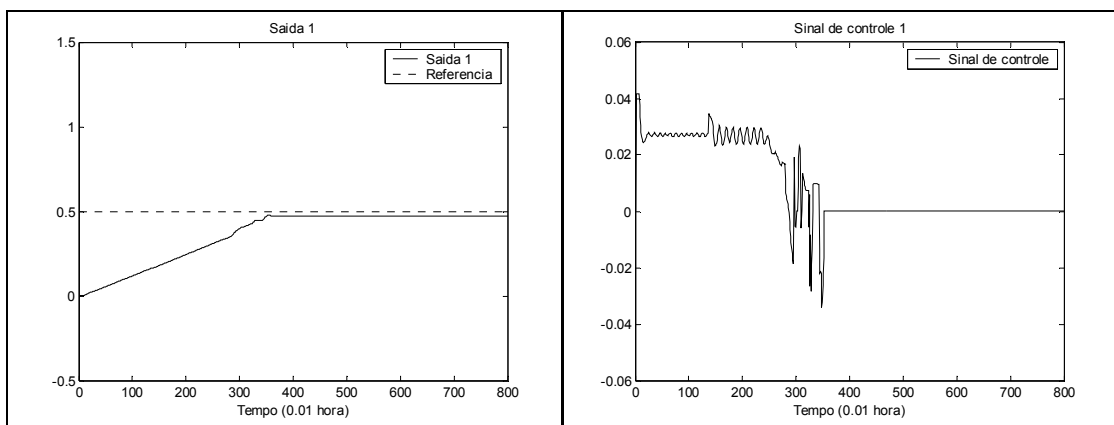


Figura 4.23- Resposta obtida y_1 para os pontos finais de operação do sistema, base de regras para controlador PD-nebuloso.




Figura 4.24- Resposta obtida y_2 para os pontos finais de operação do sistema, base de regras para controlador PD-nebuloso.

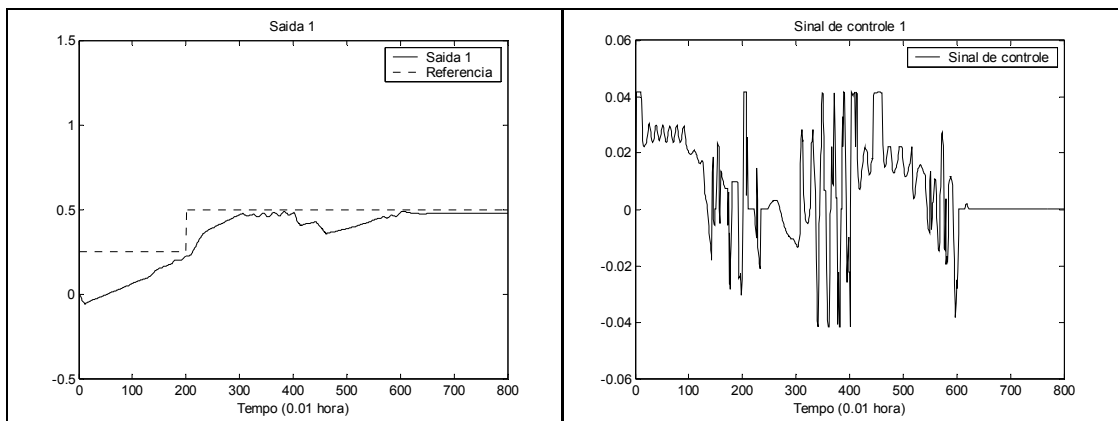


Figura 4.25- Resposta obtida y_1 para os pontos de operação do sistema, base de regras para controlador PD-nebuloso.

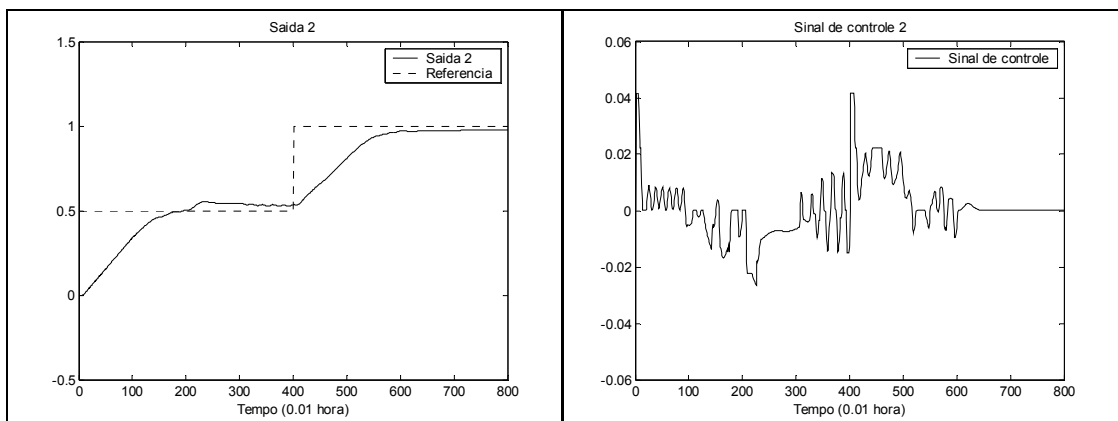


Figura 4.26- Resposta obtida y_2 para os pontos de operação do sistema, base de regras para controlador PD-nebuloso.

As respostas apresentadas nas Figuras 4.23 a 4.26 serão utilizadas para comparações posteriores com as respostas obtidas através da utilização de algoritmos genéticos para a sintonia dos controladores nebulosos. Serão efetuadas duas simulações distintas, cada uma objetivando ajustar diferentes parâmetros dos controladores nebulosos:

- Construção da base de regras (seção 4.3.2).
- Sintonia das funções de pertinência das variáveis lingüísticas (seção 4.3.3).

4.3.2 PROCESSO DE CONSTRUÇÃO DAS BASES DE REGRAS

Para a presente aplicação, foram geradas as bases de regras dos dois controladores simultaneamente a partir da utilização de algoritmos genéticos, conforme apresentado no Capítulo 3.

Nesta aplicação, o universo de discurso e a disposição das funções de pertinência apresentados nas Figuras 4.17 a 4.22 não sofrem nenhuma alteração. Portanto, o objetivo desta evolução, foi encontrar uma base de regras que se ajustasse à disposição pré-estabelecida das funções de pertinência e às características do processo, melhorando assim o desempenho do controle e as respostas do sistema obtidas anteriormente através da base de regras para controlador PD-nebuloso.

Apesar da resposta relativamente boa da saída y_2 (Figura 4.26) através da utilização da base de regras para controlador PD-nebuloso, foi necessário gerar também uma nova base de regras do controlador 2, pois, como existe um forte acoplamento entre as variáveis, alterando-se o controlador 1 através da manipulação de sua base de regras, a resposta y_2 sofrerá interferência, devendo portanto ser compensada.

4.3.2.1 CONFIGURAÇÕES DO AG

Cada cromossomo foi composto de 26 genes, que, conforme exposto no Capítulo 3, correspondem às 25 linhas da base de regras de cada controlador, necessárias para combinar cinco funções de pertinência e duas variáveis lingüísticas de entrada ($5^2 = 25$ linhas). Com relação às configurações do algoritmo genético, o tamanho da população foi definido em 500 indivíduos, taxa de mutação de 0.50, e taxa de recombinação de 0.50.

A base de regras para controlador PD-nebuloso foi incluída na população inicial, pois apresentou resultados razoáveis para esta aplicação. Desta maneira, o algoritmo genético

inicializa com uma resposta razoavelmente boa na primeira geração, que irá reproduzir suas características para outros cromossomos nas demais gerações.

Esta inclusão pode polarizar a busca, porém a introdução de conhecimento heurístico na população inicial possibilita um número de gerações menor até o encontro de soluções que satisfaçam os requisitos de controle.

4.3.2.2 RESULTADOS OBTIDOS

As bases de regras obtidas pelo algoritmo genético são apresentadas nas Tabelas 4.1 e 4.2, e as respectivas curvas bidimensionais nas Figuras 4.27 e 4.28. É possível perceber uma semelhança entre a superfície de controle da base de regras para controlador PD-nebuloso (Figura 4.16) e as superfícies de controle obtidas pelo algoritmo de busca. Isto mostra que o processo de sintonia apenas ajustou determinadas regras, mas manteve a estrutura da base do controlador PD-nebuloso.

		Variação do erro (Δe)				
		NG	NP	ZE	PP	PG
Erro (e)	NG	NG	NG	NP	NG	ZE
	NP	NG	NP	NP	NG	PP
	ZE	NP	ZE	ZE	ZE	PP
	PP	NP	PG	PP	PP	PG
	PG	ZE	PG	PP	PG	PG

		Variação do erro (Δe)				
		NG	NP	ZE	PP	PG
Erro (e)	NG	NG	NP	NG	NP	ZE
	NP	NG	NP	ZE	ZE	PP
	ZE	NG	NP	ZE	PP	PG
	PP	NP	ZE	ZE	PP	PG
	PG	ZE	PP	PG	PP	PG

Tabela 4.1- Base de regras obtida para o controlador 1. Tabela 4.2- Base de regras obtida para o controlador 2.




Figura 4.27- Superfície de controle gerada pela base de regras obtida para o controlador 1.




Figura 4.28- Superfície de controle gerada pela base de regras obtida para o controlador 2.

As respostas do sistema com os controladores nebulosos sintonizados pela metodologia apresentada podem ser observadas nas Figuras 4.29 e 4.30, os valores referência são os pontos finais de operação de 0,50 para a saída y_1 e de 1,00 para a saída y_2 . Comparativamente às respostas observadas nas Figuras 4.23 e 4.24 com a utilização da base de regras para controlador PD-nebuloso, o sistema apresentou diminuição de aproximadamente 0.5 horas no tempo de subida das duas respostas, e erro de estado estacionário de aproximadamente 3% na saída y_1 .

A melhora significativa no desempenho do controle pode ser observada na resposta para o ciclo de operação do sistema nas Figuras 4.31 e 4.32. A saída y_1 tornou-se mais rápida e se estabilizou sobre a referência de 0,25 até duas horas de processo, posteriormente, a oscilação sofrida no momento da mudança do valor de referência da saída y_2 teve amplitude e tempo de duração reduzidos quando comparados aos observados na Figura 4.25. Com relação a saída y_2 , a melhora se observa apenas na velocidade da resposta, em contrapartida, houve um aumento no erro de estado estacionário, principalmente entre os tempos de 2 e 4 horas que chega a atingir 14% do valor de referência.




Figura 4.29- Resposta obtida y_1 para os pontos finais de operação do sistema, base de regras construída por algoritmos genéticos.




Figura 4.30- Resposta obtida y_2 para os pontos finais de operação do sistema, base de regras construída por algoritmos genéticos.

