

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CÂMPUS CORNÉLIO PROCÓPIO  
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
MESTRADO EM ENGENHARIA ELÉTRICA**

**ARTHUR HIRATA BERTACHI**

**OTIMIZAÇÃO DE PARÂMETROS VIA METAHEURÍSTICAS  
POPULACIONAIS E VALIDAÇÃO DE UM CONTROLADOR DE  
ESTRUTURA VARIÁVEL**

**DISSERTAÇÃO**

**CORNÉLIO PROCÓPIO**

**2014**



**ARTHUR HIRATA BERTACHI**

**OTIMIZAÇÃO DE PARÂMETROS VIA METAHEURÍSTICAS  
POPULACIONAIS E VALIDAÇÃO DE UM CONTROLADOR DE  
ESTRUTURA VARIÁVEL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Mestre em Engenharia Elétrica”.

Orientador: Prof. Dr. Rodrigo Rodrigues Sumar

Co-orientador: Prof. Dr. Bruno Augusto Angélico

**CORNÉLIO PROCÓPIO**

**2014**

---

Dados Internacionais de Catalogação na Publicação

---

- B536 Bertachi, Arthur Hirata  
Otimização de parâmetros via metaheurísticas populacionais e validação de um controlador de estrutura variável / Arthur Hirata Bertachi. – 2014.  
129 p. : il. ; 30 cm
- Orientador: Rodrigo Rodrigues Sumar.  
Coorientador: Bruno Augusto Angélico.  
Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica. Cornélio Procópio, 2014.  
Referências: p. 115-119.
1. Sistemas de controle digital. 2. Programação heurística. 3. Inteligência coletiva. 4. Engenharia elétrica – Dissertações. I. Sumar, Rodrigo Rodrigues, orient. II. Angélico, Bruno Augusto, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica. IV. Título.

CDD (22. ed.) 621.3



---

## TERMO DE APROVAÇÃO

Otimização de parâmetros via metaheurísticas populacionais e validação de um controlador de estrutura variável

por

Arthur Hirata Bertachi

Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Engenharia Elétrica” e aprovado em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná.  
Cornélio Procópio, 25/02/2014.

**Banca Examinadora:**

---

Paulo Rogério Scalassara, Prof. Dr.  
Coordenador do Curso

---

Rodrigo Rodrigues Sumar, Prof. Dr.  
Orientador

---

Bruno Augusto Angélico, Prof. Dr.  
Co-orientador

---

Antonio Augusto Rodrigues Coelho, Prof. Dr.  
Universidade Federal de Santa Catarina

---

Cristiano Marcos Agulhari, Prof. Dr.  
Universidade Tecnológica Federal do Paraná



Dedico este trabalho aos meus pais, Toninho e Deusa.





## AGRADECIMENTOS

Agradeço a Deus por ter me dado saúde e força para superar os momentos difíceis.

Aos professores Rodrigo Rodrigues Sumar e Bruno Augusto Angélico, pela oportunidade de realizar este trabalho. Por toda ajuda, paciência, disponibilidade e conselhos durante a orientação deste trabalho.

A todos os professores do CIPECA pela constante orientação, em especial aos professores Cristiano Marcus Agulhari e Paulo Rogério Scalassara pelas valiosas contribuições fornecidas durante o exame de qualificação.

Ao professor Antonio Augusto Rodrigues Coelho, que mesmo sem me conhecer, contribuiu diretamente para sanar dúvidas relacionadas ao trabalho.

A todas as pessoas que frequentam o CIPECA, de que alguma maneira fizeram com que este trabalho se tornasse menos estressante. Em especial aos colegas do LACOS, LSI e LACOP.

À toda minha família, em especial aos meus pais, por me apoiarem e não medirem esforços para que eu conseguisse alcançar meus objetivos e sempre me incentivaram durante todo este tempo dedicado aos estudos.

À minha namorada e companheira de estudos, Lyvia, por toda ajuda, incentivo e compreensão durante os últimos anos. E também toda sua família que me incentivou e apoiou para me dedicar ao mestrado.

À UTFPR, pela oportunidade de crescimento profissional e pessoal durante os últimos 10 anos, através de ensino gratuito de qualidade.

À CAPES, pela bolsa de mestrado concedida.



*“Se você não sabe o que vai enfrentar,  
se prepare para o pior e otimize.”*

Simon Haykin



## RESUMO

BERTACHI, Arthur Hirata. **Otimização de parâmetros via metaheurísticas populacionais e validação de um controlador de estrutura variável**. 2014. 129 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2014.

Este trabalho apresenta a aplicação dos métodos de otimização por enxame de partículas e por colônia de formigas na otimização dos parâmetros de um controlador não linear de estrutura variável baseado em um controlador de variância mínima generalizada. Este controlador é composto por duas parcelas distintas: uma parcela linear e outra não linear. A parcela não linear do controlador apresenta dois parâmetros que afeta diretamente o comportamento do controlador e tais parâmetros são obtidos de maneira empírica. As metaheurísticas foram aplicadas para se obter os valores otimizados destes parâmetros. Foi considerada uma função custo que leva em consideração o erro de rastreamento e a variação da ação de controle. Um exemplo numérico do projeto deste controlador também é apresentado. O controlador otimizado foi experimentado em três plantas reais: controle de velocidade de um servomecanismo, controle de nível e controle de vazão em uma planta didática industrial. Os resultados obtidos enfatizam a melhora do desempenho do controlador com os parâmetros otimizados. Também é apresentada a comparação do desempenho deste controlador com um controlador PI.

**Palavras-chave:** Metaheurísticas e Otimização em Sistemas de Controle. Controle Não Linear. Controle de Estrutura Variável.



## ABSTRACT

BERTACHI, Arthur Hirata. **Parameters optimization using population metaheuristics and validation of a variable structure controller.** 2014. 129 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2014.

This work presents the application of particle swarm optimization and ant colony optimization in the parameters optimization of a non-linear controller with variable structure based on generalized minimum variance control. This controller is composed of two parts: linear and non-linear. The non-linear term of the controller consists of two parameters that directly affects the control action, and are obtained by trial and error. Metaheuristic methods were applied to find out the optimized values of these parameters. The cost function used in metaheuristic methods takes account the error and the control signal. A numerical example of the design of this controller is also presented. Three practical experiments were considered: a servomechanism velocity control and two control loops in a didactic industrial plant, level and flow control. Experimental results emphasize the improvement of the system performance when the optimization methods are applied. A comparison with PI controller is shown.

**Keywords:** Metaheuristics and Optimization in Control Systems. Non-Linear Control. Variable Structure Control.





## LISTA DE FIGURAS

FIGURA 1	– Histogramas de controle bom e controle ruim. ....	25
FIGURA 2	– Curva de resposta do um sistema a entrada ao degrau. ....	33
FIGURA 3	– Método de <i>Smith</i> para modelagem FOPDT. ....	33
FIGURA 4	– Método de <i>SK</i> para modelagem FOPDT. ....	34
FIGURA 5	– Diagrama de blocos de um VSC ....	40
FIGURA 6	– Estrutura R-S-T da malha de controle. ....	43
FIGURA 7	– Resposta do sistema para $\sigma = 0,3$ e $\varepsilon = 1$ . ....	45
FIGURA 8	– Resposta do sistema para $\sigma = 0,7$ e $\varepsilon = 1$ . ....	46
FIGURA 9	– Resposta do sistema para $\sigma = 0,7$ e $\varepsilon = 15$ . ....	47
FIGURA 10	– Resposta do sistema para $\sigma = 0,9$ e $\varepsilon = 60$ . ....	47
FIGURA 11	– Métodos de otimização ....	50
FIGURA 12	– Pontos de mínimo e máximo local/global ....	51
FIGURA 13	– Fluxograma do PSO. ....	53
FIGURA 14	– Atualização da posição de uma partícula. ....	54
FIGURA 15	– Comportamento das formigas na busca pelo caminho mais curto. ...	55
FIGURA 16	– Fluxograma do ACO. ....	56
FIGURA 17	– Diferença entre sinais com e sem ruídos utilizados na otimização. ...	62
FIGURA 18	– Kit didático <i>Datapool</i> e placa de aquisição de dados NI-USB 6008. ...	64
FIGURA 19	– Comunicação entre o computador e o sistema físico. ....	64
FIGURA 20	– Ensaio de malha aberta - Kit <i>Datapool</i> . ....	65
FIGURA 21	– Curva de ganho estático - Kit <i>Datapool</i> . ....	66
FIGURA 22	– Simulação do sistema otimizado - Kit <i>Datapool</i> . ....	69
FIGURA 23	– Controlador otimizado pelo PSO - Kit <i>Datapool</i> ensaio 1. ....	70
FIGURA 24	– Controlador otimizado pelo IWAPSO - Kit <i>Datapool</i> ensaio 1. ....	70
FIGURA 25	– Controlador otimizado pelo ACO - Kit <i>Datapool</i> ensaio 1. ....	71
FIGURA 26	– Resposta do sistema - Kit <i>Datapool</i> ensaio 2. ....	72
FIGURA 27	– Ação de controle - Kit <i>Datapool</i> ensaio 2. ....	72
FIGURA 28	– Resposta do sistema - Kit <i>Datapool</i> ensaio 3. ....	74
FIGURA 29	– Ação de controle - Kit <i>Datapool</i> ensaio 3. ....	74
FIGURA 30	– Resposta do sistema - Kit <i>Datapool</i> ensaio 4. ....	75
FIGURA 31	– Ação de controle - Kit <i>Datapool</i> ensaio 4. ....	76
FIGURA 32	– Comportamento dos índices de desempenho - Kit <i>Datapool</i> ensaio 4. ...	76
FIGURA 33	– Resposta do sistema - Kit <i>Datapool</i> ensaio 5. ....	78
FIGURA 34	– Ação de controle - Kit <i>Datapool</i> ensaio 5. ....	79
FIGURA 35	– Planta Didática Festo. ....	80
FIGURA 36	– Malha de controle de nível. ....	81
FIGURA 37	– Diagrama da malha de controle de nível ....	81
FIGURA 38	– Ensaio de malha aberta - Planta Festo Nível ....	82
FIGURA 39	– Curva de ganho estático - Planta Festo Nível. ....	83
FIGURA 40	– Simulação do sistema otimizado - Planta Festo Nível ....	84
FIGURA 41	– Controlador otimizado pelo PSO - Planta Festo Nível ensaio 1 ....	85
FIGURA 42	– Controlador otimizado pelo IWAPSO - Planta Festo Nível ensaio 1 ...	86
FIGURA 43	– Controlador otimizado pelo ACO - Planta Festo Nível ensaio 1 ....	86
FIGURA 44	– Resposta do sistema - Planta Festo Nível ensaio 2. ....	87

FIGURA 45 – Ação de controle - Planta Festo Nível ensaio 2. ....	88
FIGURA 46 – Resposta do sistema - Planta Festo Nível ensaio 3. ....	89
FIGURA 47 – Ação de controle - Planta Festo Nível ensaio 3. ....	89
FIGURA 48 – Resposta do sistema - Planta Festo Nível ensaio 4. ....	90
FIGURA 49 – Ação de controle - Planta Festo Nível ensaio 4. ....	91
FIGURA 50 – Comportamento dos índices de desempenho - Planta Festo Nível. ...	92
FIGURA 51 – Resposta do sistema - Planta Festo Nível ensaio 5. ....	94
FIGURA 52 – Ação de controle - Planta Festo Nível ensaio 5. ....	94
FIGURA 53 – Controlador otimizado pelo ACO - Planta Festo Nível ensaio 1 .....	96
FIGURA 54 – Malha de controle de vazão. ....	97
FIGURA 55 – Diagrama da malha de controle de vazão .....	97
FIGURA 56 – Ensaio de malha aberta - Planta Festo Vazão .....	98
FIGURA 57 – Curva de ganho estático - Planta Festo Vazão. ....	99
FIGURA 58 – Simulação do sistema otimizado - Planta Festo Vazão. ....	100
FIGURA 59 – Controlador otimizado pelo PSO - Planta Festo Vazão ensaio 1 .....	101
FIGURA 60 – Controlador otimizado pelo IWAPSO - Planta Festo Vazão ensaio 1 ..	101
FIGURA 61 – Controlador otimizado pelo ACO - Planta Festo Vazão ensaio 1 .....	102
FIGURA 62 – Resposta do sistema - Planta Festo Vazão ensaio 2. ....	103
FIGURA 63 – Ação de controle - Planta Festo Vazão ensaio 2. ....	103
FIGURA 64 – Resposta do sistema - Planta Festo Vazão ensaio 3. ....	104
FIGURA 65 – Ação de controle - Planta Festo Vazão ensaio 3. ....	105
FIGURA 66 – Resposta do sistema - Planta Festo Vazão ensaio 4. ....	106
FIGURA 67 – Ação de controle - Planta Festo Vazão ensaio 4. ....	107
FIGURA 68 – Comportamento dos índices de desempenho - Planta Festo Vazão. .	107
FIGURA 69 – Resposta do sistema - Planta Festo Vazão ensaio 5. ....	109
FIGURA 70 – Ação de controle - Planta Festo Vazão ensaio 5. ....	109
FIGURA 71 – Estrutura PID paralelo. ....	121
FIGURA 72 – Comparação entre os métodos de Smith e SK - Kit <i>Datapool</i> . ....	122
FIGURA 73 – Comparação entre os métodos de Smith e SK - Planta Festo Nível. ..	124
FIGURA 74 – Comparação entre os métodos de Smith e SK - Planta Festo Vazão. .	125

## LISTA DE TABELAS

TABELA 1	– Valores de entrada e saída de um processo fictício. ....	37
TABELA 2	– Valor de MSE para diferentes estruturas - Kit <i>datapool</i> . ....	65
TABELA 3	– Parâmetros utilizados no algoritmo PSO. ....	67
TABELA 4	– Parâmetros utilizados no algoritmo IWAPSO. ....	67
TABELA 5	– Parâmetros utilizados no algoritmo ACO. ....	67
TABELA 6	– Desempenho dos métodos de otimização - Kit <i>Datapool</i> . ....	68
TABELA 7	– Índices de desempenho - Kit <i>Datapool</i> ensaio 1. ....	70
TABELA 8	– Índices de desempenho - Kit <i>Datapool</i> ensaio 2. ....	71
TABELA 9	– Índices de desempenho - Kit <i>Datapool</i> ensaio 3. ....	73
TABELA 10	– Índices de desempenho - Kit <i>Datapool</i> ensaio 4. ....	75
TABELA 11	– Comportamento do índice $J_E$ - Kit <i>Datapool</i> ensaio 4. ....	77
TABELA 12	– Comportamento do índice $J_U$ - Kit <i>Datapool</i> ensaio 4. ....	77
TABELA 13	– Índices de desempenho - Kit <i>Datapool</i> ensaio 5. ....	78
TABELA 14	– Valor de MSE para diferentes estruturas - Planta Festo Nível. ....	83
TABELA 15	– Desempenho dos métodos de otimização - Planta Festo Nível ....	84
TABELA 16	– Índices de desempenho - Planta Festo Nível ensaio 1. ....	86
TABELA 17	– Índices de desempenho - Planta Festo Nível ensaio 2. ....	87
TABELA 18	– Índices de desempenho - Planta Festo Nível ensaio 3. ....	90
TABELA 19	– Índices de desempenho - Planta Festo Nível ensaio 4. ....	91
TABELA 20	– Comportamento do índice $J_E$ - Planta Festo Nível ensaio 4 ....	92
TABELA 21	– Comportamento do índice $J_U$ - Planta Festo Nível ensaio 4 ....	93
TABELA 22	– Índices de desempenho - Planta Festo Nível ensaio 5. ....	93
TABELA 23	– Desempenho dos métodos de otimização - Planta Festo Nível ....	95
TABELA 24	– Índices de desempenho - Planta Festo Nível ensaio 1. ....	95
TABELA 25	– Valor de MSE para diferentes estruturas - Planta Festo Vazão. ....	98
TABELA 26	– Desempenho dos métodos de otimização - Planta Festo Vazão. ....	100
TABELA 27	– Índices de desempenho - Planta Festo Vazão ensaio 1. ....	102
TABELA 28	– Índices de desempenho - Planta Festo Vazão ensaio 2. ....	104
TABELA 29	– Índices de desempenho - Planta Festo Vazão ensaio 3. ....	105
TABELA 30	– Índices de desempenho - Planta Festo Vazão ensaio 4. ....	106
TABELA 31	– Comportamento do índice $J_E$ - Planta Festo Vazão ensaio 4. ....	108
TABELA 32	– Comportamento do índice $J_U$ - Planta Festo Vazão ensaio 4 ....	108
TABELA 33	– Índices de desempenho - Planta Festo Vazão ensaio 5. ....	110
TABELA 34	– Sintonia dos ganhos do controlador PID pelo método de Cohen-Coon. ....	122
TABELA 35	– Valores de MSE para os métodos de Smith e SK. ....	123
TABELA 36	– Valores de MSE para os métodos de Smith e SK - Planta Festo Nível. ....	123
TABELA 37	– Valores de MSE para os métodos de Smith e SK - Planta Festo Vazão. ....	124



## LISTA DE SIGLAS

CAR	<i>Controlled Auto-Regressive</i>
ACO	<i>Ant Colony Optimizaion</i>
AG	Algoritmo Genético
AI	<i>Analog Input</i>
AO	<i>Analog Output</i>
CLP	Controlador Lógico Programável
EPE	Empresa de Pesquisa Energética
FOPDT	<i>First-Order Plus Dead-Time</i>
GMV	<i>Generalized Minimum Variance</i>
GPC	<i>Generalized Predictive Control</i>
IWAPSO	<i>Inertial Weight Approch PSO</i>
LIT	Linear Invariante no Tempo
MSE	<i>Mean Square Error</i>
MV	<i>Minimum Variance</i>
PDF	<i>Probability Density Function</i>
PI	Proporcional-Integral
PID	Proporcional Integral Derivativo
PRAS	<i>Pseudo Random Analog Sequence</i>
PRBS	<i>Pseudo Random Binary Sequence</i>
PSO	<i>Particle Swarm Optimization</i>
PSS	<i>Power System Stabilizer</i>
RNA	Redes Neurais Artificiais
SISO	<i>Single-Input Single-Output</i>
SK	<i>Sundaresan e Krishnaswamy</i>
VSC	<i>Variable Structure Control</i>
VSC/GMV	Controlador de Estrutura Variável via Projeto GMV



## LISTA DE SÍMBOLOS

$K_e$	Ganho Estático do Processo
$\tau$	Constante do tempo do sistema
$\theta$	Atraso de transporte
$y$	Valor medido na saída do processo
$u$	Sinal de controle aplicado no processo
$na$	Ordem do polinômio $A(\cdot)$
$nb$	Ordem do polinômio $B(\cdot)$
$\phi$	Vetor com os valores medidos do processo
$\Phi$	Vetor dos parâmetros a serem estimados
$d$	Atraso de transporte discreto do processo
$ne$	Ordem do polinômio $E(\cdot)$
$ns$	Ordem do polinômio $S(\cdot)$
$nr$	Ordem do polinômio $R(\cdot)$
$w$	Constante de inércia
$N_{var}$	Numero de variáveis a serem otimizadas
$c_1$	Constante de Individualidade
$c_2$	Constante de Sociabilidade
$Pop$	Vetor da população total
$N_{pop}$	Tamanho da população
$P_{best}$	Melhor posição individual
$G_{best}$	Melhor posição global
$v$	Velocidade de voo das partículas
$r_1$	Número aleatório entre 0 e 1
$r_2$	Número aleatório entre 0 e 1
$\zeta$	Taxa de evaporação do feromônio
$N_{ant}$	Quantidade de formigas
$q$	Parâmetro da função gaussiana
$T$	Arquivo de soluções
$K$	Quantidade de soluções do arquivo de soluções
$\hat{y}$	Valor estimado da saída do processo
$\alpha_1$	Fator de penalização do erro de rastreamento
$\alpha_2$	Fator de penalização da variação da ação de controle
$\sigma_u^2$	Variância de $u$
$\sigma_y^2$	Variância de $y$
$\bar{u}$	Média de $u$
$\bar{y}$	Média de $y$
$K_p$	Ganho proporcional
$K_i$	Ganho integral
$K_d$	Ganho derivativo





## SUMÁRIO

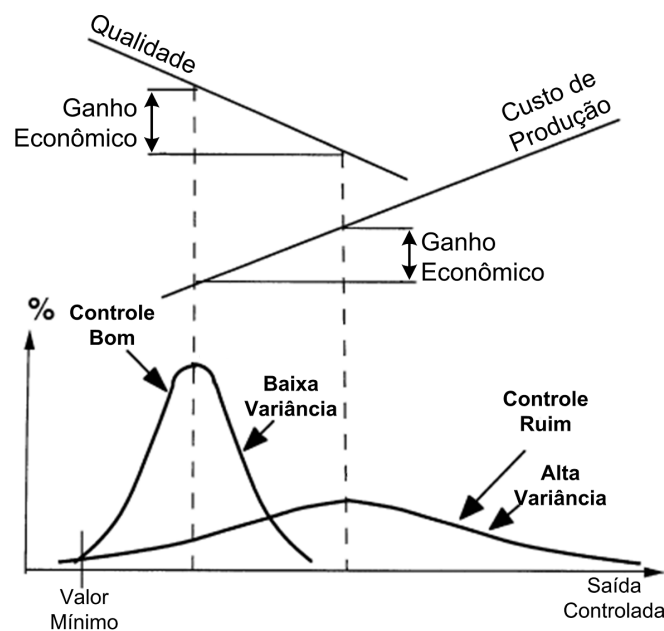
<b>1 INTRODUÇÃO</b>	<b>25</b>
1.1 OBJETIVOS	28
1.2 ESTRUTURA DO TRABALHO	28
<b>2 IDENTIFICAÇÃO E MODELAGEM DE SISTEMAS</b>	<b>31</b>
2.1 CONSIDERAÇÕES INICIAIS	31
2.2 REPRESENTAÇÃO EM TEMPO CONTÍNUO	32
2.2.1 Método de Smith	33
2.2.2 Método de Sundaresan e Krishnaswamy	34
2.3 REPRESENTAÇÃO EM TEMPO DISCRETO	34
2.3.1 Estimador dos Mínimos Quadrados Não-Recursivo	35
2.3.1.1 Exemplo numérico	36
<b>3 CONTROLADOR DE ESTRUTURA VARIÁVEL VIA PROJETO DE VARIÂNCIA MÍNIMA GENERALIZADA</b>	<b>39</b>
3.1 CONSIDERAÇÕES INICIAIS	39
3.2 CONTROLADOR VSC/GMV	40
3.3 PROJETO DO CONTROLADOR VSC/GMV: EXEMPLO NUMÉRICO	44
<b>4 OTIMIZAÇÃO DOS PARÂMETROS DA ESTRUTURA VARIÁVEL VIA METAHEURÍSTICAS POPULACIONAIS</b>	<b>49</b>
4.1 CONSIDERAÇÕES INICIAIS	49
4.2 COMPUTAÇÃO BIOINSPIRADA	50
4.3 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO)	52
4.4 OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS (ACO)	55
<b>5 RESULTADOS</b>	<b>61</b>
5.1 CONSIDERAÇÕES INICIAIS	61
5.1.1 Identificação do sistema	61
5.1.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$ do controlador	61
5.1.3 Validação do controlador	62
5.2 KIT DATAPOOL - CONTROLE DE VELOCIDADE	63
5.2.1 Identificação do sistema	64
5.2.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$	66
5.2.3 Resultados experimentais	69
5.2.3.1 Ensaio 1 - Valores otimizados de $\sigma$ e $\varepsilon$	69
5.2.3.2 Ensaio 2 - Valores empíricos de $\sigma$ e $\varepsilon$	71
5.2.3.3 Ensaio 3 - Comparação com controlador PI	73
5.2.3.4 Ensaio 4 - Comparação com controlador PI para uma única referência	75
5.2.3.5 Ensaio 5 - Comparação com controlador PI na presença de perturbação	77
5.3 PLANTA DIDÁTICA FESTO - CONTROLE DE NÍVEL	79
5.3.1 Identificação do sistema	82
5.3.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$	83
5.3.3 Resultados experimentais	85
5.3.3.1 Ensaio 1 - Valores otimizados de $\sigma$ e $\varepsilon$	85
5.3.3.2 Ensaio 2 - Valores empíricos de $\sigma$ e $\varepsilon$	87
5.3.3.3 Ensaio 3 - Comparação com controlador PI	88

5.3.3.4 Ensaio 4 - Comparação com controlador PI para uma única referência .....	90
5.3.3.5 Ensaio 5 - Comparação com controlador PI na presença de perturbação .....	93
5.4 PLANTA DIDÁTICA FESTO - CONTROLE DE VAZÃO .....	96
5.4.1 Identificação do sistema .....	97
5.4.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$ .....	99
5.4.3 Resultados experimentais .....	100
5.4.3.1 Ensaio 1 - Valores otimizados de $\sigma$ e $\varepsilon$ .....	101
5.4.3.2 Ensaio 2 - Valores empíricos de $\sigma$ e $\varepsilon$ .....	102
5.4.3.3 Ensaio 3 - Comparação com controlador PI .....	104
5.4.3.4 Ensaio 4 - Comparação com controlador PI para uma única referência .....	106
5.4.3.5 Ensaio 5 - Comparação com controlador PI na presença de perturbação .....	108
<b>6 CONSIDERAÇÕES FINAIS .....</b>	<b>111</b>
6.1 PROPOSTAS DE CONTINUIDADE .....	113
6.2 ARTIGO PRODUZIDO .....	113
<b>REFERÊNCIAS .....</b>	<b>115</b>
<b>APÊNDICE A – PROJETO DOS CONTROLADORES PI .....</b>	<b>121</b>
A.1 CONSIDERAÇÕES DE PROJETO .....	121
A.2 KIT DATAPOOL - CONTROLE DE VELOCIDADE .....	122
A.3 PLANTA DIDÁTICA FESTO - CONTROLE DE NÍVEL .....	123
A.4 PLANTA DIDÁTICA FESTO - CONTROLE DE VAZÃO .....	124
<b>APÊNDICE B – ALGORITMOS VSC/GMV .....</b>	<b>127</b>

## 1 INTRODUÇÃO

De acordo com a Empresa de Pesquisa Energética (EPE), em seu Anuário Estatístico de energia elétrica 2012 (EPE, 2012), o consumo de energia elétrica no país vem em uma crescente. Houve um aumento de 4,2% no consumo total de energia elétrica no Brasil entre os anos de 2010 e 2011, chegando ao valor de 433 TWh de energia elétrica consumida. Destaca-se o setor industrial como a classe que mais consome energia elétrica, com uma participação de cerca de 42,4% da energia total consumida.

Um sistema de controle pode influenciar diretamente a qualidade de um produto e interferir nos custos energéticos e financeiros para a fabricação de um equipamento. A Figura 1 apresenta histogramas comparando duas situações de controle: um controle considerado “bom” e um controle considerado “ruim”. Um controle “bom” apresenta uma média entre os valores medidos mais próximo ao valor mínimo possível de operação, utilizando-se menos energia do que um controle “ruim”. Já um controle “ruim” apresenta uma alta variância da saída controlada. Essa alta variância além de diminuir a qualidade do produto, pode trazer danos aos atuadores inseridos no processo.



**Figura 1 – Histogramas ilustrando a diferença entre um controle considerado bom e outro controle considerado ruim.**

Fonte: Adaptado de Landau (1998).

A busca em aumentar a produtividade na indústria têxtil europeia durante a Revolução Industrial fez com o interesse em sistemas para o controle de processos aumentasse. A solução encontrada na época para controlar a velocidade de rotação das máquinas a va-

por foi o regulador automático de velocidade, inventado por J. Watt. Com o passar dos anos a automação de processos vem crescendo de importância junto com o avanço tecnológico da informática, com o intuito de substituir tarefas realizadas por humanos e/ou encontrar soluções mais rápidas e econômicas para os problemas encontrados nas indústrias (AGUIRRE, 2007a).

Na teoria clássica de controle é utilizado o controlador Proporcional Integral Derivativo (PID) devido à sua simplicidade de implementação e robustez para a maioria dos processos. Vários trabalhos apontam que em mais de 90% das malhas de controle são utilizados os controladores PID (ÅSTRÖM; HÄGGLUND, 2001; KNOSPE, 2006), e em sua grande maioria, desconsideram o termo derivativo do controlador, utilizando apenas o controlador do tipo Proporcional-Integral (PI). No trabalho de Desborough e Miller (2000) é apresentado um estudo realizado em dezoito tipos de indústrias, onde os controladores que utilizam algoritmos de controle baseados no controlador PID alcançam cerca de 97% do total.

Um dos principais problemas do controlador PID, é que uma vez que seus ganhos são escolhidos, seu funcionamento ocorrerá de maneira satisfatória apenas se não ocorrer mudanças significativas no processo em que o controlador está inserido. Caso ocorra uma grande variação no comportamento do processo, o controlador sintonizado previamente pode não funcionar corretamente e até tornar o sistema em malha fechada instável, (VANDOREN, 2003). Mejía (2008) apresenta um estudo que aponta que apenas um terço dos controladores PID aplicados em processos contínuos possuem um desempenho aceitável e que dois terços dos controladores podem ter seu desempenho melhorado.