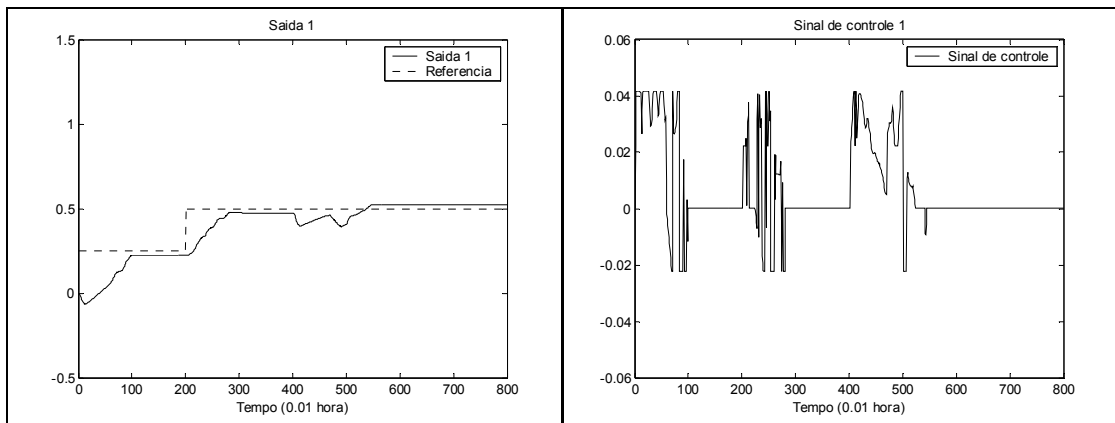


Figura 4.31- Resposta obtida y_1 para os pontos de operação do sistema, base de regras construída por algoritmos genéticos.

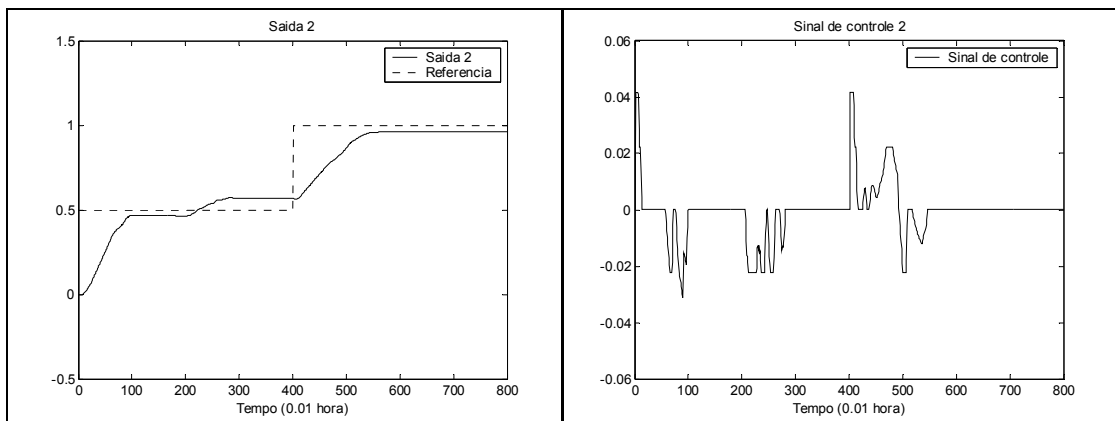


Figura 4.32- Resposta obtida y_2 para os pontos de operação do sistema, base de regras construída por algoritmos genéticos.

Para verificar o comportamento do sistema de controle frente a perturbações, aplica-se na saída y_1 do processo, sinais do tipo seqüência de degraus conforme Figura 4.33. Os resultados da resposta do sistema podem ser observados nas Figuras 4.34 e 4.35. As perturbações inseridas foram compensadas pelo sistema de controle em poucas unidades de tempo na saída y_1 , porém a resposta de y_2 demonstra a grande interferência que esta saída sofre pela influência das alterações em y_1 .

Inserir-se também na saída y_1 do processo um ruído gaussiano de média zero e variância 0.0001, as respostas podem ser observadas nas Figuras 4.36 e 4.37. É possível perceber que ruídos desta natureza causam grandes oscilações neste processo, porém o sistema de controle mantém as respostas em torno dos valores de referência.

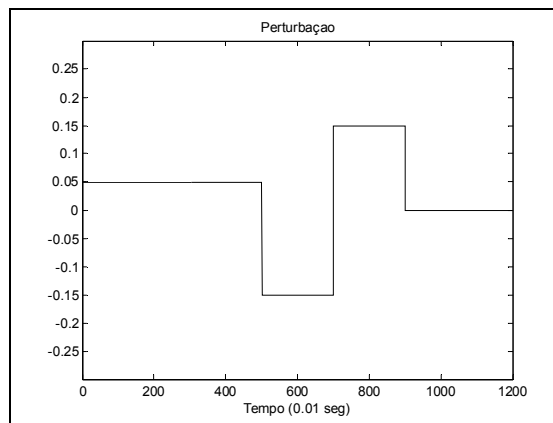


Figura 4.33- Perturbações tipo seqüência de degraus inseridas na saída y_1 do processo.




Figura 4.34- Resposta obtida y_1 com perturbação inserida na saída y_1 .




Figura 4.35- Resposta obtida y_2 com perturbação inserida na saída y_1 .

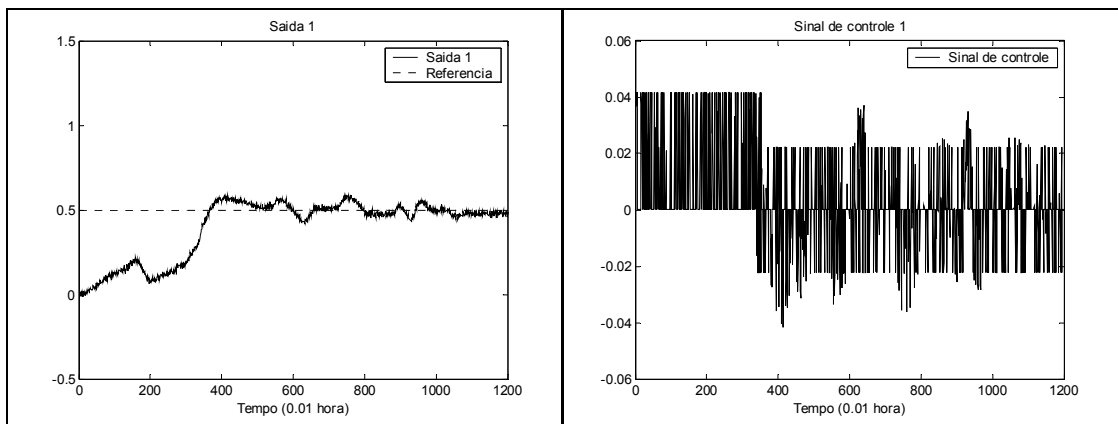


Figura 4.36- Resposta obtida y_1 com ruído inserido na saída y_1 .




Figura 4.37- Resposta obtida y_2 com ruído inserido na saída y_1 .

4.3.3 PROCESSO DE SINTONIA DAS FUNÇÕES DE PERTINÊNCIA

Diferentemente da abordagem apresentada anteriormente, na qual foi utilizada a metodologia de evolução da base de regras dos controladores nebulosos com funções de pertinência igualmente distribuídas no universo de discurso das variáveis, esta nova simulação apresenta a utilização dos algoritmos genéticos para a evolução das funções de pertinência dos controladores nebulosos com base de regras fixa, conforme apresentado no Capítulo 3.

Para os dois controladores, foi utilizada a base de regras para controlador PD-nebuloso (Tabela 3.2 e Figura 4.16), e o objetivo desta evolução foi encontrar uma distribuição das funções de pertinência que se ajustasse a esta base de regras fixada. Portanto, através da utilização de algoritmos genéticos, foram efetuados ajustes nas funções de pertinência das três variáveis lingüísticas de cada controlador simultaneamente. A simulação apenas evoluiu a disposição das funções de pertinência, o universo de discurso de cada variável foi mantido conforme Figuras 4.17 a 4.22.

4.3.3.1 CONFIGURAÇÕES DO AG

Cada cromossomo foi composto por seis conjuntos de 8 genes, totalizando 48 genes, que, conforme exposto no Capítulo 3, representam os pontos que constroem as funções de pertinência das variáveis lingüísticas de cada controlador.

A geração da população inicial foi feita de maneira aleatória, não se introduzindo nenhum indivíduo construído através de conhecimento heurístico.

Com relação às configurações do algoritmo genético, o tamanho da população foi definido em 100 indivíduos, taxa de mutação de 0.05, e taxa de recombinação de 0.10.

4.3.3.2 RESULTADOS OBTIDOS

As disposições das funções de pertinência obtidas pelo algoritmo genético são apresentadas nas Figuras 4.38 a 4.43, e as superfícies de controle geradas para os controladores 1 e 2 são apresentadas nas Figuras 4.44 e 4.45.

É possível perceber que todas as variáveis lingüísticas sofreram alterações em suas funções de pertinência quando comparadas às Figuras 4.17 a 4.22, porém, as mudanças mais significativas são observadas em apenas três variáveis lingüísticas: *variação do erro* dos controladores 1 e 2, e *senal de controle* do controlador 1.




Figura 4.38- Variável linguística *erro*, controlador 1.




Figura 4.39- Variável linguística *variação do erro*, controlador 1.




Figura 4.40- Variável linguística *sinal de controle*, controlador 1.




Figura 4.41- Variável linguística *erro*, controlador 2.




Figura 4.42- Variável linguística *variação do erro*, controlador 2.




Figura 4.43- Variável linguística *sinal de controle*, controlador 2.




Figura 4.44- Superfície de controle gerada pela base de regras do controlador 1.




Figura 4.45- Superfície de controle gerada pela base de regras do controlador 2.

As respostas do sistema com as funções de pertinência sintonizadas por algoritmos genéticos podem ser observadas nas Figuras 4.46 e 4.47, os valores referência são os pontos finais de operação de 0,50 para a saída y_1 e de 1,00 para a saída y_2 . Comparativamente às respostas observadas com a evolução das bases de regras (Figura 4.29 e 4.30), o sistema apresentou melhorias significativas com relação ao tempo de subida e ao erro de estado estacionário.

As respostas para o ciclo de operação completo são apresentadas nas Figuras 4.48 e 4.49. As saídas apresentaram um comportamento similar aos anteriormente verificados com a evolução das bases de regras (Figuras 4.31 e 4.32), porém com melhoras com relação a erro de estado estacionário.