Buscando aperfeiçoar o desempenho das malhas de controle, entre 1960 e 1980 o controle adaptativo e de aprendizagem de sistemas complexos foi amplamente pesquisado. Entre 1980 e 1990, os desenvolvimentos na teoria de controle moderno voltaram-se para o controle robusto e para tópicos associados (OGATA, 2010).

A técnica de controle denominada *Generalized Minimum Variance* (GMV) foi apresentada por Clarke e Gawthrop (1975) sendo uma evolução da técnica *Minimum Variance* (MV) proposta por Åström e Wittenmark (1973). A estratégia de controle MV é vantajosa pela sua simplicidade, porém trata apenas de sistemas de fase mínima e não penaliza a energia de controle (KNIHS, 2011). O GMV é uma técnica de controle preditiva simples, e é efetiva no controle de processos que incluem atraso de transporte, oscilações, de fase não-mínima e instáveis (SALAMANCA, 2007). Além disso, o GMV pode ser implementado de forma adaptativa. No trabalho de Knihs (2011) algumas técnicas de controle GMV são estudadas e avaliadas.

No trabalho de Sumar (2002) é apresentado um controlador de estrutura variá-

vel com ação de controle incremental via projeto GMV. Tal controlador será citado neste trabalho como Controlador de Estrutura Variável via Projeto GMV (VSC/GMV). A ação de controle calculada pelo VSC/GMV é composta por uma parcela linear gerada pelo GMV e uma parcela não linear, caracterizada pela variação da estrutura de controle. Entretanto a escolha da estrutura do controlador depende de dois parâmetros que até o momento são ajustados empiricamente através de observações da resposta de simulações.

A aplicação de um método de otimização possibilita a obtenção destes parâmetros, diminuindo a necessidade do projetista de realizar diversas simulações para encontrar tais parâmetros e avaliar qualitativamente qual a melhor resposta obtida pelo controlador. Justifica-se esta aplicação uma vez que os resultados obtidos por Sumar (2002) mostraram-se satisfatórios e a escolha de tais parâmetros, realizada empiricamente, pode tornar inadequada a sintonia deste controlador.

Recentemente, diversas pesquisas nas mais variadas áreas utilizam-se de um método de otimização para solucionar ou contornar problemas. No trabalho de Kponyo, Kuang e Li (2012) é utilizado um método de otimização para coletar dados em tempo real de um sistema de trânsito e encontrar o melhor caminho para que um destino seja alcançado. Em Tenglong et al. (2011) encontra-se o posicionamento correto de antenas de transmissão afim de evitar a interferência eletromagnética entre elas. Fernandes (2011) utiliza-se de uma metaheurística para estimar as amplitudes das correntes harmônicas de cargas na localização e identificação de consumidores que contribuem para a distorção harmônica em sistemas de distribuição. Luz (2009) desenvolveu uma metodologia para manutenção preventiva baseada em um algoritmo de otimização. A metodologia proposta foi avaliada em um reator nuclear e os autores apontaram que os resultados apresentaram uma maior eficiência, possibilitando uma maior flexibilidade no planejamento da manutenção do equipamento.

A utilização de algoritmos de otimização para melhorar a eficiência de controladores vem sendo muito pesquisada nos últimos anos, em diversos tipos de plantas e em situações reais e computacionais e apresentam bons resultados. Castoldi (2011) utiliza de um algoritmo híbrido, composto por um Algoritmo Genético (AG), para sintonizar os parâmetros de controladores de um sistema de potência, afim de garantir a operação segura e confiável deste sistema. Neste trabalho, além dos bons resultados apresentados pelos controladores otimizados, foi destacado um baixo tempo de execução deste algoritmo híbrido para encontrar os parâmetros dos controladores.

Nos trabalhos de Costa, Almeida e Angélico (2012) e Rahimian e Raahemifar (2011) são aplicadas duas metaheurísticas com o objetivo de otimizar os ganhos de um controlador PID. Em ambos os trabalhos os resultados obtidos pela otimização por enxame

de partículas, do inglês *Particle Swarm Optimization* (PSO), se mostraram superiores aos resultados apresentados pelo AG.

O método de otimização baseado em colônias de formigas, do inglês *Ant Colony Optimizaion* (ACO), é utilizado no trabalho de Mazucato Jr. et al. (2013) para sintonizar os ganhos de estabilizadores de sistemas de potência, do inglês *Power System Stabilizer* (PSS). Comumente, os ganhos destes controladores são obtidos pelo método da tentativa e erro. Ao total foram considerados 10 controladores onde cada controlador é composto por três parâmetros que foram otimizados. Portanto, o algoritmo do ACO otimizou ao total 30 parâmetros de maneira simultânea. Os autores apontaram que os resultados obtidos através de simulações foram satisfatórios para diversas condições de operação.

## 1.1 OBJETIVOS

Os principais objetivos deste trabalho são apresentados a seguir:

### Objetivo Geral:

O objetivo geral deste trabalho é utilizar métodos heurísticos para obter os parâmetros  $\sigma$  e  $\varepsilon$  do controlador VSC/GMV e validar este controlador experimentalmente em malhas de controle reais.

### Objetivos Específicos:

- Otimizar os parâmetros da estrutura variável do controlador através de metaheurísticas populacionais, mais especificamente o PSO e o ACO.
- Implementar os algoritmos de otimização no *software* MATLAB sem utilizar nenhuma *toolbox*.
- Validar o controlador otimizado através de simulações e em situações práticas.
- Verificar a robustez do controlador VSC/GMV em diferentes situações, como a aplicação de perturbações no sistema.
- Comparar e avaliar os resultados do controlador VSC/GMV com os resultados de um controlador PI clássico, sintonizado através de um método tradicional da literatura.

## 1.2 ESTRUTURA DO TRABALHO

O Capítulo 2 realiza uma breve abordagem sobre identificação e modelagem de sistema dinâmicos, que será utilizada na validação da proposta do trabalho. Também é

apresentado o estimador dos mínimos quadrados não-recursivo utilizado na obtenção dos modelos discretos utilizados na validação prática deste trabalho.

O Capítulo 3 aborda os principais conceitos referentes ao controlador de estrutura variável via projeto GMV. Também é apresentado um exemplo numérico com o intuito de facilitar a compreensão sobre o projeto deste controlador.

No Capítulo 4 são apresentadas as metaheurísticas utilizadas na otimização dos parâmetros do controlador VSC/GMV. Neste capítulo são detalhados os métodos utilizados no trabalho: o PSO (EBERHART; KENNEDY, 1995; SHI; EBERHART, 1998) e o ACO (SOCHA; DORIGO, 2008).

O Capítulo 5 é dedicado à validação da proposta do trabalho em sistemas reais. São consideradas três malhas de controle: controle de velocidade de um servomecanismo, controle de nível e vazão em uma planta didática. São realizados vários ensaios em cada uma das malhas e os resultados são apresentados e comparados com os resultados de um controlador PI.

Por fim, no Capítulo 6 são apresentadas as conclusões do trabalho realizado, além de artigos produzidos relacionados ao trabalho e propostas de continuidade da pesquisa.





## 2 IDENTIFICAÇÃO E MODELAGEM DE SISTEMAS

### 2.1 CONSIDERAÇÕES INICIAIS

Neste capítulo serão abordados os principais aspectos relacionados à identificação e modelagem de sistemas. A identificação de sistemas tem como objetivo principal obter um modelo matemático que descreva o sistema de interesse. Um sistema é um processo cujo comportamento é determinado por variáveis internas que interagem e produzem sinais observáveis denominados saídas (AGUIRRE, 2007a).

A modelagem matemática é a área do conhecimento que estuda maneiras de desenvolver modelos matemáticos de sistemas reais. Uma das maneiras de classificar as técnicas de modelagem matemática separa tais técnicas em três categorias: modelagem caixa branca, modelagem caixa cinza e modelagem caixa preta (ROCHA; LOPES; MURATA, 2008).

Na modelagem caixa branca é necessário conhecer a fundo o sistema a ser modelado e conhecer as relações matemáticas que descrevem os fenômenos envolvidos (AGUIRRE, 2007b). Essa modelagem se baseia apenas nas leis e princípios físicos e quando existem dados disponíveis do sistema, estes são utilizados apenas para validar o modelo obtido.

A motivação para o estudo de técnicas de identificação de sistemas surge do fato que frequentemente não se conhecem as equações envolvidas no funcionamento de determinado sistema ou elas são conhecidas, mas seria impraticável, por limitações de tempo e recurso, levantar tais equações e estimar seus respectivos parâmetros (AGUIRRE, 2007b). A técnica que não utiliza nenhum (ou quase nenhum) conhecimento prévio do sistema é conhecida como caixa preta.

Já a modelagem caixa cinza pode ser colocada entre a modelagem caixa branca e a modelagem caixa preta. As técnicas deste tipo de modelagem utilizam-se de informações auxiliares que não se encontram nos dados utilizados para a modelagem caixa preta.

De acordo com Aguirre (2007b) as principais etapas para um problema de identificação paramétrica são:

- **Teste dinâmico e coleta de dados:** nesta etapa é realizada a coleta de dados, a partir de sinais de excitação aplicados na entrada do sistema, que serão utilizados para encontrar uma relação entre os valores de entrada e de saída do processo. Se possível, tais dados devem extrair informações da dinâmica do processo, e não apenas dados em condições normais de operação.
- **Escolha da representação matemática a ser usada:** nesta etapa deve-se escolher

se o sistema será representado em tempo contínuo ou tempo discreto.

- **Determinação da estrutura do modelo:** no caso de modelos lineares, esta etapa se restringe à escolha da quantidade de polos e zeros do sistema, bem como na determinação do atraso de tempo do sistema. Rocha, Lopes e Murata (2008) afirma que nesta etapa também deve-se definir quais variáveis serão utilizadas, afim de evitar uma redundância de informações, e conseqüentemente, utilizar menos recursos computacionais para a obtenção do modelo.
- **Estimação de parâmetros:** para se estimar os parâmetros das etapas anteriores é necessário utilizar algum algoritmo específico para cada tipo de representação matemática.
- **Validação do modelo:** nesta etapa é verificada a capacidade do modelo contendo os valores estimados da etapa anterior em representar o processo escolhido. Podem ser utilizados alguns índices para que se torne possível quantificar o modelo identificado em relação ao modelo real, que é representado pelos dados coletados na primeira etapa.

Coelho e Coelho (2004) dizem que a noção de um “bom modelo” é subjetiva, fazendo com que a tentativa e erro seja uma regra relevante de engenharia em identificação de processos.

Uma das maneiras de representar os modelos obtidos pela identificação é através da sua função de transferência. Essa representação é comumente utilizadas para caracterizar a relação entre a entrada e a saída de um dados sistema Linear Invariante no Tempo (LIT).


## 2.2 REPRESENTAÇÃO EM TEMPO CONTÍNUO

Uma maneira de representar um sistema contínuo é através do modelo *First-Order Plus Dead-Time* (FOPDT), representado na Equação (1). Tal modelo pode ser considerado pois o mesmo consegue representar de maneira satisfatória a maioria dos processos industriais (ÅSTRÖM; HÄGGLUND, 2000; SALAMANCA, 2007). Além disto, este modelo é utilizado em trabalhos relacionados ao projeto e sintonia de controladores PI e PID (ÅSTRÖM et al., 1993; CARMO, 2006; HAUGEN, 2010).

$$G_{planta}(s) = \frac{K_e}{\tau s + 1} e^{-\theta s} \quad (1)$$

onde  $K_e$  é o ganho estático do sistema de malha aberta,  $\tau$  é a constante de tempo do sistema e  $\theta$  é o atraso de transporte.

Existem diversos métodos na literatura que são utilizados para encontrar os parâmetros  $K_e$ ,  $\tau$  e  $\theta$  de um modelo FOPDT (COELHO; COELHO, 2004; AGUIRRE, 2007b; ÅSTRÖM; HÄGGLUND, 1995). Os métodos de *Smith* e *Sundaresan e Krishnaswamy* (SK), apresentado por Coelho e Coelho (2004), serão apresentados nas seções 2.2.1 e 2.2.2. Tais métodos utilizam-se da curva de reação do sistema a uma entrada ao degrau, conforme ilustra a Figura 2, para se obter o modelo FOPDT.




**Figura 2 – Curva de resposta do um sistema a entrada ao degrau.**

Fonte: Adaptado de Coelho e Coelho (2004).

### 2.2.1 Método de Smith

O método de *Smith* é ilustrado pela Figura 3.



**Figura 3 – Método de *Smith* para modelagem FOPDT.**

Fonte: Adaptado de Coelho e Coelho (2004).

O parâmetro  $K_e$  da Equação (1) é a razão da variação medida na saída do processo  $y$  pela variação aplicada na entrada do processo  $u$ , ou seja,

$$K_e = \frac{\Delta y}{\Delta u} \quad (2)$$


os parâmetros  $\tau$  e  $\theta$  são obtidos pelas equações (3) e (4), respectivamente.

$$\tau = 1,5(t_2 - t_1) \quad (3)$$

$$\theta = t_2 - \tau \quad (4)$$

### 2.2.2 Método de Sundaresan e Krishnaswamy

O parâmetro  $K_e$  é obtido da mesma maneira que no método de *Smith*, de acordo com a Equação (2). Para obter os outros parâmetros, deve-se observar a curva de reação do sistema, conforme é ilustrado na Figura 4.



**Figura 4 – Método de SK para modelagem FOPDT.**

Fonte: Adaptado de Coelho e Coelho (2004).

Os parâmetros  $\tau$  e  $\theta$  são obtidos pelas equações (5) e (6), respectivamente.

$$\tau = 0,67(t_2 - t_1) \quad (5)$$

$$\theta = 1,3t_1 - 0,29t_2 \quad (6)$$

## 2.3 REPRESENTAÇÃO EM TEMPO DISCRETO

Embora muitos processos sejam contínuos por natureza, os modernos sistemas de controle utilizados para controlar processos baseiam-se em computadores digitais e aplicam algoritmos de controle digital (COELHO; COELHO, 2004). Se um *hardware* digital, como por exemplo um computador, é utilizado para controlar um processo, o modelo que relaciona valores de entrada com valores de saída, utilizando a transformada- $z$ , pode ser obtido como

$$G_{planta}(z) = \frac{Y(z)}{U(z)} \quad (7)$$

onde  $G_{planta}(z)$  é a função de transferência discreta do processo, incluindo o segurador de ordem zero, e pode ser representada pelo modelo *Controlled Auto-Regressive (CAR)*<sup>1</sup>, apresentado na Equação (8), onde utiliza-se uma notação mista.

$$A(z^{-1})y(k) = z^{-d}B(z^{-1})u(k) \quad (8)$$

em que  $d$  representa o atraso de transporte discreto do processo e os polinômios  $A(z^{-1})$  e  $B(z^{-1})$  representam os polinômios do numerador e denominador do sistema em malha aberta e são da seguinte forma:

$$A(z^{-1}) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{na}z^{-na} \quad (9)$$

$$B(z^{-1}) = b_0 + b_1z^{-1} + b_2z^{-2} + \dots + b_{nb}z^{-nb} \quad (10)$$

onde  $na$  e  $nb$  são as ordens dos polinômios  $A(z^{-1})$  e  $B(z^{-1})$ , respectivamente.