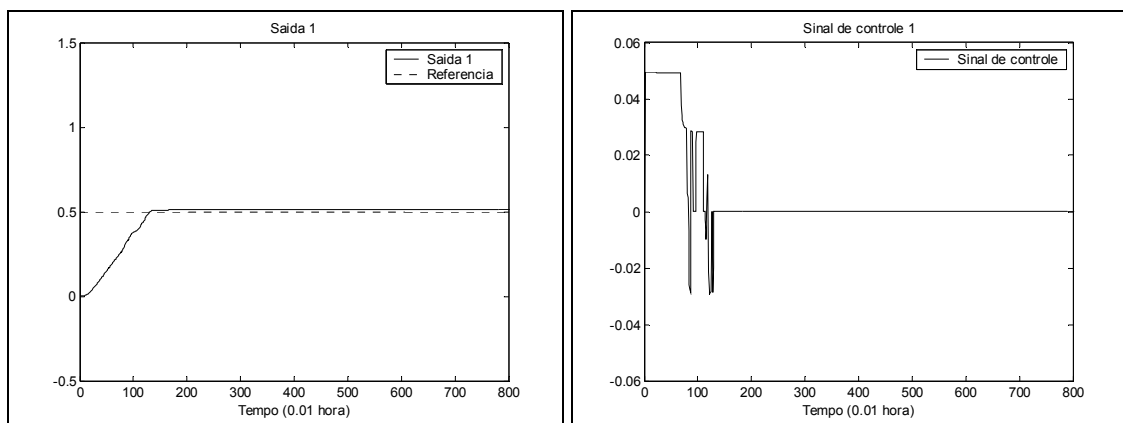


Figura 4.46- Resposta obtida y_1 para os pontos finais de operação do sistema, funções de pertinência ajustadas por algoritmos genéticos.




Figura 4.47- Resposta obtida y2 para os pontos finais de operação do sistema, funções de pertinência ajustadas por algoritmos genéticos.




Figura 4.48- Resposta obtida y1 para os pontos de operação do sistema, funções de pertinência ajustadas por algoritmos genéticos.




Figura 4.49- Resposta obtida y2 para os pontos de operação do sistema, funções de pertinência ajustadas por algoritmos genéticos.

Para comparar o comportamento desta arquitetura frente a perturbações, com relação a arquitetura anterior (evolução das bases de regras), aplica-se os mesmos sinais de perturbação tipo seqüência de degraus (Figura 4.33) e o ruído gaussiano de média zero e variância 0.0001 utilizados anteriormente. As respostas podem ser verificadas nas Figuras 4.50 a 4.53.

Comparativamente às respostas obtidas através da evolução das bases de regras (Figuras 4.34 a 4.37), a evolução das funções de pertinência apresenta resultados com uma robustez melhor frente a estas perturbações.




Figura 4.50- Resposta obtida y1 com perturbação inserida na saída y1.




Figura 4.51- Resposta obtida y2 com perturbação inserida na saída y1.

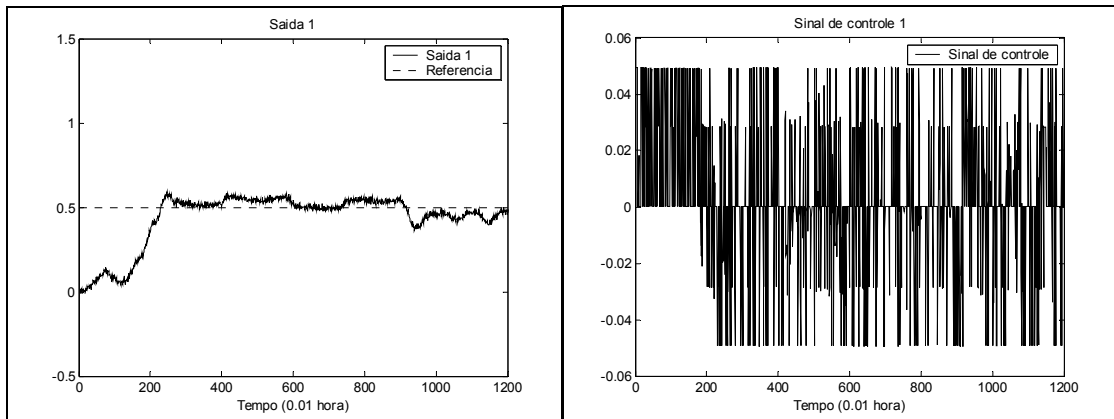


Figura 4.52- Resposta obtida y1 com ruído inserido na saída y1.




Figura 4.53- Resposta obtida y2 com ruído inserido na saída y1.

4.3.4 CONCLUSÃO

Conforme exposto no Capítulo 3, o desempenho do controlador nebuloso pode ser melhorado a partir da evolução de um de seus parâmetros principais, a base de regras e a disposição das funções de pertinência sobre o universo de discurso.

O objetivo desta seção foi apresentar isoladamente a aplicação destas duas técnicas sobre um mesmo processo para verificar o desempenho do algoritmo genético em cada condição.

A evolução da base de regras através da utilização de algoritmos genéticos apresenta dificuldades relacionadas ao tamanho da população e ao número de gerações necessárias para encontrar uma solução adequada.

Conforme apresentado anteriormente, o espaço de busca para evolução das bases de regras dos dois controladores, com a metodologia apresentada, é maior que 11 milhões.

Como o espaço de busca é grande, existe a necessidade de se trabalhar com grandes tamanhos de população e número de gerações. Assim, o tempo necessário para a avaliação destes cromossomos pode dificultar a utilização do algoritmo genético.

Portanto, o maior problema encontrado na evolução da base de regras de controladores nebulosos é cobrir de forma eficiente todo o espaço de busca sem comprometer o tempo necessário para se encontrar uma solução satisfatória.

Neste trabalho optou-se pela utilização de uma população de 500 elementos, número baixo quando comparado ao tamanho do espaço de busca, porém razoável com relação ao tempo computacional. Nesta simulação, a taxa de mutação e a taxa de recombinação foram maiores que as utilizadas nas demais simulações, com o propósito de aumentar a variabilidade genética dos cromossomos a serem avaliados dentro do número de gerações possível.

Além disto, com o objetivo de diminuir o número de gerações necessárias para alcançar uma solução que atendesse os requisitos de controle, foi incluída na população inicial uma base de regras conhecida que apresentava desempenho aceitável. Esta inclusão polarizou a busca, a solução encontrada apresentou semelhanças com a solução inserida, porém com melhor desempenho.

Simulações preliminares, sem a inclusão deste conhecimento heurístico, não geraram, dentro deste mesmo número de gerações, soluções que pudessem ser utilizadas no controle do processo.

Neste caso, considerando que possa haver uma polarização da busca, e as soluções encontradas possam apenas ser pontos locais, não se pode considerar a metodologia exposta como uma otimização global, mas apenas apresentá-la como uma ferramenta capaz de melhorar de maneira eficiente sintonias pré-estabelecidas.

A evolução das funções de pertinência dentro de universos de discursos fixos não apresenta os mesmos problemas da evolução da base de regras. O número de combinações de pontos dentro de um universo de discurso depende do número de casas decimais utilizadas. Visto que se pode considerar baixa a precisão necessária para que mudanças nas funções de pertinência gerem alterações na saída do controle, o espaço de busca torna-se pequeno. Devido a isto, para a sintonia das funções de pertinência, o tamanho da população e o número de gerações podem ser menores que os utilizados para a construção da base de regras.

Esta diferença interfere diretamente no tempo de simulação total da rotina. Com a evolução das funções de pertinência, o tempo necessário para se encontrar uma solução adequada foi praticamente cinco vezes menor que o consumido com a evolução das bases de regras.

Com relação aos resultados obtidos, é possível perceber que a metodologia de evolução das funções de pertinência apresentou resultados melhores com relação ao erro de estado estacionário e tempo de subida quando comparados aos obtidos pela evolução das bases de regras, além de uma robustez maior frente a perturbações.

4.4 PROCESSO DE CRAQUEAMENTO CATALÍTICO EM LEITO FLUIDIZADO

O modelo do processo FCC utilizado nas simulações foi o mesmo utilizado no trabalho de Prosdóssimo (2003) que teve como fonte inicial o trabalho de Moro e Odloak (1995).

As variáveis controladas do processo e seus respectivos pontos de operação são apresentados a seguir (PROSDÓSSIMO, 2003):

- Temperatura da saída do *riser* (Trx).
Referência inicial: 540° C
Tempo de 30 minutos: 543° C
Tempo de 120 minutos: 545° C
- Temperatura da fase densa do segundo estágio do regenerador (Trg2).
Referência inicial: 700° C
Tempo de 30 minutos: 702° C
Tempo de 120 minutos: 704° C
- Inventário de catalisador no vaso separador (Hra).
Referência inicial: 90 ton
Tempo de 80 minutos: 92 ton
- Pressão diferencial entre o vaso separador e o regenerador (DPr).
Referência inicial: 0,65 kgf/cm²
Tempo de 150 minutos: 0,70 kgf/cm²
- Pressão de sucção do compressor de gás úmido (Psuc).
Referência inicial: 1 kgf/cm²
Tempo de 70 minutos para 0,97 kgf/cm²

As variáveis manipuladas do processo e seus universos de atuação são brevemente descritos a seguir (PROSDÓSSIMO, 2003):

- Abertura da válvula (aTCV) controla a circulação de catalisador regenerado para o *riser*, e é utilizada para controlar sua temperatura de saída (Trx). Sua atuação também interfere na temperatura da fase densa do regenerador.
- Vazão de ar para o regenerador (Rai) controla a vazão total de ar para os dois estágios do regenerador, e é, portanto, utilizada para o controle da temperatura da fase densa do segundo estágio do regenerador (Trg2).

- Abertura da válvula (LCV) controla o inventário de catalisador no vaso separador (Hra).
- Abertura da válvula (PdCV) controla o diferencial de pressão entre o vaso separador e o regenerador (DPr).
- Abertura da válvula (PCV) controla a pressão de sucção do compressor de gás úmido (Psuc).

Maiores detalhes sobre este processo e sua modelagem podem ser encontrados nos trabalhos de Prosdóssimo (2003), Zanin (2001) e Moro e Odloak (1995).

4.4.1 ANÁLISE PRELIMINAR

O trabalho de Prosdóssimo (2003) apresenta, em uma de suas simulações, um algoritmo DMC que calcula as ações de controle que incrementam a atuação das variáveis manipuladas aTCV e Rai. As demais válvulas LCV, PdCV e PCV são manipuladas diretamente a partir de um controle regulatório composto por controladores PI. A arquitetura descrita pode ser observada na Figura 4.54.