A Equação (8) pode ser reescrita da seguinte maneira:

$$y(k) + a_1y(k-1) + \dots + a_{na}y(k-na) = b_0u(k-d) + b_1u(k-d-1) + \dots + b_{nb}u(k-d-nb) \quad (11)$$

Para se alcançar um modelo discreto do sistema, é necessário obter os coeficientes dos polinômios  $A(z^{-1})$  e  $B(z^{-1})$ . Uma das maneiras mais utilizadas para isto é o método conhecido como estimador dos mínimos quadrados, desenvolvido por Karl F. Gauss no final do século 18. Gauss formulou o princípio dos mínimos quadrados para estimar a posição de cometas e planetas em seus estudos astronômicos.

### 2.3.1 Estimador dos Mínimos Quadrados Não-Recursivo

Para se determinar os termos  $a_i$  e  $b_j$  da Equação (8), onde  $i = 1, \dots, na$  e  $j = 0, \dots, nb$ , deve-se ter amostras coletadas da saída do processo devido a um sinal aplicado na entrada do mesmo. Este sinal de estímulo pode ser um degrau, uma senoide, uma sequência binária pseudo aleatória, do inglês *Pseudo Random Binary Sequence (PRBS)*, uma sequência analógica pseudo aleatória, do inglês *Pseudo Random Analog Sequence (PRAS)*, entre outros.

O sistema da Equação (11) pode ser reescrito de forma matricial em função dos valores medidos de entrada e de saída e dos termos de  $A(z^{-1})$  e  $B(z^{-1})$ .

$$y(k) = \phi^T(k)\Phi(k) \quad (12)$$

onde  $\phi$  é vetor dos valores medidos do processo e  $\Phi$  é vetor contendo os parâmetros

---

<sup>1</sup>Este modelo também pode ser denominado como *Auto-Regressive Exogenous (ARX)*

que se deseja encontrar, ou seja, os coeficientes de  $A(z^{-1})$  e  $B(z^{-1})$  e são definidos como

$$\phi^T(k) = [-y(k-1) \ -y(k-2) \ \dots \ -y(k-na) \ u(k-d) \ \dots \ u(k-d-nb)]$$

$$\Phi^T(k) = \begin{bmatrix} a_1 & a_2 & \dots & a_{na} & b_0 & b_1 & \dots & b_{nb} \end{bmatrix}$$

Como ilustração, admite-se que foram coletadas  $N$  amostras do processo. A Equação (12) apresenta a seguinte forma

$$\begin{bmatrix} y(1) \\ y(2) \\ \dots \\ y(N) \end{bmatrix} = \begin{bmatrix} \phi^T(1) \\ \phi^T(2) \\ \dots \\ \phi^T(N) \end{bmatrix} \Phi \quad (15)$$

Após coletadas as  $N$  amostras, com seus respectivos valores de entrada e saída, é possível estimar um vetor de parâmetros através do algoritmo dos mínimos quadrados não-recursivo. Para isto, utiliza-se a Equação 16.

$$\hat{\Phi} = [\varphi^T \varphi]^{-1} \varphi^T Y \quad (16)$$

onde  $\hat{\Phi}$  contém os valores estimados dos termos de  $A(z^{-1})$  e  $B(z^{-1})$  e  $\varphi$  contém os dados coletados organizados da seguinte maneira (COELHO; COELHO, 2004)

$$\varphi = \begin{bmatrix} -y(k-1) & -y(k-2) & \dots & -y(k-na) & u(k-d) & \dots & u(k-d-nb) \\ -y(k) & y(k-1) & \dots & -y(k+1-na) & u(k-d+1) & \dots & u(k+1-d-nb) \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ -y(k+N-1) & -y(k+N-2) & \dots & -y(k+N-na) & u(k+N-d-1) & \dots & u(k+N-nb-1) \end{bmatrix}$$

e  $Y$  é o vetor de saída dado por

$$Y^T = \begin{bmatrix} y(1) & y(2) & y(3) & \dots & y(N) \end{bmatrix}$$

O estimador dos mínimos quadrados não-recursivo pode ser considerado um método de identificação *off-line*, uma vez que a etapa de coleta de dados do processo e a etapa da estimação dos parâmetros não ocorrem ao mesmo tempo.

### 2.3.1.1 Exemplo numérico

Como ilustração do método dos mínimos quadrados não-recursivo, a Tabela 1 contém medidas de entrada e saída de um processo fictício.

Considerando que o processo pode ser representado pelo seguinte modelo matemático:

$$y(k) = b_0 u(k) + b_1 u(k-1)$$

Tabela 1 – Valores de entrada e saída de um processo fictício.

<b>k</b>	1	2	3	4	5	6	7	8	9	10
<b>u(k)</b>	1	0,8	0,6	0,4	0,2	0	0,2	0,4	0,6	0,8
<b>y(k)</b>	0,9	2,5	2,4	1,3	1,2	0,8	0	0,9	1,4	1,9

Fonte: Adaptado de Coelho e Coelho (2004).

Logo, os parâmetros que devem ser estimados são  $b_0$  e  $b_1$ .  $\hat{b}_0$  e  $\hat{b}_1$  são as estimativas de  $b_0$  e  $b_1$ . Considerando  $d=0$  e  $N=7$ , tem-se:

$$\begin{bmatrix} y(2) \\ y(3) \\ y(4) \\ y(5) \\ y(6) \\ y(7) \\ y(8) \end{bmatrix} = \begin{bmatrix} u(2) & u(1) \\ u(3) & u(2) \\ u(4) & u(3) \\ u(5) & u(4) \\ u(6) & u(5) \\ u(7) & u(6) \\ u(8) & u(7) \end{bmatrix} \begin{bmatrix} \hat{b}_0 \\ \hat{b}_1 \end{bmatrix}$$

Inserindo os valores numéricos da Tabela 1, tem-se:

$$\begin{bmatrix} 2,5 \\ 2,4 \\ 1,3 \\ 1,2 \\ 0,8 \\ 0 \\ 0,9 \end{bmatrix} = \begin{bmatrix} 0,8 & 1 \\ 0,6 & 0,8 \\ 0,4 & 0,6 \\ 0,2 & 0,4 \\ 0 & 0,2 \\ 0,2 & 0 \\ 0,4 & 0,2 \end{bmatrix} \begin{bmatrix} \hat{b}_0 \\ \hat{b}_1 \end{bmatrix}$$

$\hat{\Phi}$  é um vetor contendo os valores de  $\hat{b}_0$  e  $\hat{b}_1$ , que é obtido de acordo com a Equação (16). As matrizes  $\varphi$  e  $Y$  para tais condições são:

$$\varphi = \begin{bmatrix} 0,8 & 1 \\ 0,6 & 0,8 \\ 0,4 & 0,6 \\ 0,2 & 0,4 \\ 0 & 0,2 \\ 0,2 & 0 \\ 0,4 & 0,2 \end{bmatrix}$$

$$Y^T = [ 2,5 \quad 2,4 \quad 1,3 \quad 1,2 \quad 0,8 \quad 0 \quad 0,9 ]$$

O vetor  $\hat{\Phi}$  resulta em:

$$\hat{\Phi} = [ 0,3214 \quad 2,4464 ]$$

Portanto, os valores estimados de  $b_0$  e  $b_1$  são 0,3214 e 2,4464, respectivamente.



### 3 CONTROLADOR DE ESTRUTURA VARIÁVEL VIA PROJETO DE VARIÂNCIA MÍNIMA GENERALIZADA

#### 3.1 CONSIDERAÇÕES INICIAIS

Sumar (2002) apresentou em seu trabalho um controlador de estrutura variável (do inglês *Variable Structure Control* (VSC)) para sistemas de uma entrada e uma saída (*Single-Input Single-Output* (SISO)) baseado em técnicas GMV. Esta técnica de controle é atraente para uma ampla classe de sistemas, devido a capacidade de tratar não-linearidades, parâmetros variantes no tempo, incertezas e perturbações de forma direta, em vista das imprecisões de modelagem. A inserção da estrutura variável no GMV tem como objetivo suprir algumas deficiências dos controladores GMV, que falham no controle de alguns processos de fase não-mínima ou quando o atraso de transporte não é perfeitamente conhecido (SANTOS, 2007).

O trabalho apresentado por Utkin (1977) foi responsável por gerar um grande interesse da comunidade científica em pesquisas relacionadas ao controle de estrutura variável (GUO; ZHANG, 2002). Esta técnica é caracterizada pelo movimento de um modo deslizante em um hiperplano previamente definido. De acordo com Xiao et al. (2006), Young, Utkin e Ozguner (1999) e Yu e Xu (2002) esta técnica de controle já provou sua eficiência, se mostrando robusto no controle de diversos processos.

Um sistema de estrutura variável consiste em pelo menos dois sistemas que possuem uma lógica de comutação determinada pelo projetista do sistema. De acordo com a condição desejada e com o comportamento do sistema, uma determinada estrutura pode ser utilizada para alcançar os objetivos de projeto, como por exemplo estabilidade.

Considere um sistema de controle representado em equações de estados, conforme a Equação (18).

$$\dot{x} = A(x,t) + B(x,t)u \quad (18)$$

A ação de controle  $u(x,t)$  aplicada no sistema é definida como:

$$u(x,t) = \begin{cases} u^+(x,t) & \text{quando } s(x) > 0 \\ u^-(x,t) & \text{quando } s(x) < 0 \end{cases}$$

para garantir que  $s(x)$  seja igual a zero, ou seja, alcance uma superfície de deslizamento em um tempo finito.

A escolha da superfície de deslizamento  $s(x)$  depende das especificações desejadas do projeto. A ação de controle  $u(x,t)$  garante que qualquer estado  $x$  fora da superfície


de deslizamento consiga alcançar a superfície em um tempo finito. Uma vez que os estados consigam atingir a superfície de deslizamento, a dinâmica desejada para o sistema é alcançada (HUNG; GAO; JUNG, 1993).

No trabalho de Hung, Gao e Jung (1993) é apresentada a ideia básica por trás de um controle por estrutura variável baseado em um sistema de segunda ordem, representado em (19).

$$\begin{aligned}\dot{x}_1 &= x_2 \\ \dot{x}_2 &= 2x_2 - x_1 + u \\ u &= -\psi x_1\end{aligned}\tag{19}$$

onde  $\psi = 4$  quando  $s(x_1, x_2) > 0$ , e  $\psi = -4$  quando  $s(x_1, x_2) < 0$ .

É definida uma função de comutação  $s(x_1, x_2) = x_1 \sigma$  com  $\sigma = 0,5x_1 + x_2$ . Um diagrama de blocos do sistema é apresentado na Figura 5.



**Figura 5 – Diagrama de blocos de um VSC**

Fonte: Adaptado de Hung, Gao e Jung (1993).

O ganho de realimentação do sistema,  $\psi$ , é selecionado de acordo com o sinal da função de comutação. Portanto, o sistema descrito em (19) pode ser tratado como duas regiões distintas, devido a estrutura variável do controlador.

Com o avanço da computação digital, o VSC discreto passou a ser estudado e utilizado em sistemas discretos, apresentando estruturas de controle similares ao VSC contínuo. Entretanto, no VSC discreto a ação de controle só é alterada em períodos de amostragem, fazendo com que o esforço de controle seja constante durante cada período. Isso faz com que o estado se aproxime da superfície de interesse, mas não consiga permanecer sobre ela. Desta forma, o VSC discreto não possui a propriedade de invariância apresentada pelo VSC contínuo (HUNG; GAO; JUNG, 1993; SARPTURK; ISTEFAPOULOS; KAYNAK, 1987).

### 3.2 CONTROLADOR VSC/GMV

A estratégia de controle MV apresentada por Åström e Wittenmark (1973) não é capaz de tratar sistemas de fase não-mínima e não exerce nenhuma influência no esforço

de controle do processo. Devido a estes fatos, a estratégia de controle MV serviu como base no desenvolvimento de outras estratégias de controle, como o GMV e o *Generalized Predictive Control* (GPC) (KNIHS, 2011). O equacionamento da lei de controle do GMV, diferentemente do MV, insere um termo que penaliza a variação excessiva da ação de controle na função custo do projeto.

Considere o sistema da Equação (8) onde  $A(z^{-1})$  representa os polos do sistema em malha aberta e  $B(z^{-1})$  os zeros do sistema em malha aberta.

O objetivo do controle é minimizar  $s(k+d)$  que, no caso determinístico, gera um sinal de controle que satisfaz a Equação (20).

$$s(k+d) = T(z^{-1})[y(k+d) - y_r(k+d)] + P(z^{-1})\Delta u(k) = 0 \quad (20)$$

onde  $d$  é o atraso de transporte do processo,  $\Delta u(k) = (1 - z^{-1})u(k)$ ,  $y$  é o valor medido na saída do processo,  $y_r$  é a referência desejada e  $P(z^{-1})$  e  $T(z^{-1})$  são polinômios de projeto representados da seguinte maneira:

$$\begin{aligned} P(z^{-1}) &= p_0 + p_1 z^{-1} + \dots + p_{(nb-1)} z^{-(nb-1)} \\ T(z^{-1}) &= t_0 + t_1 z^{-1} + \dots + t_{(na)} z^{-(na)} \end{aligned}$$

e devem ser selecionados de forma que o sistema de controle seja estável e satisfaça o Lema 1.

**Lema 1** *A condição necessária e suficiente para que a saída seja estável, fazendo que  $s(k+d) = 0$  é que todas as raízes da Equação 21 estejam no interior do círculo unitário e  $(Q(z^{-1}), T(z^{-1}))$ ,  $(A(z^{-1}), T(z^{-1}))$  e  $(B(z^{-1}), Q(z^{-1}))$  não tenham zeros comuns fora do círculo unitário (CORRADINI; ORLANDO, 1994).*

$$A(z^{-1})Q(z^{-1}) + B(z^{-1})T(z^{-1}) = 0 \quad (21)$$

onde  $Q(z^{-1}) = \Delta P(z^{-1})$ .