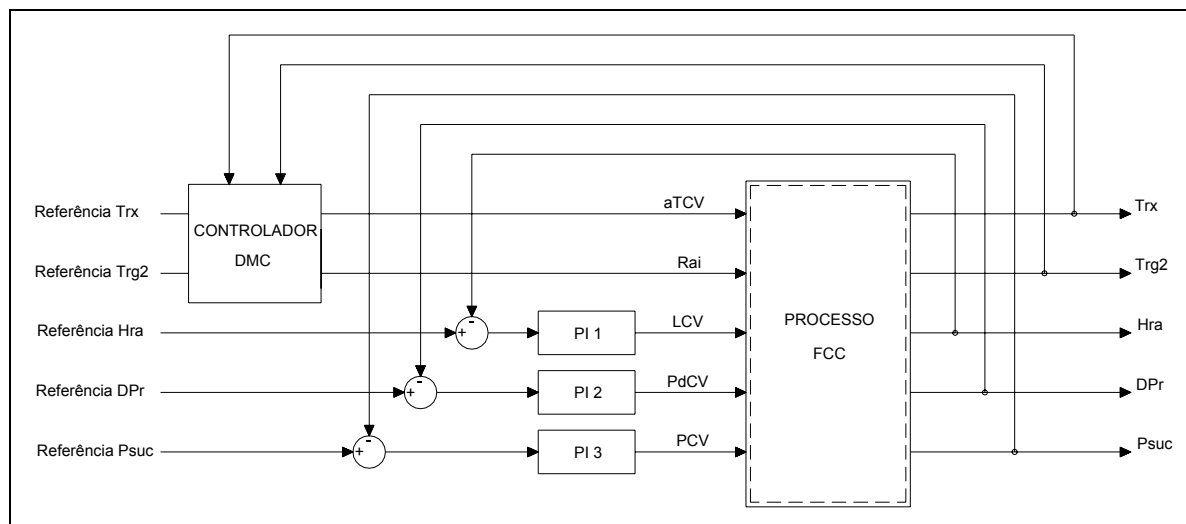


Figura 4.54- Arquitetura de controle DMC + PI.

O trabalho de Melo Jr. (2003) apresenta os valores de sintonia K_p e T_i dos controladores PI utilizados, e, segundo Zanin (2001) estes parâmetros foram calculados

através de técnicas tradicionais como *Ziegler-Nichols* (Ogata, 1998) e *Cohencon* (Stephanopoulos, 1984). As Figuras 4.55 a 4.59 apresentam as variáveis Trx, Trg2, Hra, DPr e Psuc controladas a partir dessa arquitetura. As Figuras 4.60 a 4.64 apresentam as variáveis manipuladas aTCV, Rai, LCV, PdCV e PCV.




Figura 4.55- Variável controlada Trx, controle DMC.




Figura 4.56- Variável controlada Trg2 controle DMC.




Figura 4.57- Variável controlada Hra, controle PI sintonizado por técnicas tradicionais.




Figura 4.58- Variável controlada DPr, controle PI sintonizado por técnicas tradicionais.




Figura 4.59- Variável controlada Psuc, controle PI sintonizado por técnicas tradicionais.




Figura 4.60- Variável manipulada aTCV.




Figura 4.61- Variável manipulada Rai.




Figura 4.62- Variável manipulada LCV.




Figura 4.63- Variável manipulada PdCV.




Figura 4.64- Variável manipulada PCV.

As curvas apresentadas nas Figuras 4.55 a 4.64 serão utilizadas para comparações posteriores com as respostas obtidas através de duas arquiteturas de controle distintas, sintonizadas por algoritmos genéticos:

- Composição de controladores nebulosos (aplicados a duas saídas) e controladores PIs (aplicados a três saídas do processo) (seção 4.4.2).
- Controladores PIs aplicados a cada uma das cinco saídas do processo (seção 4.4.3).

4.4.2 PROCESSO DE SINTONIA CONTROLE NEBULOSO + PI

A arquitetura de controle utilizada nesta simulação pode ser observada na Figura 4.65. O controlador DMC utilizado no trabalho de Prosdóssimo (2003) para o controle das variáveis manipuladas aTCV e Rai, foi substituído por dois controladores nebulosos. Os controladores PI para o controle das válvulas LCV, PdCV e PCV foram mantidos na arquitetura.

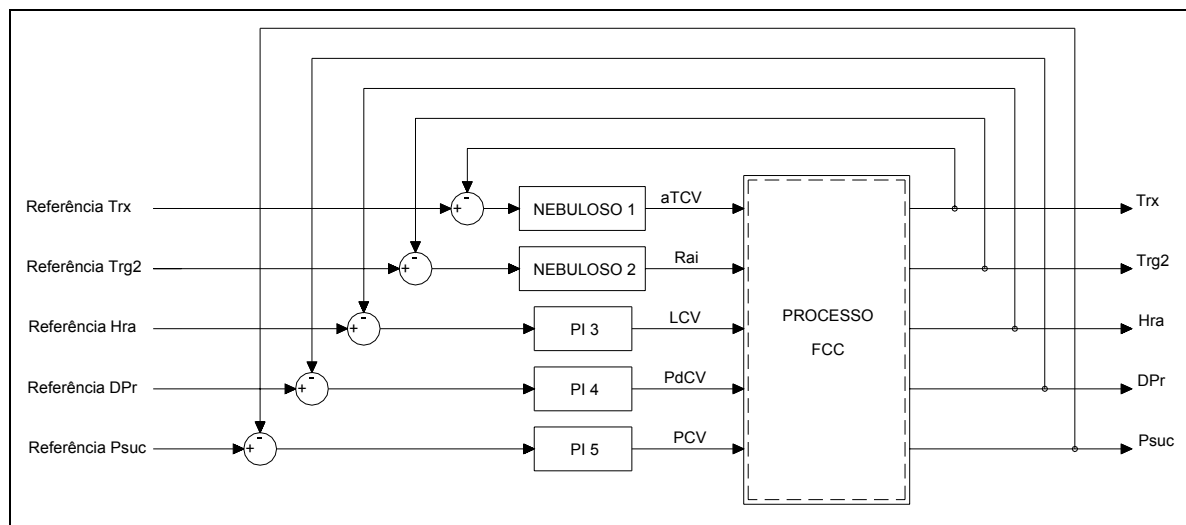


Figura 4.65- Arquitetura de controle nebuloso + PI.

A sintonia dos controladores foi efetuada em duas etapas. Primeiramente o algoritmo genético foi executado apenas para a sintonia dos controladores PI, para tanto, as variáveis manipuladas aTCV e Rai foram forçadas a manter-se dentro de valores fixos que não causassem oscilações nas demais. O processo de sintonia dos controladores PI foi feito diretamente pela busca dos melhores valores para cada um dos parâmetros K_p , e T_i de cada controlador simultaneamente através da utilização de algoritmos genéticos.

Após o estabelecimento do ajuste dos controladores PI, os controladores nebulosos tiveram suas bases de regras ajustadas através dos algoritmos genéticos. Cada controlador foi composto por uma saída para o incremento do atuador (u) e duas entradas representadas pelas variáveis lingüísticas, erro (e) e variação do erro (Δe).

O trabalho de Prosdóssimo (2003) apresenta a faixa de atuação com os limites máximos e mínimos de abertura das válvulas aTCV e Rai. As válvulas foram inicializadas com o valor médio entre estes limites, e as faixas de atuação foram utilizadas como o universo

de discurso das saídas dos controladores, que incrementam a abertura ou fechamento destes atuadores.

As variáveis linguísticas foram compostas por cinco funções de pertinência, definidas por NG (negativo grande), NP (negativo pequeno), ZE (zero), PP (positivo pequeno) e PG (positivo grande). O universo de discurso e a disposição das funções de pertinência foram estabelecidos conforme as Figuras 4.66 a 4.71.




Figura 4.66- Variável linguística *erro*, controlador 1.




Figura 4.67- Variável linguística *variação do erro*, controlador 1.




Figura 4.68- Variável linguística *incremento do atuador*, controlador 1.




Figura 4.69- Variável linguística *erro*, controlador 2.




Figura 4.70- Variável linguística variação do erro, controlador 2.




Figura 4.71- Variável linguística incremento do atuador, controlador 2.

A máquina de inferência é do tipo Mandani, as regras aplicadas ao sistema são do tipo modo afirmativo (*modus ponens*), a agregação das regras é dada pelo operador de máximo e a implicação das regras pelo operador mínimo.

O sistema foi amostrado a cada 0,001 segundos, e houve a necessidade de definição de períodos de controle diferenciados para cada controlador, pois o atraso de resposta é diferente entre as variáveis. O período de controle dos controladores nebulosos 1 e 2 foi definido em 1 iteração, dos controladores PI 3 e 5 em 40 iterações, e do controlador PI 4 em 12 iterações.

4.4.2.1 Configurações do AG

Para a sintonia dos controladores PI, foi definida a utilização de cromossomos com 6 genes, que representam diretamente os parâmetros K_{p3} , T_{i3} , K_{p4} , T_{i4} , K_{p5} , T_{i5} dos três controladores. Os genes tiveram espaços de busca diferenciados entre si, que foram determinados a partir de uma análise preliminar que objetivou eliminar ganhos que ocasionavam instabilidade no sistema. A faixa de variação de K_{p3} , e K_{p4} foi estabelecida como sendo entre $[-1$ e $1]$, a faixa de variação de K_{p5} entre $[-20$ e $20]$, e a faixa de variação de T_{i3} , T_{i4} e T_{i5} entre $[0$ e $1]$.

Para a sintonia dos controladores nebulosos, cada cromossomo foi composto de 26 genes correspondendo às 25 linhas da base de regras de cada controlador, necessárias para combinar cinco funções de pertinência e duas variáveis linguísticas de entrada.

Com relação às configurações do algoritmo genético, para ambas etapas de sintonia, o tamanho da população foi definido em 100 indivíduos, taxa de mutação de 0.05, e taxa de recombinação de 0.10.

4.4.2.2 Resultados Obtidos

A solução selecionada na primeira etapa de simulação apresentou os seguintes valores de ganho:

$$\begin{array}{ll} K_{p3} = -0.2000 & T_{i3} = 0.5161 \\ K_{p4} = -0.9500 & T_{i4} = 0.4500 \\ K_{p5} = -5.5000 & T_{i5} = 0.0400 \end{array}$$

Após a primeira etapa, com a atuação dos controles PI sobre três variáveis do processo, iniciou-se a evolução das bases de regras dos controladores nebulosos 1 e 2.

A base de regras para controlador PD-nebuloso (Tabela 3.2) foi incluída na população inicial do algoritmo genético e o processo de sintonia foi iniciado. Porém, como a característica do controle nebuloso é a avaliação das duas entradas do controlador (*erro* e *variação do erro*) para o cálculo da saída (*signal de controle*), e isto ocorre a cada instante de tempo, a simulação com a comunicação entre o *software* matlab e o C++ Builder mostrou-se demasiadamente lenta quando comparada à sintonia dos controladores PIs. Devido a este problema, o tamanho da população foi diminuído para 30 indivíduos, e a simulação foi encerrada após apenas 15 gerações.

As bases de regras obtidas pelo algoritmo genético são apresentadas nas Tabelas 4.3 e 4.4, e as respectivas curvas bidimensionais nas Figuras 4.72 e 4.73. As curvas bidimensionais encontradas se assemelham a um controle por relé multi-nível.