Percebe-se que a Equação (20), comumente denominada função custo do projeto do controlador, possui termos no futuro, que não estão disponíveis no instante de tempo  $k$ . Logo, tais valores são substituídos por valores estimados. Considere o modelo CAR:

$$A(z^{-1})y(k) = z^{-d}B(z^{-1})u(k)$$

Multiplicando ambos os lados da igualdade por  $\Delta E(z^{-1})$ , tem-se:

$$\Delta E(z^{-1})A(z^{-1})y(k) = \Delta E(z^{-1})z^{-d}B(z^{-1})u(k)$$

onde  $E(z^{-1}) = e_0 + e_1z^{-1} + e_2z^{-2} + \dots + e_{ne}z^{-ne}$ , e  $ne$  é a ordem do polinômio  $E(z^{-1})$ , sendo  $ne = (d - 1)$ .

Multiplicando ambos os lados da igualdade por  $z^d$ , tem-se:

$$\begin{aligned} \Delta E(z^{-1})A(z^{-1})y(k) \cdot z^d &= \Delta E(z^{-1})z^{-d}B(z^{-1})u(k) \cdot z^d \\ \Delta E(z^{-1})A(z^{-1})y(k+d) &= \Delta E(z^{-1})B(z^{-1})u(k) \end{aligned} \quad (22)$$

O objetivo do GMV é minimizar a função custo apresentada pela Equação (20). Considere a seguinte identidade polinomial, representada pela Equação (23).

$$T(z^{-1}) = \Delta E(z^{-1})A(z^{-1}) + z^{-d}S(z^{-1}) \quad (23)$$

onde  $S(z^{-1}) = s_0 + s_1z^{-1} + \dots + s_{ns}z^{-ns}$  e  $ns$  é a ordem do polinômio  $S(z^{-1})$ , em que  $ns = na$ .

Substituindo a Equação (23) na Equação (20), temos:

$$s(k+d) = \Delta E(z^{-1})A(z^{-1})y(k+d) + S(z^{-1})y(k) - T(z^{-1})y_r(k+d) + \Delta P(z^{-1})u(k) = 0 \quad (24)$$

Substituindo a Equação (22) na Equação (24), obtém-se a lei de controle incremental responsável por minimizar a saída do sistema da Equação (20).

$$\Delta E(z^{-1})B(z^{-1})u(k) + S(z^{-1})y(k) - T(z^{-1})y_r(k+d) + \Delta P(z^{-1})u(k) = 0$$

$$\Delta u(k) [B(z^{-1})E(z^{-1}) + P(z^{-1})] + S(z^{-1})y(k) - T(z^{-1})y_r(k+d) = 0$$

Considerando que  $R(z^{-1}) = B(z^{-1})E(z^{-1}) + P(z^{-1})$ , a lei de controle incremental do GMV é representada pela Equação (25) a seguir.

$$R(z^{-1})\Delta u(k) = T(z^{-1})y_r(k+d) - S(z^{-1})y(k), \quad (25)$$

onde  $R(z^{-1}) = r_0 + r_1z^{-1} + \dots + r_{nr}z^{-nr}$  e  $nr$  representa a ordem dos polinômios  $R(z^{-1})$  e  $nr = d$ . A ação de controle aplicada ao processo é dada pela Equação (26).

$$u(k) = u(k-1) + \Delta u(k) \quad (26)$$

A estrutura R-S-T do controlador é apresentada na Figura 6. Esta estrutura é muito utilizada na implementação de controladores digitais (LANDAU, 1998), onde são considerados filtros individuais para o sinal de referência e o sinal medida na saída. A diferença gerada por estes filtros é aplicada em outro filtro, gerando o sinal de controle. A função de transferência para esta estrutura de controle é apresentada pela Equação (27).

$$\frac{y(k)}{y_r(k)} = \frac{B(z^{-1})T(z^{-1})}{\Delta A(z^{-1})P(z^{-1}) + B(z^{-1})T(z^{-1})} = \frac{B(z^{-1})T(z^{-1})}{W(z^{-1})} \quad (27)$$

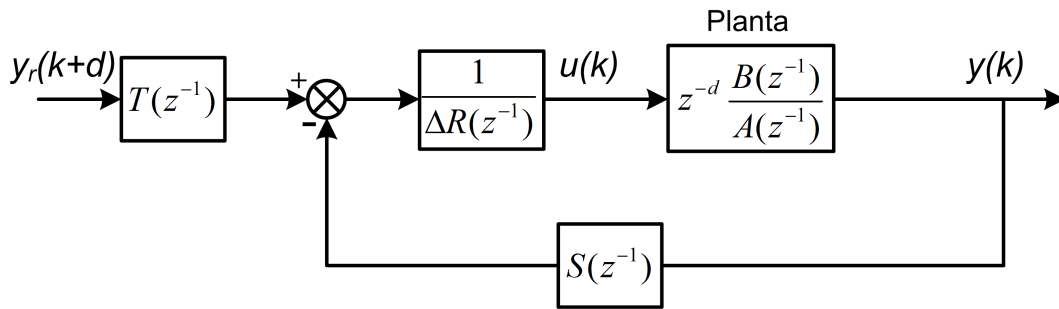


Figura 6 – Estrutura R-S-T da malha de controle.

Fonte: Autoria própria.

onde  $W(z^{-1})$  é considerada a equação característica do sistema, definindo a posição dos polos de malha fechada. Os polos de malha fechada do sistema devem ser selecionados entre zero e um para evitar o *ringing* na ação de controle. Polos situados próximo de zero conduzem a uma resposta mais agressiva (KNIHS et al., 2010; SEBORG et al., 2010).

O desempenho da lei de controle GMV pode ser melhorado pela adição de uma entrada auxiliar a ação de controle. Utiliza-se um termo baseado no VSC agregado a ação de controle linear gerada pelo GMV. A lei de controle do controlador VSC/GMV baseia-se no Teorema 1 (CORRADINI; ORLANDO, 1995; CORRADINI; ORLANDO, 1997; SUMAR, 2002):

**Teorema 1** *Dado um sistema na forma (8), a lei de controle apresentada pela Equação (28) garante o alcance de uma superfície estável de deslizamento sobre o hiperplano  $s(k+d) = 0$ , quando as condições do Lema 1 são respeitadas.*

$$R(z^{-1})\Delta u(k) = T(z^{-1})y_r(k+d) - S(z^{-1})y(k) + s(k) + v(k) \quad (28)$$

Para isto, a estrutura variável do controlador ( $v(k)$ ) deve ser selecionada de acordo com a Equação (29).

$$v(k) = \begin{cases} -2\sigma\varepsilon/s(k), & \text{se } |s(k)| \geq \sqrt{\varepsilon} \\ -2\sigma s(k), & \text{se } |s(k)| < \sqrt{\varepsilon} \end{cases} \quad (29)$$

onde  $\sigma$  e  $\varepsilon$  são escalares positivos, com  $0 < \sigma < 1$ .

A seleção dos parâmetros  $\sigma$  e  $\varepsilon$  afeta a duração e a precisão do transitório do processo controlado. A escolha de tais parâmetros é realizada, até o momento, através de diversas simulações onde são considerados diferentes valores para  $\sigma$  e  $\varepsilon$ , cabendo ao projetista realizar a análise qualitativa da resposta do sistema, para selecionar quais valores são os mais satisfatórios.

Corradini e Orlando (1995) apresentaram um controlador de estrutura variável discreto posicional. A inserção da estrutura variável é inserida na lei de controle calculada pelo

GMV, assim como o VSC/GMV proposto por Sumar (2002). Neste trabalho os parâmetros da estrutura variável também são obtidos empiricamente. Devido à ação de controle posicional, o sistema controlador pode apresentar erro em regime permanente. Já o controlador VSC/GMV não apresenta este problema devido à sua ação de controle ser incremental.

### 3.3 PROJETO DO CONTROLADOR VSC/GMV: EXEMPLO NUMÉRICO

Nesta seção é apresentado a sistemática de projeto do controlador VSC/GMV para uma planta discreta de segunda ordem com as seguintes características:

$$\begin{aligned} A(z^{-1}) &= 1 - 1,3z^{-1} + 0,42z^{-2} \\ B(z^{-1}) &= 1 - 0,8z^{-1} \\ W(z^{-1}) &= 1 - 1,001z^{-1} + 0,1702z^{-2} - 0,008z^{-3} \\ d &= 1 \end{aligned}$$

Portanto, os polinômios  $P(z^{-1})$ ,  $T(z^{-1})$ ,  $S(z^{-1})$  e  $R(z^{-1})$  possuem as seguintes ordens:

$$\begin{aligned} P(z^{-1}) &= p_0 \\ T(z^{-1}) &= t_0 + t_1z^{-1} + t_2z^{-2} \\ S(z^{-1}) &= s_0 + s_1z^{-1} + s_2z^{-2} \\ R(z^{-1}) &= r_0 + r_1z^{-1} \end{aligned}$$

Calculando o valor de  $\Delta A(z^{-1})$ , tem-se:

$$\Delta A(z^{-1}) = 1 - 2,3z^{-1} + 1,72z^{-2} - 0,42z^{-3} \quad (30)$$

Substituindo os valores de  $\Delta A(z^{-1})$ ,  $B(z^{-1})$  e  $W(z^{-1})$  na Equação (21), tem-se:

$$\begin{aligned} (1 - 2,3z^{-1} + 1,72z^{-2} - 0,42z^{-3}) \cdot p_0 + (1 - 0,8z^{-1}) \cdot (t_0 + t_1z^{-1} + t_2z^{-2}) \\ = 1 - 1,001z^{-1} + 1,1702z^{-2} - 0,008z^{-3} \quad (31) \end{aligned}$$

Resolvendo a Equação (31), encontra-se os coeficientes dos polinômios  $P(z^{-1})$  e  $T(z^{-1})$ .

$$\begin{aligned} P(z^{-1}) &= 0,1225 \\ T(z^{-1}) &= 0,8775 - 0,0173z^{-1} - 0,0543z^{-2} \end{aligned}$$

Para obter os polinômios  $S(z^{-1})$ , é necessário substituir os valores de  $T(z^{-1})$ ,  $\Delta A(z^{-1})$  e  $d$  na Equação (23)<sup>1</sup>. Sabe-se que  $E(z^{-1}) = e_0$ . Logo:

<sup>1</sup>De acordo com Silveira (2012) a obtenção de uma solução para esta equação é uma das maiores dificuldades do projeto de controladores GMV. Essa dificuldade aumenta de acordo com a ordem do modelo que descreve a planta e do valor do atraso de transporte discreto  $d$ .

$$0,8775 - 0,0173z^{-1} - 0,0543z^{-2} = e_0 \cdot (1 - 2,3z^{-1} + 1,72z^{-2} - 0,42z^{-3}) + s_0z^{-2} + s_1z^{-3} + s_2z^{-4} \quad (33)$$

Solucionando a Equação 33, encontra-se que os coeficientes dos polinômios  $E(z^{-1})$  e  $S(z^{-1})$  são:

$$E(z^{-1}) = 0,8775$$

$$S(z^{-1}) = 2,001 - 1,5636z^{-1} + 0,3686z^{-2}$$

Sabe-se que  $R(z^{-1}) = B(z^{-1})E(z^{-1}) + P(z^{-1})$ . Portanto:


$$r_0 - r_1z^{-1} = (1 - 0,8z^{-1}) \cdot (0,8775) + 0,1225 \quad (35)$$

Finalmente, o último polinômio utilizado no cálculo da ação de controle aplicada ao processo é o resultado da Equação (35);

$$R(z^{-1}) = 1 - 0,7020z^{-1}$$

Para concluir o projeto do controlador, os valores dos parâmetros  $\sigma$  e  $\varepsilon$ , que compõem a estrutura variável que foi adicionada à lei de controle do GMV, devem ser escolhidos.


A seguir é ilustrado o comportamento do sistema para alguns valores de  $\sigma$  e  $\varepsilon$  selecionados de maneira empírica para o teste de seguimento de referência. A Figura 7 ilustra a resposta do sistema e o sinal de controle para  $\sigma = 0,3$  e  $\varepsilon = 1$ .



**Figura 7 – Resposta do sistema para  $\sigma = 0,3$  e  $\varepsilon = 1$ .**

**Fonte: Autoria própria.**

Observa-se que o controlador VSC/GMV projetado foi capaz de seguir a referência. Porém o desempenho do controlador depende da escolha de  $\sigma$  e  $\varepsilon$ . A seguir ilustra-se como o ajuste destes parâmetros influencia no comportamento do sistema. A Figura 8 ilustra a resposta do sistema para  $\sigma = 0,7$  e  $\varepsilon = 1$ . Na Figura 9 é ilustrado o comportamento do sistema para  $\sigma = 0,7$  e  $\varepsilon = 15$ . E por fim a Figura 10 apresenta a resposta do sistema para  $\sigma = 0,9$  e  $\varepsilon = 60$ .



**Figura 8 – Resposta do sistema para  $\sigma = 0,7$  e  $\varepsilon = 1$ .**


Fonte: Autoria própria.

Inicialmente, apenas o valor de  $\sigma$  foi alterado de 0,3 para 0,7. Comparando as Figuras 7 e 8 percebe-se uma diminuição no tempo de resposta do sistema. Posteriormente, apenas o valor de  $\varepsilon$  foi acrescido de 1 para 15. Novamente, houve uma redução no tempo de resposta do sistema. Aumentando ainda mais os valores de  $\sigma$  de 0,7 para 0,9 e de  $\varepsilon$  de 15 para 60. O comportamento do sistema para o controlador VSC/GMV com tais parâmetros é apresentado na Figura 10. Comparando as Figuras 9 e 10, é nítido a degradação na resposta transitória do sistema.

Observando as Figuras 7, 8, 9 e 10 comprova-se a influência dos parâmetros  $\sigma$  e  $\varepsilon$  na resposta do sistema, principalmente durante o período transitório.


Justifica-se investigar um método para obter tais parâmetros. Na literatura estudada, não foi encontrado nenhum método que auxilie a seleção de  $\sigma$  e  $\varepsilon$  para melhorar a eficiência do controlador.





**Figura 9 – Resposta do sistema para  $\sigma = 0,7$  e  $\varepsilon = 15$ .**

Fonte: Autoria própria.



**Figura 10 – Resposta do sistema para  $\sigma = 0,9$  e  $\varepsilon = 60$ .**

Fonte: Autoria própria.

Neste trabalho utiliza-se de metaheurísticas para encontrar valores de  $\sigma$  e  $\varepsilon$ . As metaheurísticas são métodos computacionais que permitem encontrar soluções satisfatórias para diferentes problemas de maneira iterativa. Tais métodos serão explicados mais detalhadamente no Capítulo 4.