		Variação do erro (Δe)				
		NG	NP	ZE	PP	PG
Erro (e)	NG	NG	NG	NG	ZE	ZE
	NP	NG	NG	NG	ZE	PP
	ZE	NG	NP	ZE	PP	PG
	PP	NP	ZE	PG	PG	PG
	PG	ZE	ZE	PG	PG	PG

		Variação do erro (Δe)				
		NG	NP	ZE	PP	PG
Erro (e)	NG	NG	NP	NG	NP	ZE
	NP	NG	NG	NG	ZE	ZE
	ZE	NG	NP	ZE	PP	PG
	PP	ZE	ZE	PG	PG	PG
	PG	ZE	PP	PG	PP	PG

Tabela 4.3- Base de regras obtida para o controlador 1. Tabela 4.4- Base de regras obtida para o controlador 2.




Figura 4.72- Superfície de controle gerada pela base de regras obtida para o controlador 1.

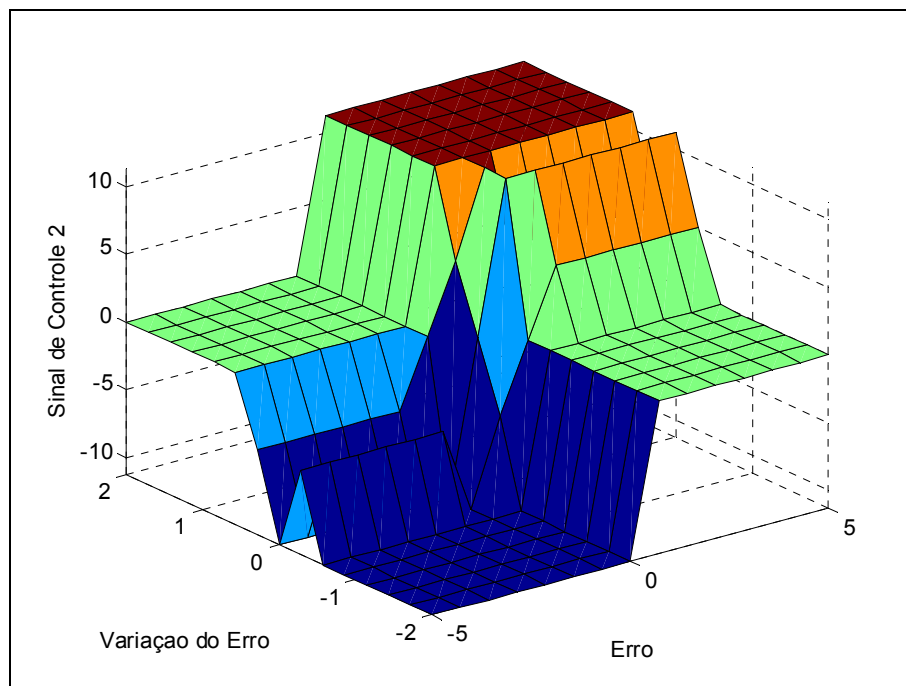


Figura 4.73- Superfície de controle gerada pela base de regras obtida para o controlador 2.

As respostas do sistema obtidas através da metodologia apresentada podem ser observadas nas Figuras 4.74 a 4.78, os valores referência são os pontos de operação apresentados no início da seção 4.4. As Figuras 4.79 a 4.83 apresentam o comportamento das variáveis manipuladas do processo.

Mesmo com números baixos de gerações e tamanho de população, é possível perceber que a solução encontrada pelo algoritmo genético possibilita que as variáveis Trx e Trg2 acompanhem os valores de referência sem oscilações de amplitude significativa, porém estas variáveis apresentam erro de estado estacionário. Este erro poderia ser compensado se o sistema de controle incorporasse uma ação integral em sua estrutura.

Comparativamente às respostas obtidas no trabalho de Prosdóssimo (2003) (Figuras 4.55 e 4.56), apesar do erro de estado estacionário, as saídas são mais estáveis, principalmente com relação à variável Trg2.

O controle PI aplicado sobre os atuadores das variáveis controladas Hra, DPr e Psuc, apresentou desempenho satisfatório. Quando se compara os resultados obtidos com os apresentados no trabalho de Prosdóssimo (2003) (Figuras 4.57 a 4.59), verifica-se uma similaridade entre as respostas, porém uma melhora nas variáveis Hra e Psuc com relação a oscilações.




Figura 4.74- Variável controlada Trx, controle nebuloso sintonizado por algoritmos genéticos.




Figura 4.75- Variável controlada Trg2, controle PI sintonizado por algoritmos genéticos.




Figura 4.76- Variável controlada Hra, controle nebuloso sintonizado por algoritmos genéticos.




Figura 4.77- Variável controlada DPr, controle PI sintonizado por algoritmos genéticos.




Figura 4.78- Variável controlada Psuc, controle PI sintonizado por algoritmos genéticos.




Figura 4.79- Variável manipulada aTCV.




Figura 4.80- Variável manipulada Rai.




Figura 4.81- Variável manipulada LCV.




Figura 4.82- Variável manipulada PdCV.




Figura 4.83- Variável manipulada PCV.

Mesmo a sintonia do controlador nebuloso não sendo satisfatória por apresentar erro de estado estacionário em suas variáveis, verifica-se a estabilidade do sistema de controle frente a perturbações de carga.

Para esta finalidade, foram fixados os valores de referência das variáveis manipuladas em $Trx = 540^\circ \text{ C}$, $Trg2 = 700^\circ \text{ C}$, $Hra = 90 \text{ ton}$, $DPr = 0.65 \text{ kgf/cm}^2$, $Psuc = 1 \text{ kgf/cm}^2$, e aplicou-se perturbações na variável de vazão de carga Rtf (PROSDÓSSIMO, 2003), conforme a Figura 4.84.

As respostas do sistema frente a este tipo de perturbação podem ser observadas nas Figuras 4.85 a 4.89, e o comportamento das variáveis manipuladas nas Figuras 4.90 a 4.94. As oscilações ocorridas não apresentaram valor de amplitude elevado e o sistema de controle rapidamente conduziu as respostas novamente aos seus valores de referência. Isto mostra que a arquitetura de controle é robusta para perturbações desta natureza.




Figura 4.84- Perturbação: degraus na vazão de carga.




Figura 4.85- Variável controlada Trx, perturbação na vazão de carga.




Figura 4.86- Variável controlada Trg2, perturbação na vazão de carga.




Figura 4.87- Variável controlada Hra, perturbação na vazão de carga.




Figura 4.88- Variável controlada DPp, perturbação na vazão de carga.




Figura 4.89- Variável controlada PCV, perturbação na vazão de carga.




Figura 4.90- Variável manipulada aTCV, perturbação na vazão de carga.




Figura 4.91- Variável manipulada Rai, perturbação na vazão de carga.




Figura 4.92- Variável manipulada LCV, perturbação na vazão de carga.




Figura 4.93- Variável manipulada PdCV, perturbação na vazão de carga.




Figura 4.94- Variável manipulada PCV, perturbação na vazão de carga.

Para verificar o comportamento do sistema de controle frente à ruídos de medição, aplicou-se sobre a saída Trx um ruído de amplitude variável entre $[+0,00005\%$ e $-0,00005\%$] de seu valor de saída. Os resultados obtidos podem ser observados nas Figuras 4.95 a 4.99, e o comportamento das variáveis manipuladas nas Figuras 4.100 a 4.104. Apesar da amplitude do ruído ser pequena e pouco percebida visualmente na resposta da variável Trx, é possível perceber as influências sobre a variável Trg2 que apresentou erro de estado estacionário um pouco maior que o verificado anteriormente (Figura 4.75) e oscilações maiores entre o tempo de 0 a 150 minutos. A variável DPr também apresentou maior amplitude de oscilações neste mesmo período de tempo quando comparada a resposta obtida sem o ruído (Figura 4.77). Apesar destas interferências, as saídas mantiveram-se sobre os valores de referência. Porém, em ensaios preliminares foi verificado que, um ruído com amplitude um pouco maior que a utilizada levam a variável Trg2 a valores totalmente fora de seus pontos de operação.




Figura 4.95- Variável controlada Trx, ruído inserido na variável Trx.




Figura 4.96- Variável controlada Trg2, ruído inserido na variável Trx.




Figura 4.97- Variável controlada Hra, ruído inserido na variável Trx.




Figura 4.98- Variável controlada DPr, ruído inserido na variável Trx.

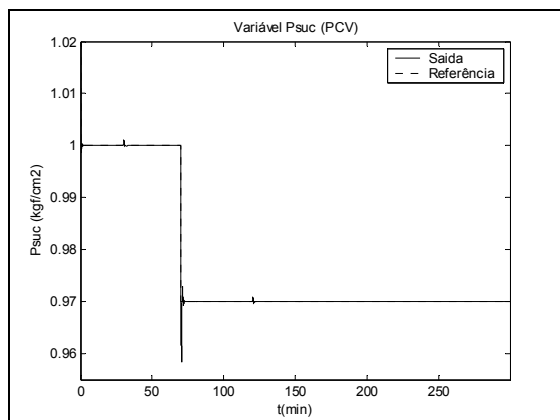


Figura 4.99- Variável controlada Psuc, ruído inserido na variável Trx.




Figura 4.100- Variável manipulada aTCV, ruído inserido na variável Trx.




Figura 4.101- Variável manipulada Rai, ruído inserido na variável Trx.




Figura 4.102- Variável manipulada LCV, ruído inserido na variável Trx.




Figura 4.103- Variável manipulada PdCV, ruído inserido na variável Trx.




Figura 4.104- Variável manipulada PCV, ruído inserido na variável Trx.

4.4.3 PROCESSO DE SINTONIA CONTROLE PI

Uma segunda simulação foi efetuada com o objetivo de se avaliar o algoritmo genético para a procura dos parâmetros de sintonia dos cinco controladores PI simultaneamente. A arquitetura de controle é apresentada na Figura 4.105.

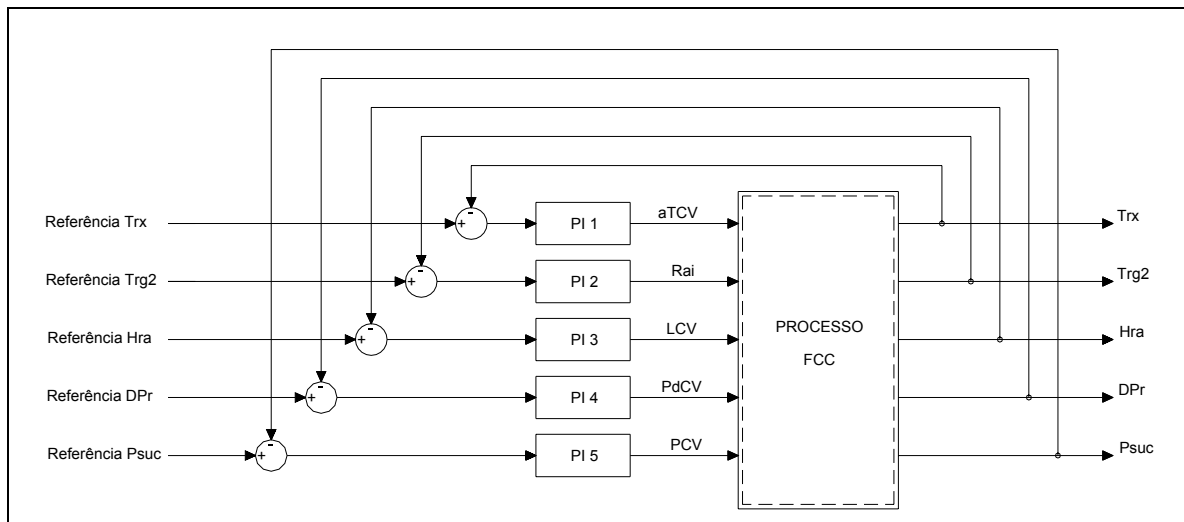


Figura 4.105- Arquitetura de controle PI, processo FCC.