## 4 OTIMIZAÇÃO DOS PARÂMETROS DA ESTRUTURA VARIÁVEL VIA METAHEURÍSTICAS POPULACIONAIS

### 4.1 CONSIDERAÇÕES INICIAIS

Rao (2009) define otimização como o ato de obter o melhor resultado sob determinadas circunstâncias. Haupt e Haupt (2004) considera que otimização é o procedimento de tornar algo melhor e consiste na tentativa de mudar as considerações iniciais feitas em um determinado problema e utilizar as informações obtidas por essas mudanças para alcançar melhores resultados.

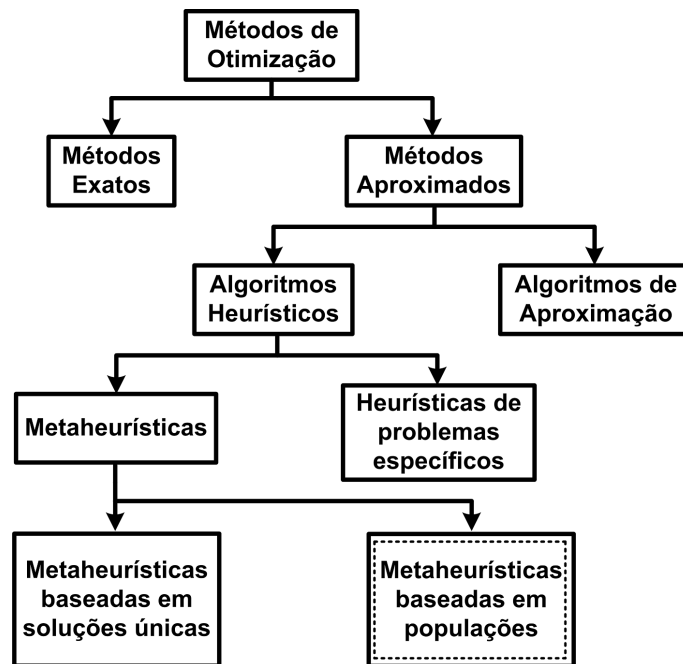
A otimização pode ser aplicada para a solução de vários tipos de problemas de engenharia, onde pode-se citar como exemplos: projeto de estruturas de aviões para alcançar o mínimo peso possível, encontrar a melhor trajetória para veículos espaciais, obtenção do menor percurso para um vendedor visitar várias cidades na mesma viagem consumindo a menor quantidade possível de combustível, projeto de sistemas de controle, entre outros (RAO, 2009).

Heurística é um método informal que auxilia na resolução de diversos tipos de problemas, pois busca reduzir as tarefas complexas de avaliar probabilidades e prever valores para operações de julgamento mais simples (TVERSKY; KAHNEMAN, 1974). As heurísticas não são utilizadas somente em problemas de engenharia, mas também são comumente encontradas na psicologia, filosofia, direito, entre outras áreas da sociedade (VALERDI, 2011).

A palavra heurística é oriunda da Grécia antiga e tem como significado “a arte de descobrir novas estratégias para resolver problemas”. As metaheurísticas são metodologias de nível superior que são utilizadas para a solução de problemas de otimização (TALBI, 2009), e também são consideradas heurísticas modernas. Ilustra-se os diferentes métodos de otimização na Figura 11.

Rao (2009) classifica as metaheurísticas como técnicas de otimização modernas ou técnicas não tradicionais de otimização. Talbi (2009) cita que nos últimos 20 anos a popularidade destas técnicas vem aumentando, mesmo que não exista garantia que tais técnicas encontrem soluções ótimas. Entretanto, a aplicação das metaheurísticas vem se mostrando eficiente na solução de problemas complexos.

Os algoritmos baseados em soluções únicas buscam uma solução durante o procedimento de otimização, isto permite uma busca mais intensa em uma região específica de interesse. Já os algoritmos baseados em populações consideram um número maior de soluções, possibilitando que os indivíduos da população (possíveis soluções) percorram um espaço de busca maior.



**Figura 11 – Métodos de otimização**

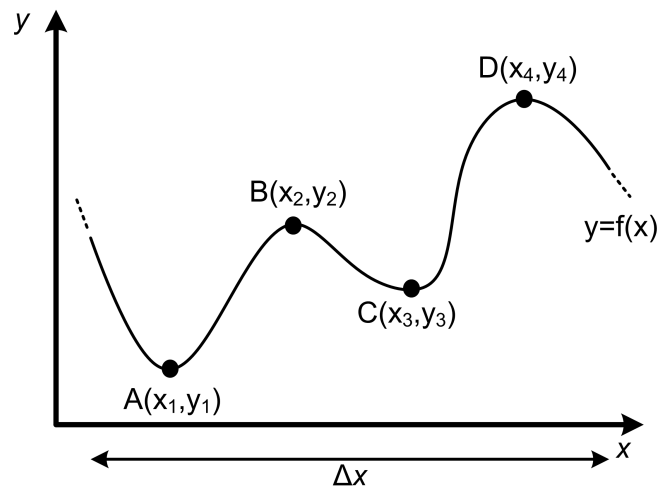
Fonte: Adaptado de Talbi (2009).

Portanto, as metaheurísticas baseadas em populações consideram um número finito de valores candidatos a serem solução de um determinado problema. Para analisar qual destas possíveis soluções é mais adequada, utiliza-se uma função custo para avaliar qual destas soluções apresenta o melhor valor. Por exemplo, em problemas de minimização, a solução que apresentar o menor valor quando aplicada a função custo será considerada a melhor solução.

Um solução pode ser considerada local ou global em relação a um determinada região de interesse. A Figura 12 exemplifica estes conceitos levando em consideração uma região de interesse delimitada por  $\Delta x$ . O ponto A representa um mínimo global enquanto o ponto D representa um máximo global. Já os pontos B e C representam um máximo local e um mínimo local, respectivamente.

## 4.2 COMPUTAÇÃO BIOINSPIRADA

Aguirre (2007a) afirma que a progressiva inspiração na biologia como metáfora para o desenvolvimento de algoritmos computacionais na busca de soluções de problemas se justifica pela possibilidade da reprodução artificial de propriedades proveitosas que estão inseridas em sistemas biológicos, como: tendência à descentralização, existência de mecanismos de adaptação e auto-organização. Dentre as técnicas computacionais bioinspiradas destacam-se as redes neurais artificiais, a computação evolutiva e os sistemas de



**Figura 12 – Pontos de mínimo e máximo local/global**

**Fonte: Autoria própria.**

inteligência coletiva, que serão apresentadas a seguir.

As Redes Neurais Artificiais (RNA) são modelos computacionais inspirados no sistema nervoso dos seres vivos, mais especificamente no comportamento do neurônio humano. Um neurônio artificial é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural artificial. As pesquisas envolvendo este tema começaram a ter destaque a partir da década de 90, muito devido ao avanço da capacidade de processamento computacional. Suas principais características são: adaptação por experiência, capacidade de aprendizado, capacidade de generalização, habilidade de classificação, entre outros (HAYKIN, 1999; SILVA; SPATTI; FLAUZINO, 2010).

O método de otimização conhecido como algoritmo genético foi desenvolvido em 1975 por John Holland e é um dos métodos mais utilizados na busca por soluções desconhecidas. O AG é um algoritmo de busca que faz analogia ao processo da seleção natural e à evolução genética. O princípio básico do AG considera uma população de indivíduos, chamados cromossomos. Durante o processo de otimização, estes cromossomos são submetidos a procedimentos de seleção e reprodução. Com isso, o algoritmo utiliza-se das melhores soluções para gerar novos cromossomos e ao mesmo tempo aumentar o espaço de busca (RENDERS; NORDVIK; BERSINI, 1992; CASTOLDI, 2011).

No trabalho de Yang (2010) é apresentada uma nova metaheurística populacional baseada no comportamento dos morcegos. Esta metaheurística tem como base a ecolocalização, que é uma capacidade biológica dos morcegos. Através da emissão de ondas ultrassônicas, os morcegos conseguem determinar a distância ou posição de obstáculos e/ou outros animais em busca de uma presa ou comida.

Além dos métodos apresentados anteriormente, existem inúmeros trabalhos que

se inspiram em sistemas biológicos ou em características específicas dos animais. A seguir serão apresentados as duas metaheurísticas populacionais consideradas neste trabalho: o PSO e o ACO. Tais metaheurísticas foram escolhidas devido aos bons resultados apresentados em outros trabalhos de otimização (COSTA; ALMEIDA; ANGÉLICO, 2012; RAHIMIAN; RAAHEMIFAR, 2011; MAZUCATO JR. et al., 2013).

#### 4.3 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO)

Eberhart e Kennedy (1995) desenvolveram esta técnica de otimização que utiliza-se apenas de cálculos matemáticos simples e seu custo computacional é baixo em relação ao consumo de memória e velocidade de execução. Assim como nas demais metaheurísticas baseadas em população, o PSO é composto por diversas possíveis soluções para o problema de otimização. Estas possíveis soluções são conhecidas como partículas. O conceito inicial do PSO consiste no cálculo da velocidade de movimentação das partículas levando em consideração a melhor posição individual de cada partícula e a melhor posição global entre todas as partículas do enxame. Desta maneira, o algoritmo busca uma solução ótima levando em consideração o comportamento de todo o enxame.

O PSO apresenta algumas vantagens em comparação a outros métodos de otimização. Seu algoritmo é robusto e é capaz de lidar com espaços de buscas não lineares e não convexos. Além disso, o PSO é capaz de solucionar problemas discretos ou contínuos com certa facilidade (PEREZ; BEHDINAN, 2007).

Em Shi e Eberhart (1998) foi apresentada uma evolução deste algoritmo, onde foi acrescentada uma constante que pondera a atualização da velocidade das partículas em relação a sua velocidade anterior. Esta constante de inércia ( $w$ ) controla a capacidade de exploração do enxame em busca de um ponto ótimo global. O fluxograma que mostra as principais etapas para a implementação deste método de otimização é apresentado na Figura 13.

Inicialmente devem-se definir alguns parâmetros para o funcionamento do processo de otimização, como quantidade de variáveis ( $N_{var}$ ) a serem otimizados e os limites das mesmas. Também devem ser definidas algumas constantes que são utilizados no cálculo da velocidade das partículas:  $c_1$  e  $c_2$  representam as constantes de individualidade e sociabilidade.

De acordo com os limites estipulados pelo projetista, deve-se gerar uma população ( $Pop$ ) contendo  $N_{pop}$  partículas, onde cada partícula é um vetor de tamanho  $N_{var}$ . Tais vetores podem ser representados da seguinte forma:

$$Pop = \left[ \begin{array}{cccc} X_1 & X_2 & \cdots & X_{N_{pop}} \end{array} \right]$$

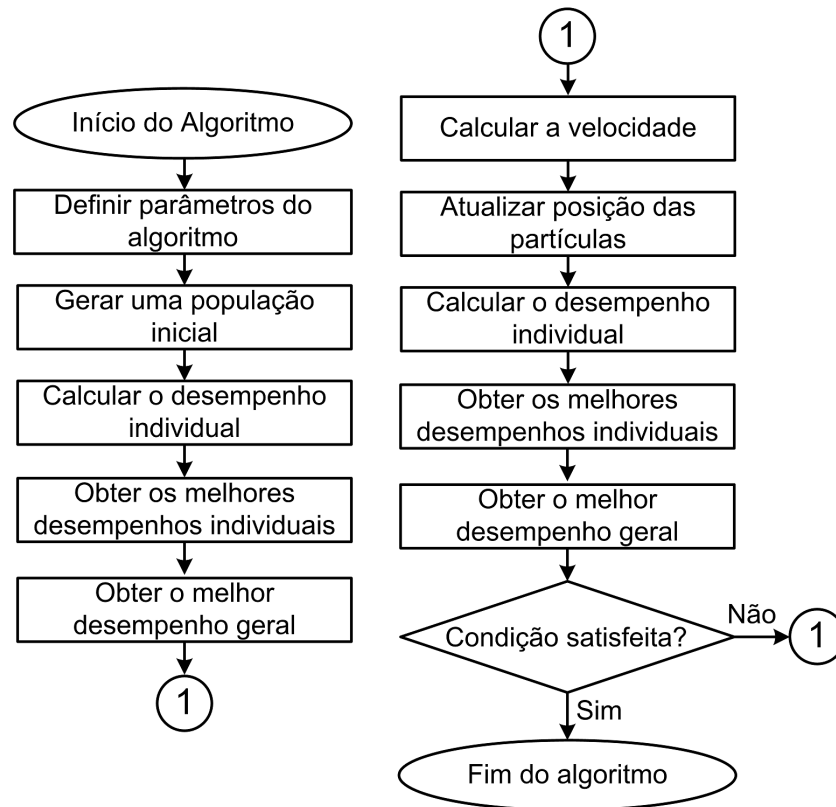


Figura 13 – Fluxograma do PSO.

Fonte: Autoria própria.

$$X_i = \left[ x_1 \quad x_2 \quad \cdots \quad x_{N_{var}} \right]^T, i = 1, 2, \dots, N_{pop}.$$

Portanto, cada partícula é representada por um vetor com tamanho  $N_{var}$ . Uma população é uma matriz contendo todas as partículas com dimensão  $N_{pop} \times N_{var}$ .

Uma vez escolhida a função custo do projeto, o desempenho de todas as partículas deve ser calculado de maneira que os melhores resultados individuais ( $P_{best}$ ) e o melhor resultado global ( $G_{best}$ ) são armazenados. O cálculo da velocidade de voo ( $v$ ) é apresentado na Equação (37) (SHI; EBERHART, 1998).

$$v_{(i+1)} = wv_i + c_1r_1(P_{best,i} - X_i) + c_2r_2(G_{best} - X_i), i = 1, 2, \dots, N_{pop} \quad (37)$$

onde  $r_1$  e  $r_2$  são números aleatórios entre 0 e 1 e a velocidade inicial geralmente é zero no início do algoritmo. Para evitar extrapolações na atualização da velocidade de voo das partículas, o projetista deve escolher valores  $v_{max}$  e  $v_{min}$ , da seguinte maneira:

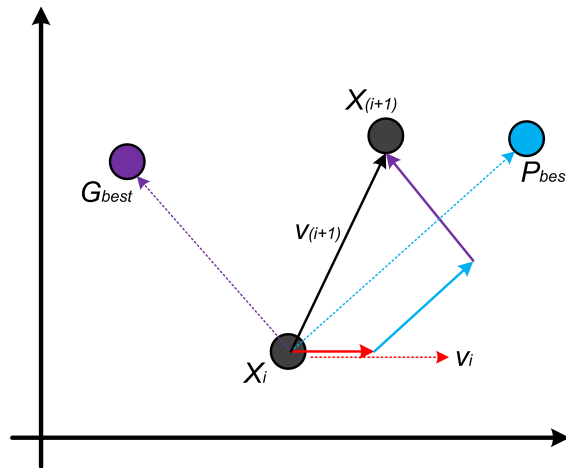
Se  $v_{(i+1)} > v_{max}$ , então  $v_{(i+1)} = v_{max}$ .