O processo de sintonia dos controladores PI foi feito diretamente pela busca de melhores valores para cada um dos parâmetros K_p , e T_i de cada controlador simultaneamente através da utilização de algoritmos genéticos.

O sistema foi amostrado a cada 0,001 segundos, o período de controle dos controladores 1 e 2 foi definido em 1 interação, dos controladores 3 e 5 em 40 interações, e do controlador 4 em 12 interações.

4.4.3.1 Configurações do AG

Para a sintonia dos controladores PI, foi definida a utilização de cromossomos com 10 genes, que representam diretamente os parâmetros K_{p1} , T_{i1} , K_{p2} , T_{i2} , K_{p3} , T_{i3} , K_{p4} , T_{i4} , K_{p5} , T_{i5} dos cinco controladores. Os genes tiveram espaços de busca diferenciados entre si, a faixa de variação de K_{p1} , K_{p3} , K_{p4} , foi determinada como sendo entre $[-1$ e $1]$, a faixa de variação de K_{p2} e K_{p5} entre $[-20$ e $20]$, e a faixa de variação de T_{i1} , T_{i2} , T_{i3} , T_{i4} , T_{i5} entre $[0$ e $1]$.

Com relação às configurações do algoritmo genético, o tamanho da população foi definido em 200 indivíduos, taxa de mutação de 0.05, e taxa de recombinação de 0.10.

4.4.3.2 Resultados Obtidos

A solução encontrada pelo algoritmo genético apresentou valores de ganho para os controladores 3, 4 e 5 muito próximos dos encontrados na seção 4.4.2, portanto, optou-se por manter os mesmos valores de sintonia encontrados anteriormente para estes controladores, conforme apresentado abaixo:

$K_{p1} = 0.0449$	$Ti_1 = 0.4550$
$K_{p2} = 15.070$	$Ti_2 = 0.9783$
$K_{p3} = -0.2000$	$Ti_3 = 0.5161$
$K_{p4} = -0.9500$	$Ti_4 = 0.4500$
$K_{p5} = -5.5000$	$Ti_5 = 0.0400$

As respostas do sistema com os controladores PI sintonizados pela metodologia apresentada podem ser observadas nas Figuras 4.106 a 4.110, os valores referência são os pontos de operação apresentados no início da seção 4.4. O comportamento das variáveis manipuladas pode ser observado nas Figuras 4.111 a 4.115.

A sintonia efetuada pelos algoritmos genéticos estabilizou o sistema e as respostas das variáveis são comparáveis às apresentadas por Prosdóssimo (2003) (Figuras 4.55 a 4.59), com apenas algumas diferenças. As respostas das variáveis Trx e DPr apresentaram oscilações com amplitude maior que as apresentadas pelo sistema de Prosdóssimo (2003), e as variáveis Trg2, Hra e Psuc apresentaram melhorias em relação a oscilações.




Figura 4.106- Variável controlada Trx, controle PI sintonizado por algoritmos genéticos.



Figura 4.107- Variável controlada Trg2, controle PI sintonizado por algoritmos genéticos.




Figura 4.108- Variável controlada Hra, controle PI sintonizado por algoritmos genéticos.




Figura 4.109- Variável controlada DPPr, controle PI sintonizado por algoritmos genéticos.




Figura 4.110- Variável controlada Psuc, controle PI sintonizado por algoritmos genéticos.




Figura 4.111- Variável manipulada aTCV.




Figura 4.112- Variável manipulada Rai.




Figura 4.113- Variável manipulada LCV.




Figura 4.114- Variável manipulada PdCV.




Figura 4.115- Variável manipulada PCV.

Para verificar a robustez do sistema de controle frente a perturbações de carga, efetua-se o mesmo teste utilizado na arquitetura anterior (seção 4.4.2), provocando perturbações na variável de vazão de carga R_{tf} (PROSDÓSSIMO, 2003), conforme a Figura 4.84.

As respostas do sistema frente a este tipo de perturbação podem ser observadas nas Figuras 4.116 a 4.120, e o comportamento das variáveis manipuladas nas Figuras 4.121 a 4.125. A arquitetura de controle se mostrou robusta a este tipo de perturbação. As oscilações ocorridas não apresentaram valor de amplitude elevado e o sistema de controle rapidamente conduziu as respostas novamente aos valores de referência. Porém, comparativamente às respostas obtidas pela arquitetura anterior (seção 4.4.2), a variável Trx apresentou amplitude de oscilação maior.




Figura 4.116- Variável controlada Trx , perturbação na vazão de carga.




Figura 4.117- Variável controlada $Trg2$, perturbação na vazão de carga.




Figura 4.118- Variável controlada Hra, perturbação na vazão de carga.




Figura 4.119- Variável controlada DPr, perturbação na vazão de carga.




Figura 4.120- Variável controlada Psuc, perturbação na vazão de carga.




Figura 4.121- Variável manipulada aTCV, perturbação na vazão de carga.




Figura 4.122- Variável manipulada Rai, perturbação na vazão de carga.




Figura 4.123- Variável manipulada LCV, perturbação na vazão de carga.




Figura 4.124- Variável manipulada PdCV, perturbação na vazão de carga.




Figura 4.125- Variável manipulada PCV, perturbação na vazão de carga.

Para verificar o comportamento do sistema de controle frente à ruídos de medição, aplica-se sobre a saída Trx um ruído de amplitude variável entre $[+0,00005\%$ e $-0,00005\%$] de seu valor de saída, o mesmo aplicado na arquitetura anterior (seção 4.4.2).

Os resultados obtidos podem ser observados nas Figuras 4.126 a 4.130, e o comportamento das variáveis manipuladas nas Figuras 4.131 a 4.135. As variáveis Trg2 e DPr tiveram um acréscimo na amplitude das oscilações entre os tempos de 0 a 150 minutos, este acréscimo é maior que o verificado na arquitetura anterior (seção 4.4.2), o que demonstra que os controladores PI são um pouco menos robustos para este tipo de interferência que os controladores nebulosos para este sistema.

Conforme verificado na arquitetura anterior, ruídos com amplitudes maiores levaram a variável Trg2 a valores distantes do seu ponto de operação.




Figura 4.126- Variável controlada Trx, ruído inserido na variável Trx.




Figura 4.127- Variável controlada Trg2, ruído inserido na variável Trx.




Figura 4.128- Variável controlada Hra, ruído inserido na variável Trx.




Figura 4.129- Variável controlada DPr, ruído inserido na variável Trx.




Figura 4.130- Variável controlada Psuc, ruído inserido na variável Trx.




Figura 4.131- Variável manipulada aTCV, ruído inserido na variável Trx.




Figura 4.132- Variável manipulada Rai, ruído inserido na variável Trx.




Figura 4.133- Variável manipulada LCV, ruído inserido na variável Trx.




Figura 4.134- Variável manipulada PdCV, ruído inserido na variável Trx.




Figura 4.135- Variável manipulada PCV, ruído inserido na variável Trx.

4.4.4 CONCLUSÕES

No controle do processo FCC, a utilização de algoritmos genéticos para a sintonia dos controladores PI apresentou resultados satisfatórios. As respostas apresentadas se comparam às obtidas com controladores preditivos e demonstram a possibilidade de sintonia de três e cinco controladores simultaneamente em simulações de plantas industriais.

O tempo necessário para a obtenção desta solução pode ser considerado razoável, pois, em alguns casos, através de técnicas tradicionais ou por tentativa e erro, o tempo para a consolidação de uma resposta adequada pode ser parecido.

A pouca robustez frente a ruídos demonstra que outros tipos de controladores devem ser utilizados ou associados a estes, mas as simulações apresentadas visaram apenas demonstrar a eficiência da metodologia de sintonia conjunta dos parâmetros de diversos controladores utilizados no processo, a discussão de qual tipo de controle seria mais adequado para o sistema em questão, não faz parte da nossa proposta.

Portanto, com os resultados apresentados pode-se concluir que a utilização de algoritmos genéticos para a procura dos parâmetros de sintonia de diversos controladores PID simultaneamente é uma alternativa eficiente que pode ser aplicada a plantas com instabilidades e não linearidades conforme a utilizada nesta simulação.

A sintonia dos controladores nebulosos foi efetuada com um número menor de gerações devido ao tempo computacional elevado para a simulação desta planta, porém mesmo com poucas gerações do algoritmo genético, foi possível encontrar uma base de regras que se adaptasse ao processo.

5.1 COMENTÁRIOS FINAIS

A sintonia de diversos controladores constitui um desafio aos engenheiros de processo e operadores, uma vez que ela depende de um completo conhecimento das plantas, que muitas vezes são complexas, e que podem possuir variáveis com fortes interações entre si, além de não linearidades e de objetivos de controle conflitantes.

O objetivo principal deste trabalho foi a implementação de uma metodologia de sintonia automática de controladores descentralizados em sistemas multivariáveis através do uso de algoritmos genéticos. A maior vantagem desta abordagem é que um sistema de controle multivariável, controlado através de várias malhas independentes, pode ter todos seus controladores ajustados de forma unificada.

Foram selecionados dois tipos de controladores para a validação da metodologia, controladores PID e controladores PD-nebulosos.

A metodologia aplicada aos controladores PID apresentou desempenho muito satisfatório. A sintonia efetuada na Coluna de Destilação Wood-Berry apresentou resultados melhores que os obtidos por métodos tradicionais. O tempo de simulação necessário para encontrar a solução é considerado aceitável, o que reforça a viabilidade de utilização desta técnica para a sintonia destes tipos de controladores.

A metodologia aplicada aos controladores PD-nebulosos também apresentou desempenho satisfatório.

A Coluna de Destilação de Isopropanol teve seus controladores nebulosos sintonizados de forma adequada, sendo pela evolução das bases de regras, ou pela evolução das funções de pertinência das variáveis lingüísticas. Porém, a evolução das funções de pertinência apresentou respostas melhores com relação ao erro de estado estacionário, velocidade e robustez frente a perturbações.

O Processo de Craqueamento Catalítico em Leito Fluidizado, por ser um processo com maior número de variáveis e apresentar uma modelagem próxima da existente na indústria de petróleo, apresenta um tempo de simulação maior que os dois primeiros processos utilizados para a validação da proposta. Este tempo interferiu no desempenho do

algoritmo genético para a sintonia de controladores PD-nebulosos, pois apenas foi possível efetuar um baixo número de gerações. Apesar disto, as bases de regras encontradas se adaptaram às características do processo, os valores de referência foram seguidos de maneira eficaz, porém as variáveis controladas apresentaram erro de estado estacionário devido a não utilização de ação integral nos controladores.

A segunda simulação efetuada neste processo, com a utilização de somente controladores PI, forneceu valores de sintonia com resultados considerados muito bons com relação ao acompanhamento de referência pelas variáveis controladas.

Quanto à robustez do sistema de controle frente a perturbações neste processo, as duas arquiteturas, controle nebuloso + PI e controle PI, apresentaram características parecidas. Perturbações de carga foram compensadas de maneira satisfatória, porém ruídos de pequena amplitude interferiram no comportamento das variáveis Trx e Trg2.

Outras abordagens que utilizam diferentes tipos de controladores, como o DMC apresentado no trabalho de Prosdóssimo (2003), trazem resultados melhores para o controle destas duas variáveis, porém o objetivo deste trabalho não é a discussão do melhor tipo de controle para o sistema utilizado e sim o estudo da eficiência da metodologia de sintonia conjunta dos parâmetros dos diversos controladores utilizados no processo.

Com este conjunto de informações é possível concluir que a metodologia apresentada traz bons resultados e pode ser estendida a outros tipos de controladores e processos.

5.2 CONTRIBUIÇÕES

A principal contribuição deste trabalho foi o desenvolvimento de uma metodologia eficiente de sintonia conjunta de diversos controladores utilizados em um processo industrial. Esta sintonia simultânea otimiza soluções, pois considera as influências de cada variável do processo sobre as demais, o que é difícil de se implementar quando a sintonia é feita isoladamente em cada controlador através do uso de técnicas tradicionais.

A segunda contribuição foi a apresentação de uma função de avaliação que alia diferentes critérios de desempenho, baseados no erro quadrático e na variância mínima dos sinais de saída e de controle, que possibilita uma avaliação mais refinada das soluções pelo algoritmo genético.

A última contribuição foi a sugestão de utilização de uma casta elitista mais aprimorada, que além de garantir a transmissão de bons elementos para a geração seguinte, tem a função de manter o conjunto das melhores soluções obtidas durante todas as evoluções, o que possibilita flexibilidade e opção de escolha ao operador.

5.3 TRABALHOS FUTUROS

Os trabalhos futuros são sugeridos com o objetivo de complementação e melhoria da metodologia apresentada.

- Estudo aprofundado sobre as diferenças de resultados e de desempenho do algoritmo genético com relação ao ajuste da base de regras e das funções de pertinência de controladores nebulosos.

- Estudo de melhoria da representação cromossômica da base de regras de controladores nebulosos, incluindo simplificações com o objetivo de diminuir o número de parâmetros de procura do algoritmo genético, e melhorar seu desempenho em processos de grande porte.

- Para o ajuste das funções de pertinência de controladores nebulosos, estudo de inclusão de um fator que atue sobre os limites do universo de discurso, objetivando um ajuste fino destes valores, possibilitando uma representação completa das variáveis lingüísticas do processo.

- Aplicação da metodologia de sintonia conjunta de controladores nebulosos descentralizados em processos multivariáveis, a partir da evolução simultânea das bases de regras e das funções de pertinência das variáveis destes controladores.

- Aplicação da metodologia de sintonia conjunta de controladores descentralizados em processos multivariáveis com a utilização de outros tipos de controle.

- Testes exaustivos na função de avaliação.

- Apresentação de um conjunto de soluções obtido com a utilização da casta elitista conforme apresentada neste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABILOV, A. G., ZEYBEK, Z., TUZUNALP, O., TELATAR, Z. *Fuzzy temperature control of industrial refineries furnaces through combined feedforward/feedback multivariable cascade systems*. Chemical Engineering and Processing, v. 41, pp. 87–98, 2002.
- AFZALIAN, A., LINKENS, D. A. *Training of neurofuzzy power system stabilisers using genetic algorithms*. Electrical Power and Energy Systems, v. 22, pp. 93-102, 2000.
- ALTINTEN, A., ERDOGAN, S., HAPOGLU, H., ALPBAZ, M. *Control of a polymerization reactor by fuzzy control method with genetic algorithm*. Computers and Chemical Engineering, v. 27, pp. 1031-1040, 2003.
- ARRUDA, L. V. R., NAGAY, E. Y. *Automatic generation of fuzzy models by genetic algorithms*. 15th IFAC World Congress, Barcelona, 2002.
- ARSLAN, A., KAYA, M. *Determination of logic membership functions using genetic algorithms*. Fuzzy Sets and Systems, 118, pp. 297-306, 2001.
- ASTRÖM, K. J., WITTENMARK B. *Adaptive Control*, 2nd ed. USA: Addison – Wesley, 1995.
- ASTRÖM, K. J., HÄGGLUND, T. *The future of PID control*. Control Engineering Practice 9, pp. 1163–1175, 2001.
- ASTRÖM, K. J., HÄGGLUND, T. *Revisiting the Ziegler–Nichols step response method for PID control*. Journal of Process Control, v. 14, pp. 635–650, 2004.
- AZEVEDO, F. M. *Algoritmos genéticos em redes neurais artificiais*. V Escola de Redes Neurais, Conselho Nacional de Redes Neurais, pp. c91-c121, 1999.
- BANDYOPADHYAY, R., CHAKRABORTY, U. K., PATRANABIS, D. *Autotuning a PID controller: a fuzzy-genetic approach*. Journal of Systems Architecture, v.47, pp. 663-673, 2001.
- BLASCO, X., MARTÍNEZ, M., SANCHIS, J., SENENT, J. *Model based predictive control using genetic algorithms. Application to a greenhouse climate control*. In Connectionist Models of Neurons, Learning Processes, and Artificial Intelligence, 6th International Work Conference on Artificial and Natural Neural Network IWANN2001, LNCS 2084, pp. 457-465, Granada, 2001.
- BLICKLE, T., THIELE, L. *A Comparison of Selection Schemes used in Genetic Algorithms*. Report n. 11, Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology, Zurich, 1995.

- CAMPOS, M. M., SAITO, K. *Sistemas inteligentes em controle e automação de processos*. Ciência Moderna, Rio de Janeiro, 2004.
- CHAN, P. T., XIE, W. F., RAD, A. B. *Tuning of fuzzy controller for an open-loop unstable system: a genetic approach*. Fuzzy Sets and Systems, v. 111, pp. 137-152, 2000.
- CHEN, W. C., CHANG, N. B., CHEN, J. C. *GA-based fuzzy neural controller design for municipal incinerators*. Fuzzy Sets and Systems 129, pp. 343-369, 2002.
- CHEN, L. H., CHIANG, C. H. *An intelligent control system with a multi-objective self-exploration process*. Fuzzy Sets and Systems 143, pp. 275-294, 2004.
- CHIANG, C. L., SU, C. T. *Tracking control of induction motor using fuzzy phase plane controller with improved genetic algorithm*. Electric Power Systems Research, 2004.
- CHIOU, Y. C., LAN, L. W. *Genetic fuzzy logic controller: an iterative evolution algorithm with new encoding method*. Fuzzy Sets and Systems, v. 152, pp. 617-635, 2005.
- COELHO, A. A. R. *Controle adaptativo para processos multivariáveis: aspectos teóricos e simulação*. Tese de doutorado, Universidade de Campinas, Campinas, 1991.
- COELHO, L. S., COELHO, A. A. R. *Algoritmos evolutivos em identificação e controle de processos: uma visão integrada e perspectivas*. SBA Controle & Automação, v. 10, n. 01, 1999.
- DARWIN, C. *On the origin of the species*. John Murray, London, 1859.
- FABRO, J. A. *Uma abordagem neuro-nebulosa para controle preditivo de processos multi-estágios*. Tese de doutorado, Centro Federal de Educação Tecnologia do Paraná – Cefet-PR, Curitiba, 2003.
- FABRO, J. A., ARRUDA, L. V. R. *Uma abordagem baseada em técnicas da inteligência computacional para o controle de processos multi-variáveis*. XV Congresso Brasileiro de Automática (CBA), Gramado, RS, 2004.
- GILLES, E. D., RETZBACH, B. *Reduced models and control of distillation columns with sharp temperature profiles*. IEEE Transactions on Automatic Control, vol. ac-28, n.5, 1983.
- GOLDBERG, D. E. *Genetic algorithms in search, optimization, and machine learning*. Adison-Wesley. Ann Arbor, 1989.
- GÜROCAK, H. B. *A genetic-algorithm-based method for tuning fuzzy logic controllers*. Fuzzy Sets and Systems, 108, pp. 39-47, 1999.
- HARRIS, C. J., MOORE, C. G., BROWN, M. *Intelligent Control: Aspects of Fuzzy Logic and Neural Nets*, World Scientific Co., Singapore, 1993.

- HERRERO, J. M., BLASCO, X., MARTÍNEZ, M., SALCEDO, J. V. *Optimal PID tuning with genetic algorithms for non-linear process models*. In 15th World Congress IFAC, Barcelona, 2002.
- HERREROS, A., BAEYENS, E., PERÁN, J. R. *MRCO: a genetic algorithm for multiobjective robust control design*. Engineering Applications of Artificial Intelligence, v. 15, pp. 285–301, 2002.
- HOLLAND, J. H. *Adaptation in natural and artificial systems*. The University of Michigan Press, Ann Arbor, 1975.
- HOMAIFAR, A., MCCORMICK, V. E. *Simultaneous design of membership functions and rule sets for fuzzy controllers using genetic algorithms*. IEEE Trans. On Fuzzy Systems, v. 3, n. 2, pp. 129-139, 1995.
- KIGUCHI, K., WATANABE, K., FUKUDA, T. *Generation of efficient adjustment strategies for a fuzzy-neuro force controller using genetic algorithms – application to robot force control in an unknown environment*. Information Sciences, v. 145, pp. 113-126, 2002.
- KITSIOS, I., PIMENIDES, T. *H_{∞} controller design for a distillation column using genetic algorithms*. Mathematics and Computers in Simulation, v. 60, pp. 357–367, 2002.
- LAST, M. EYAL, S. *A fuzzy-based lifetime extension of genetic algorithms*. Fuzzy Sets and Systems, v. 149, pp. 131–147, 2005.
- LAZO, J. G. L., VARGAS, J. M. P., TANSCHKEIT, R., VELLASCO, M. *Controle nebuloso de um manipulador robótico com ajuste heurístico da base de regras*. Encontro Nacional de Inteligência Artificial, ENIA'99, Rio de Janeiro, 1999.
- LEE, Y., ZAK, S. H. *Designing a genetic neural fuzzy antilock-brake-system controller*. IEEE Transactions On Evolutionary Computation, v. 6, n. 2, 2002.
- LI, T. H. S., SHIEH, M. Y. *Design of a GA-based fuzzy PID controller for non-minimum phase systems*. Fuzzy Sets and Systems 111, pp. 183-197, 2000.
- LIANG, M., YEAP, T., HERMANSYAH, A., RAHMATI, S. *Fuzzy control of spindle torque for industrial CNC machining*. International Journal of Machine Tools & Manufacture v. 43, pp. 1497–1508, 2003.
- LIN, C. J. *A GA-based neural fuzzy system for temperature control*. Fuzzy Sets and Systems, v. 143, pp. 311-333, 2004.
- LIN, F. J., SHIEH, H. J., SHYU, K. K., HUANG, P. K. *On-line gain-tuning IP controller using real-coded genetic algorithm*. Electric Power Systems Research 72, pp. 157–169, 2004.