Se  $v_{(i+1)} < v_{min}$ , então  $v_{(i+1)} = v_{min}$ .

A partir da velocidade calculada, as partículas se movimentam levando em consideração a individualidade e sociabilidade de cada partícula do enxame. A atualização da

posição de cada partícula se faz de acordo com a Equação (38). Uma ilustração do procedimento de atualização da posição de uma partícula em um espaço de busca bidimensional é ilustrado na Figura 14.

$$X_{(i+1)} = X_i + v_{(i+1)} \quad (38)$$



**Figura 14 – Atualização da posição de uma partícula.**

Fonte: Autoria própria.

Para garantir que as partículas não extrapolem os limites de operação, o projetista deve adotar valores  $x_{min}$  e  $x_{max}$  para limitar cada variável a ser otimizada, de tal maneira que

Se  $x_{(i+1)} > x_{max}$ , então  $x_{(i+1)} = x_{max}$ .

Se  $x_{(i+1)} < x_{min}$ , então  $x_{(i+1)} = x_{min}$ .

De maneira iterativa, o procedimento para calcular o desempenho de cada partícula em sua nova posição é realizado e comparado com  $P_{best}$  e  $G_{best}$ . Caso alguma partícula apresente melhor custo individual  $P_{best}$ , é atualizado e se alguma partícula apresentar um melhor custo global,  $G_{best}$  é atualizado. Este processo se repete até que a condição de parada seja satisfeita.

No trabalho de Mohamed, Rao e Hasan (2010), foi utilizada uma variação do algoritmo de otimização. Esta versão, chamada *Inertial Weight Approach PSO* (IWAPSO), se assemelha com o trabalho apresentado por Shi e Eberhart (1998), mas considera um peso inercial decrescente em função do número de iterações. O parâmetro de inércia é atualizado de acordo com a Equação (39). No início do processo, as partículas realizam uma busca global, mas com o passar das iterações, a redução de  $w$  faz com que a busca tenha uma tendência mais local, diminuindo a velocidade de voo das partículas.

$$w_i = w_{max} - \left[ \frac{w_{max} - w_{min}}{i_{max}} \right] \cdot i, \quad (39)$$



onde  $i$  é o índice da iteração,  $i_{\max}$  é o número máximo de iterações definidas,  $w_{\max}$  e  $w_{\min}$  representam o valor máximo e o valor mínimo do peso inercial das partículas, respectivamente, durante a execução do algoritmo de otimização. Portanto, a nova equação para o cálculo da velocidade é representada pela Equação (40).

$$v_{(i+1)} = w_i v_i + c_1 r_1 (P_{best,i} - X_i) + c_2 r_2 (G_{best} - X_i), i = 1, 2, \dots, N_{pop} \quad (40)$$

#### 4.4 OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS (ACO)

Assim como o PSO, citado anteriormente, o ACO é um algoritmo de otimização baseado no comportamento social de uma espécie. Neste caso, ao invés de pássaros, o ACO é inspirado no comportamento das formigas durante a realização de alguma tarefa importante para a colônia. Mesmo sendo composta por indivíduos frágeis, uma colônia de formigas apresenta um alto nível de organização e cooperação entre seus indivíduos, sendo capazes de realizar tarefas complexas, como por exemplo, encontrar um caminho entre seu ninho e uma fonte de alimento (DORIGO; STÜTZLE, 2004; BLUM, 2005).

Quando as formigas estão procurando por comida ao redor de seu ninho, elas depositam pelo caminho que passam uma substância química volátil chamada ferormônio. As formigas são capazes de identificar o feromônio depositado no chão, utilizando-o como base para tomada na decisão da escolha pelo menor caminho em busca do seu alimento. Cada formiga probabilisticamente prefere seguir uma direção com uma concentração maior de feromônio do que uma direção com menor concentração (KPONYO; KUANG; LI, 2012; LEE, 2005). É apresentada na Figura 15 uma ilustração deste comportamento.

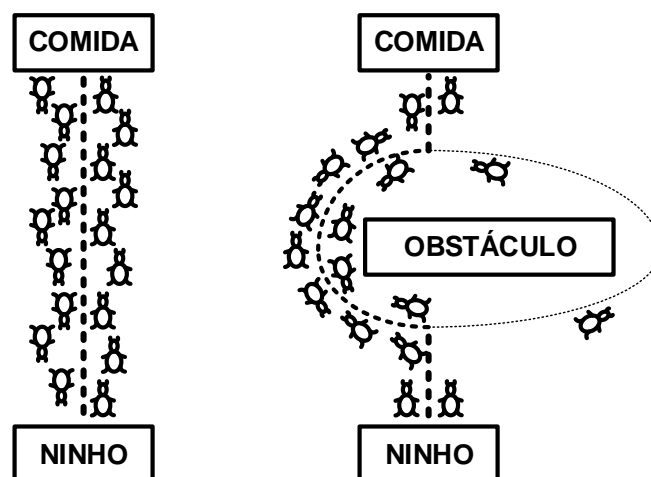
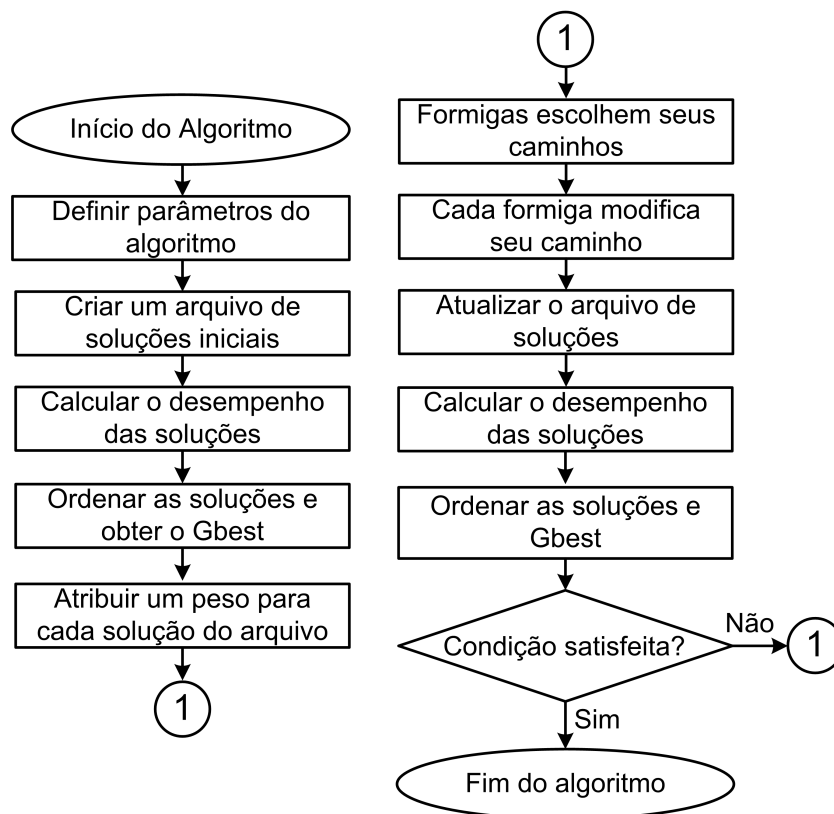


Figura 15 – Comportamento das formigas na busca pelo caminho mais curto.  
Fonte: Adaptado de Toksari (2006).

Inicialmente as formigas andam todas pelo mesmo caminho, graças à grande quantidade de feromônio presente, representado pela linha tracejada. Caso as formigas se deparem com um obstáculo, existe uma probabilidade igual para que elas escolham entre o caminho da esquerda ou da direita para transpor tal obstáculo. Como o caminho da esquerda é mais curto, as formigas levarão menos tempo para percorrer este caminho e a concentração de feromônio será maior. Conseqüentemente, mais formigas escolherão o caminho pela esquerda e a concentração será cada vez maior em relação ao caminho da direita, devido a taxa de evaporação do feromônio.

A ideia inicial de otimização baseada no comportamento das formigas foi proposta por Dorigo (1992) para solucionar problemas combinatórios, como o clássico problema do caixeiro viajante. Entretanto, existem alguns problemas que não podem ser tratados como problemas combinatórios, devido a necessidade de se otimizar variáveis contínuas em um determinado domínio. Para solucionar estes problemas, alguns algoritmos foram desenvolvidos. Neste trabalho, será considerado um algoritmo baseado no  $ACO_{\mathbb{R}}$ , proposto por Socha e Dorigo (2008) e Socha (2008). Na sequência do texto, este algoritmo será tratado apenas como ACO. O fluxograma apresentado na Figura 16 mostra os principais passos para a implementação deste método de otimização.



**Figura 16 – Fluxograma do ACO.**  
**Fonte: Autoria própria.**

Inicialmente, assim como no PSO, alguns parâmetros do algoritmo deve ser definidos, como a quantidade de variáveis a serem otimizadas ( $N_{var}$ ) e os limites de operação destas variáveis. Além disso, também devem ser definidos a taxa de evaporação do feromônio ( $\zeta$ ), a quantidade de formigas ( $N_{ant}$ ) e um parâmetro  $q$  que é utilizado em uma função gaussiana que será abordado posteriormente.

Uma matriz é inicialmente gerada contendo possíveis soluções aleatórias para o problema em questão. Esta matriz ( $T$ ) é chamada de “arquivo de soluções” e possui dimensão  $K \times N_{var}$ . As soluções devem ser geradas dentro dos limites das variáveis a serem otimizadas. Pelo fato de que esta matriz possui possíveis soluções para o problema em questão, ela pode ser denominada como a matriz de feromônio, devido a uma analogia realizada com o comportamento de formigas reais, que caminham em locais onde existem o feromônio depositado. Tal matriz é representada da seguinte forma:

$$T = \begin{bmatrix} s_1^1 & s_1^2 & \cdots & s_1^g & \cdots & s_1^{N_{var}} \\ s_2^1 & s_2^2 & \cdots & s_2^g & \cdots & s_2^{N_{var}} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ s_h^1 & s_h^2 & \cdots & s_h^g & \cdots & s_h^{N_{var}} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ s_K^1 & s_K^2 & \cdots & s_K^g & \cdots & s_K^{N_{var}} \end{bmatrix}$$

onde a  $g$ -ésima variável da  $h$ -ésima solução é denominada como  $s_h^g$ .

As soluções geradas são ordenadas de acordo com seus desempenhos. O desempenho é determinado de acordo com uma função custo escolhida. A melhor solução do arquivo é considerada o mínimo global ( $G_{best}$ ). Após isto, é atribuído um peso a cada uma dessas soluções de acordo com uma função densidade de probabilidade (do inglês, *Probability Density Function* (PDF)). Neste trabalho, é utilizada a função gaussiana com média 1 e desvio padrão  $qK$ , apresentada na Equação (41).

$$\omega_h = \frac{1}{qK\sqrt{2\pi}} e^{-\frac{(h-1)^2}{2q^2K^2}}, h = 1, 2, \dots, K \quad (41)$$

A função gaussiana possui característica não linear, permitindo maior flexibilidade na atribuição dos pesos das soluções. O ajuste do parâmetro  $q$  influencia nesta atribuição de pesos. Quando  $q$  é um valor pequeno, os pesos atribuídos as melhores soluções terão uma maior proporção em relação aos pesos das piores soluções. Quando  $q$  possui um valor alto, a atribuição dos pesos é mais uniforme.

Cada uma das  $N_{ant}$  formigas deve escolher uma das soluções da matriz  $T$  para “caminhar”. Esta escolha é realizada de maneira probabilística, com base nos pesos atri-

buídos à cada solução. A probabilidade de uma formiga escolher uma solução  $h$  é dada pela Equação (42) de maneira que  $\sum P_h = 1$  para  $P_h \geq 0 \forall h$ .

$$P_h = \frac{\omega_h}{\sum_{r=1}^K \omega_r}, h = 1, 2, \dots, K \quad (42)$$

Um número aleatório uniformemente distribuído entre 0 e 1 é gerado para cada formiga e comparado com o vetor de probabilidades acumuladas. Ou seja, o vetor de probabilidade acumulada apresenta menores valores para os melhores caminhos e valores unitários para os caminhos com probabilidade nula de escolha. A escolha de qual caminho cada formiga vai escolher é realizada pelo método da roleta. Portanto, um caminho  $h$  com probabilidade zero, nunca será escolhido.

Depois que cada formiga realiza a escolha de qual caminho seguir, as formigas devem desenvolver a habilidade de explorar novos caminhos. Para isto deve ser calculado  $\sigma_h^g$ , que corresponde ao desvio padrão da  $i$ -ésima variável a ser otimizada em relação à  $h$ -ésima solução do arquivo de soluções. O cálculo de  $\sigma_h^g$  é realizado de acordo com a Equação (43).

$$\sigma_h^g = \zeta \sum_{\substack{j=1 \\ j \neq h}}^K \frac{|s_h^g - s_j^g|}{K-1}, \quad (43)$$

onde  $\zeta > 0$  é uma variável de entrada do algoritmo e tem influência na velocidade de convergência do algoritmo. Quanto maior o valor de  $\zeta$ , menor a velocidade de convergência (SOCHA; DORIGO, 2008). A atualização dos caminhos escolhidos pelas formigas no arquivo de soluções é realizada através de uma amostragem de uma distribuição gaussiana com média zero e desvio padrão  $\sigma_h^g$ , que é adicionado ao valor de  $s_h^g$ .

Assim como no PSO, deve-se verificar se as soluções recém geradas estão dentro dos limites de operação. Portanto:

$$\begin{aligned} \text{Se } s_{h(i+1)}^g > s_{h \max}^g, & \text{ então } s_{h(i+1)}^g = s_{h \max}^g. \\ \text{Se } s_{h(i+1)}^g < s_{h \min}^g, & \text{ então } s_{h(i+1)}^g = s_{h \min}^g. \end{aligned}$$

A próxima etapa consiste na atualização do arquivo de soluções  $T$ . As novas soluções recém geradas pelas formigas substituem as piores soluções do arquivo de soluções. Por exemplo, se um arquivo de soluções for de tamanho  $K = 10$  e for considerado que  $N_{ant} = 7$ , apenas as três melhores soluções do arquivo são mantidas ( $K - N_{ant}$ ). O arquivo de soluções é novamente avaliado e ordenado de acordo com o desempenho de cada solução. Caso alguma solução apresente um desempenho melhor do que o mínimo global anterior, esta solução passa a ser o mínimo global.

O procedimento descrito anteriormente, baseado no fluxograma da Figura 16, é

repetido até que o critério de parada é satisfeito. O critério de parada considerado neste trabalho é um número máximo de iterações durante o processo de busca por um mínimo global. No Capítulo 5 apresenta-se com mais detalhes este procedimento.



## 5 RESULTADOS

### 5.1 CONSIDERAÇÕES INICIAIS

Neste capítulo são apresentados diferentes ensaios em sistemas SISO aplicando o controlador VSC/GMV. Estes ensaios buscam validar a proposta do trabalho e avaliar a eficiência do controlador perante ao controlador PI.

A metodologia utilizada pode ser dividida em três etapas: identificação do sistema, otimização dos parâmetros do controlador e validação do controlador.

#### 5.1.1 Identificação do sistema

Para alcançar um modelo discreto do sistema, é necessário obter os coeficientes dos polinômios  $A(z^{-1})$  e  $B(z^{-1})$ . Para se determinar os termos  $a_i$  e  $b_j$  da equação (8), onde  $i = 1, 2, \dots, n_a$  e  $j = 0, 1, \dots, n_b$ , é utilizado neste trabalho o estimador dos mínimos quadrados não-recursivo. Para isto, deve-se ter amostras coletadas da saída do processo ( $y(k)$ ) devido a um sinal aplicado na entrada do processo ( $u(k)$ ).

Para conseguir quantificar qual estrutura apresenta maior precisão é utilizado o erro quadrático médio (do inglês, *Mean Square Error* (MSE)), representado pela Equação (44), entre os valores medidos da saída e os valores de saída estimados pelo estimador dos mínimos quadrados não-recursivo.

$$MSE = \frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2, \quad (44)$$

onde  $N$  é a quantidade de amostras coletadas,  $y$  é a saída do processo e  $\hat{y}$  é o valor estimado da saída do processo.

#### 5.1.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$ do controlador


Com a obtenção da equação de diferenças que descreve a dinâmica do sistema, observa-se o comportamento do controlador VSC/GMV através de simulações. Portanto, é possível aplicar as metaheurísticas de otimização para encontrar os valores de  $\sigma$  e  $\varepsilon$  que apresentem o melhor desempenho do controlador.

Como índice de desempenho das metaheurísticas utilizadas, foi escolhida uma função custo que leva em consideração o erro de rastreamento do sistema e a variação da ação de controle, representada pela Equação (45).

$$J_{opt} = \alpha_1 \sum_{k=1}^N e(k)^2 + \alpha_2 \sum_{k=2}^N (u(k) - u(k-1))^2, \quad (45)$$

onde  $\alpha_1$  e  $\alpha_2$  são fatores de penalização do erro de rastreamento e da variação da ação de controle, respectivamente. Portanto, quanto menor o valor de  $J_{opt}$ , melhor é o desempenho do controlador.

Para tornar tais simulações mais fidedignas ao comportamento real dos sistemas, adiciona-se um ruído aleatório uniforme (com média  $\mu = 0$ ) nos sinais medidos durante as simulações. É ilustrado na Figura 17 a diferença entre o sinal simulado com ruído, com uma amplitude entre  $\pm 5\%$  em torno do sinal original sem ruído, e o sinal simulado sem ruído de um sistema genérico de controle.



**Figura 17 – Diferença entre sinais com e sem ruídos utilizados na otimização.**

**Fonte: Autoria própria.**

### 5.1.3 Validação do controlador

Após a obtenção dos valores de  $\sigma$  e  $\varepsilon$ , realiza-se a validação do controlador, que é dividida em duas etapas: simulação e prática. A validação via simulação permite observar se os parâmetros  $\sigma$  e  $\varepsilon$  garantem o controle do processo. Nas aplicações práticas, o controlador é aplicado em sistemas reais e tem seu desempenho comparado com um controlador PI <sup>1</sup>.

Para realizar uma análise quantitativa e auxiliar na comparação do desempenho dos controladores, serão utilizados dois índices de desempenho representados pelas

<sup>1</sup>Os projetos dos controladores PI são apresentados no Apêndice A.



Equações (46) e (47).

$$J_E = \frac{1}{N} \sum_{k=1}^N (y(k) - y_r(k))^2 \quad (46)$$

$$J_U = \frac{1}{N-1} \sum_{k=2}^N (u(k) - u(k-1))^2, \quad (47)$$

O erro médio de rastreamento do sistema é medido pelo índice  $J_E$  e através do índice  $J_U$  é calculada a energia do incremento do sinal de controle, ambos durante todo o ensaio.

Além dos índices  $J_E$  e  $J_U$ , em alguns ensaios será realizada a análise da variância para medir o grau de dispersão de um conjunto de sinais. As variâncias do sinal de controle ( $\sigma_u^2$ ) e da saída do sistema ( $\sigma_y^2$ ) são calculadas de acordo com as Equações (48) e (49), respectivamente.

$$\sigma_u^2 = \frac{1}{N} \sum_{k=1}^N (u(k) - \bar{u})^2 \quad (48)$$


$$\sigma_y^2 = \frac{1}{N} \sum_{k=1}^N (y(k) - \bar{y})^2 \quad (49)$$

onde  $\bar{u}$  é a média dos valores do sinal de controle  $\bar{y}$  é a média dos valores da saída do processo.

Todos os experimentos, simulações ou aplicações práticas, foram realizados em um computador com as seguintes especificações técnicas: Processador *Intel Core 2 Duo 1,8 GHz*, *3 GB* de memória *RAM* e com sistema operacional *Windows Seven 32 bits*. Outro fato importante é que nenhuma *toolbox* foi utilizada durante o trabalho. Todos os resultados foram obtidos através de algoritmos implementados em linha de comando no *software* MATLAB.


## 5.2 KIT DATAPOOL - CONTROLE DE VELOCIDADE

O motor de corrente contínua é uma solução atrativa em relação ao motores de indução em aplicações envolvendo controle, principalmente em aplicações de baixa potência e que necessitam de alta precisão (RUDERMAN et al., 2008). O kit didático da *Datapool*, modelo 2208, que possibilita o controle de velocidade e posição de um motor de corrente contínua de um servomecanismo é apresentado na Figura 18. Também é utilizada uma placa de aquisição de dados do fabricante *National Instruments*, modelo NI-USB 6008. Esta placa de aquisição permite além da coleta de dados, a comunicação em tempo real do sistema físico e um computador via porta *USB*. Com isso é possível utilizar o computador para realizar o controle do sistema em tempo real.



**Figura 18 – Kit didático *Datapool* e placa de aquisição de dados NI-USB 6008.**  
**Fonte: Autoria própria.**

A placa de aquisição de dados envia um sinal analógico (*Analog Output (AO)*) de 0 até 5 V. Este sinal é aplicado em um conversor que gera uma tensão proporcional a este sinal analógico no circuito de armadura do motor de corrente contínua. Através de um tacômetro é gerada uma tensão proporcional à velocidade de rotação do motor. Esta tensão é inserida em uma entrada analógica (*Analog Input (AI)*) da placa de aquisição de dados. Desta maneira é possível manter o algoritmo de controle do sistema em um computador remoto, apenas utilizando-se de uma conexão USB. Ilustra-se este procedimento na Figura 19.




**Figura 19 – Comunicação entre o computador e o sistema físico.**  
**Fonte: Autoria própria.**

### 5.2.1 Identificação do sistema

Para determinar a estrutura do modelo, aplica-se um sinal de entrada do tipo degrau no sistema com amplitude de 0,5 V. Na Figura 20(a) é apresentada a resposta do sistema para um total de 200 amostras. Os dados de entrada coletados foram referentes à tensão aplicada no motor e os dados de saída em relação à velocidade.

Através do método dos mínimos quadrados apresentado no Capítulo 2, é possível obter os termos dos polinômios  $A(z^{-1})$  e  $B(z^{-1})$  que descrevem o comportamento do sistema. Uma análise quantitativa entre as diferentes estruturas é apresentada na Tabela 2 e as curvas estimadas para tais estruturas são ilustradas na Figura 20(b). Através destas curvas é possível realizar uma análise qualitativa superficial sobre os valores estimados.



**Figura 20 – Kit *Datapool* - (a) Resposta do sistema para um degrau de 0,5 V. (b) Comparação entre a resposta do sistema e as respostas estimadas.**

Fonte: Autoria própria.

**Tabela 2 – Valor de MSE para diferentes estruturas - Kit *datapool*.**

Estrutura	MSE
$n_a=2$ $n_b=1$	$0,4179 \cdot 10^{-3}$
$n_a=3$ $n_b=1$	$0,4003 \cdot 10^{-3}$


Fonte: Autoria própria.

Analisando as curvas da Figura 20(b) observa-se que as duas estruturas apresentam respostas próximas entre si. A Tabela 2 indica que o modelo estimado pela estrutura com  $n_a = 3$  e  $n_b = 1$  apresentou o menor MSE. Portanto, o modelo que representa o sistema em questão é representado pela Equação (50), considerando  $d = 1$  e  $b_0 = 0$ .

$$y(k) = 1,49y(k-1) - 0,58y(k-2) + 0,03y(k-3) + 0,23u(k-2) \quad (50)$$

Para o projeto do controlador VSC/GMV foi considerado o polinômio de malha fechada  $W(z^{-1}) = 1 - 2,25z^{-1} + 1,8z^{-2} - 0,6025z^{-3} + 0,0714z^{-4}$  e um período de amostragem  $T_s = 0,03$ .

A curva de ganho estático da malha de velocidade é apresentada na Figura 21. Esta curva relaciona diferentes valores aplicados à entrada do sistema e seus respectivos valores de saída medidos em regime permanente.



**Figura 21 – Curva de ganho estático - Kit *Datapool*.**

**Fonte: Autoria própria.**

### 5.2.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$

Com a obtenção do modelo que representa o sistema de interesse, utiliza-se o PSO e o ACO para obter os parâmetros  $\varepsilon$  e  $\sigma$  do controlador através de simulações. Durante cada simulação, são aplicados cinco degraus de referência. A referência inicial é de 2 rad/s, e depois é variada para 2,5 rad/s, 3,0 rad/s, 2,5 rad/s e 2,0 rad/s. O ruído aleatório inserido em cada simulação apresenta amplitude de  $\pm 5\%$ .

Os parâmetros do algoritmo do PSO são mostrados na Tabela 3 e os parâmetros para o algoritmo IWAPSO são apresentados na Tabela 4. Já os parâmetros para o ACO são apresentados na Tabela 5.

Durante o processo de otimização baseado no PSO e IWAPSO 15 simulações diferentes foram realizadas considerando 80 iterações em cada simulação como critério de parada do algoritmo. Durante a primeira simulação uma população inicial é gerada, com posições aleatórias dentro de uma faixa de operação desejada pelo projetista. Na primeira iteração do algoritmo o desempenho individual de cada partícula é calculado, e automaticamente, cada desempenho é considerado o  $P_{best}$ . A partícula que apresentar o melhor

Tabela 3 – Parâmetros utilizados no algoritmo PSO.

Parâmetro	Valor
$N_{var}$	2
$N_{pop}$	10
$c_1$	1,15
$c_2$	0,80
$v_{max\sigma}$	0,1
$v_{max\epsilon}$	3
$w$	0,85
$\alpha_1$	1
$\alpha_2$	2

Fonte: Autoria própria.

Tabela 4 – Parâmetros utilizados no algoritmo IWAPSO.

Parâmetro	Valor
$N_{var}$	2
$N_{pop}$	10
$c_1$	1,15
$c_2$	0,80
$v_{max\sigma}$	0,1
$v_{max\epsilon}$	3
$w_{max}$	0,9
$w_{min}$	0,3
$\alpha_1$	1
$\alpha_2$	2

Fonte: Autoria própria.

Tabela 5 – Parâmetros utilizados no algoritmo ACO.

Parâmetro	Valor
$N_{var}$	2
$K$	12
$N_{ant}$	6
$q$	0,1
$\zeta$	0,6
$\alpha_1$	1
$\alpha_2$	2

Fonte: Autoria própria.

desempenho entre todas as partículas é considerada o  $G_{best}$ . O cálculo da velocidade de voo é realizado e a posição das partículas são atualizadas, até que o critério de parada seja satisfeito. Quando uma partícula apresentar um desempenho melhor que o seu próprio melhor desempenho, o valor armazenado em  $P_{best}$  deve ser atualizado e quando alguma partícula apresentar um resultado melhor do que o melhor resultado global já apresentado, o valor de  $G_{best}$  deve ser atualizado. Nas demais simulações este procedimento é repetido.

O processo de otimização baseado no ACO é realizado de maneira similar ao PSO. Foram realizadas 15 simulações diferentes, sendo 80 iterações o critério de parada de cada simulação. No início da primeira simulação, o arquivo de soluções (caminhos de ferormônio) é gerado. Esse arquivo de soluções é uma matriz que contém possíveis caminhos nos quais as formigas irão caminhar. As soluções do arquivo são avaliadas para se obter o desempenho de cada uma delas. O melhor desempenho entre todas as soluções é considerado o mínimo global até o momento. Cada uma das  $N_{ant}$  formigas escolhe um caminho de maneira probabilística. Cada formiga altera o caminho escolhido afim de encontrar novos caminhos. As piores soluções do arquivo de soluções são substituídas pelos caminhos alterados pelas formigas. Novamente o desempenho de cada solução é calculado. Se for necessário, o mínimo global deve ser atualizado. De maneira iterativa, as formigas devem escolher os caminhos e alterá-los até que o critério de parada seja satisfeito. Nas demais simulações este procedimento é realizado da mesma maneira.


Os resultados obtidos ao término dos processos de otimização são apresentados na Tabela 6, onde foram considerados os valores médios obtido entre as 15 simulações. Considera-se o valor médio devido ao fato que o ruído adicionado no sistema durante o processo de otimização ser aleatório. Assim, uma simulação não apresenta característica idênticas a nenhuma outra simulação, porém é o mesmo durante todas as suas iterações.

**Tabela 6 – Comparação entre o desempenho dos métodos de otimização - Kit *Datapool*.**

	PSO	IWAPSO	ACO
$\sigma$	0,6737	0,6740	0,6734
$\varepsilon$	103,29	93,73	114,03
$J_{opt}$	39,3812	39,1087	39,1181
Tempo de execução (s)	56,01	55,67	67,41

Fonte: Autoria própria.

Pode-se observar através da Tabela 6 que os resultados obtidos pelos três métodos foram similares. Foram realizadas simulações para verificar o comportamento do sistema utilizando os valores otimizados. É ilustrada na Figura 22 a resposta do sistema para o teste de seguimento de referência em simulação considerando os valores de  $\sigma$  e  $\varepsilon$  da Tabela 6.



**Figura 22 – Comportamento da resposta do sistema em simulação para os valores otimizados - Kit *