- LOPES, H. S. *Algoritmos genéticos em projetos de engenharia: aplicações e perspectivas futuras*. Anais do 4º Simpósio Brasileiro de Automação Inteligente – SBAI, pp. 64-74, São Paulo, 1999.
- LUYBEN, W. L. *Simple method for tuning SISO controllers in multivariable systems*. Ind. Eng. Chem. Process Des. Dev., v.25, pp.654- 660, 1986.
- LUYBEN, W. L. *Process Modeling, Simulation and Control for Chemical Engineers*. 2nd edition, McGraw Hill, New York, 1990.
- MARLIN, T. E. *Process control. Designing processes and control systems for dynamic performance*. 1nd edition, McGraw Hill, New York, 1995.
- MEDEIROS, A. V., MAITELLI, A. L., FILHO, O. G. *Otimização das funções de pertinência de um controlador nebuloso utilizando algoritmos genéticos*. V Simpósio Brasileiro de Automação Inteligente, Canela, 2001.
- MEDEIROS, A. V., MAITELLI, A. L., ARAÚJO, F. M. U. *Geração de regras de inferência de um controlador nebuloso utilizando algoritmos genéticos*. VI Simpósio Brasileiro de Automação Inteligente, Bauru, 2003.
- MEI, T. X., GOODALL, R. M. *LQG and GA solutions for active steering of railway vehicles*. IEE Proceedings - Control Theory and Applications, v. 147, n. 1, pp. 111-117, 2000.
- MELO JR., W. S. *Controle preditivo generalizado adaptativo aplicado ao processo de craqueamento catalítico*. Dissertação de mestrado, Centro Federal de Educação Tecnológica do Paraná, Curitiba, 2003.
- MICHALEWICZ, Z. *Genetic algorithms + data structures = evolution programs*. 3. ed. Springer-Verlag, New York, 1966.
- MORO, L. F. L., ODLOAK, D. *Constrained multivariable control of fluid catalytic craking converters*. Journal of Process Control, v. 5, n. 1, pp. 29-39, 1995.
- O'MAHONY, T., DOWNING, C. J., FATLA, K. *Genetic algorithms for PID parameter optimisation: minimising error criteria*. Process Control and Instrumentation, University of Strathclyde Preprints, pp. 148-153, 2000.
- OGATA, K. *Engenharia de controle moderno*. 3 ed. Prentice-Hall, Rio de Janeiro, 1998.
- PAL, T., PAL, N. R. *SOGARG: A self-organized genetic algorithm-based rule generation scheme for fuzzy controllers*. IEEE Transactions on Evolutionary Computation, v. 7, n. 4, pp. 397-415, 2003.
- PANAGOPOULOS, H., ASTRÖM, K. J., HÄGGLUND, T. *Design of PI controllers based on Non-Convex Optimization*. Automatica, v. 34, n. 5, pp. 585–601, 1998.

- PEDRYCZ, W. (1993). *Fuzzy control and fuzzy systems*. 2nd extended edition, Research Studies Press, Taunton, Somerset, England.
- PHILLIPS, C. L., NAGLE, H. T. *Digital control system analysis and design*. 2 ed. Prentice-Hall, New Jersey, 1990.
- POTOCNIK, P., GRABEC, I. *Nonlinear model predictive control of a cutting process*. Neurocomputing 43, pp. 107–126, 2002.
- PRECUP, R. E., PREITL, S., FAUR, G. *PI predictive fuzzy controllers for electrical drive speed control: methods and software for stable development*. Computers in Industry v.52, pp.253–270, 2003.
- PRETT, D. M., MORARI, M. *The Shell process control workshop*. London: Butterworths, 1987.
- PROSDÓSSIMO, C. *Uma contribuição ao controle preditivo multivariável de unidades de craqueamento catalítico*. Dissertação de mestrado. Centro Federal de Educação Tecnológica do Paraná, Curitiba, 2003.
- RIVAS, V. M., MERELO, J. J., ROJAS, I., ROMERO, G., CASTILLO, P. A., CARPIO, J. *Evolving two-dimensional fuzzy systems*. Fuzzy Sets and Systems, 138, pp. 381-398, 2003.
- ROBANDI, I., NISHIMORI, K., NISHIMURA, R., ISHIHARA, N. *Optimal feedback control design using genetic algorithm in multimachine power system*. Electrical Power and Energy Systems, v. 23, pp. 263-271, 2001.
- SARIMVEIS, H., BAFAS, G. *Fuzzy model predictive control of non-linear processes using genetic algorithms*. Fuzzy Sets and Systems, v. 139, pp. 59-80, 2003.
- SHAW, I. S., SIMÕES, M. G. *Controle e modelagem fuzzy*. 1 ed., Edgard Blücher, São Paulo, 1999.
- SON, J. S., LEE, D. M., KIM, I. S., CHOI, S. K. *A study on genetic algorithm to select architecture of a optimal neural network in the hot rolling process*. Journal of Materials Processing Technology 153–154, pp. 643-648, 2004.
- SRINIVAS, M., PATNAIK, L. M. *Genetic Algorithms: A Survey*. IEEE Computer, v. 27, n. 6, pp. 17-26, 1994.
- STEPHANOPOULOS, G. *Chemical process control: an introduction to theory and practice*. Prentice Hall, 1984.
- TAVAKOLI, S., GRIFFIN, I., FLEMING, P. J. *Tuning of decentralised PI (PID) controllers for TITO processes*. Control Engineering Practice, In Press, Available online 3 August, 2005.

- VLACHOS, C., WILLIAMS, D., GOMM, J. B. *Solution to the Shell standard control problem using genetically tuned PID controllers*. Control Engineering Practice, v.10, pp. 151- 63, 2002.
- VON ZUBEN, F. J. *Computação evolutiva: uma abordagem pragmática*. I Jornada de Estudos em Computação de Piracicaba e Região, v. 1, pp. 25-45, Piracicaba, 2000.
- WANG, H., KWONG, S., JIN, Y., WEI, W., MAN, K. F. *Multi-objective hierarchical genetic algorithm for interpretable fuzzy rule-based knowledge extraction*. Fuzzy Sets and Systems 149, pp. 149–186, 2005.
- WANG, L. X. *A course in fuzzy systems and control*. Prentice Hall, 1997.
- WANG, Q., SPRONCK, P., TRACHT, R. *An overview of genetic algorithms applied to control engineering problems*. Proceedings of the Second International Conference on Machine Learning and Cybernetics, Xi'an, 2003.
- WOOD, R. K. BERRY, M. W. *Terminal composition of a binary distillation column*. Chemical. Engineering Sciences, v. 28, pp. 1707-1717, 1973
- ZADEH, L. A. *Fuzzy sets*. Information and Control 8, pp. 338–353, 1965.
- ZANIN, A. C. *Implementação industrial de um otimizador em tempo real*. Tese de doutorado, Universidade de São Paulo, São Paulo, 2001.
- ZHUANG, M., ATHERTON, D. P. *Automatic tuning of optimum PID controllers*. IEE Proceedings D, v. 140, n. 3, 1993.

DADOS DE SIMULAÇÃO

Coluna de Destilação Wood-Berry

	Tempo de processo	População	Gerações	Tempo de simulação	
				p/ geração	Total
Controlador PI	100 minutos	100	40	30 seg	20 min
Controlador PID	100 minutos	100	50	30 seg	25 min

Coluna de Destilação de Isopropanol

	Tempo de processo	População	Gerações	Tempo de simulação	
				p/ geração	Total
Base de Regras	8 horas	500	110	20 min	38 h
Funções Pertinência	8 horas	100	50	4 min	3,5 h

Craqueamento Catalítico em Leito Fluidizado

	Tempo de processo	População	Gerações	Tempo de simulação	
				p/ geração	Total
3 x PI	160 min	100	40	21 min	14 h
2 x PD nebuloso	160 min	30	15	12,5 h	187 h
5 x PI	160 min	200	50	42 min	35 h



MINISTÉRIO DA EDUCAÇÃO
CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGA^a ELÉTRICA E INFORMÁTICA INDUSTRIAL

"Algoritmos Genéticos Para Sintonia Simultânea de Múltiplos Controladores em Processos Refino."

por

Maria Cristina Szpak Swiech

Esta Dissertação foi apresentada no dia 14 de Outubro de 2005, como requisito parcial para a obtenção do título de MESTRE EM CIÊNCIAS – Área de Concentração: Informática Industrial. Aprovada pela Banca Examinadora composta pelos professores:

Prof. Dr. Lúcia Valéria Ramos de Arruda
(Orientador - CEFET-PR)

Prof. Dr. Jussara Farias Fardin
(UFES-ES)

Prof. Dr. João Alberto Fabro
(UNIOESTE-PR)

Prof. Dr. Flávio Neves Junior
(CEFET-PR)

Visto e aprovado para impressão:

Prof. Dr. José Luís Fabris
(Coordenador do CPGEI)

RESUMO:

Este trabalho apresenta uma metodologia de sintonia simultânea de controladores utilizados em um processo multivariável, através da utilização de algoritmos genéticos e sua aplicação em processos de refino.

Propõe-se a utilização de uma função de avaliação do algoritmo genético composta por três parcelas considerando os critérios ITSE (*Integral Time Squared Error*) e de variância mínima para os sinais de saída e de controle. A metodologia pode ser aplicada na sintonia integrada de diferentes tipos de controladores, mesmo quando inseridos em processos que apresentam forte interação entre as variáveis.

Para a validação da metodologia, foram utilizados os controladores PID (proporcional-integral-derivativo) e PD-nebuloso, aplicados sob arquitetura de controle descentralizado em três diferentes processos multivariáveis, Coluna de Destilação Wood-Berry, Coluna de Destilação de Isopropanol, e *Fluid Catalytic Cracking* (FCC) ou Processo de Craqueamento Catalítico em Leito Fluidizado.

A metodologia apresenta bons resultados, podendo ser estendida a outros tipos de controladores e processos.

PALAVRAS-CHAVE

sintonia controladores, algoritmos genéticos, processos multivariáveis

ÁREA/SUB-ÁREA DE CONHECIMENTO

- 3.04.05.02-5 Automação eletrônica de processos elétricos e industriais.
- 1.03.03.00-6 Metodologia e técnicas da computação.
- 3.06.01.00-2 Processos industriais de engenharia química.

2005

Nº: 377

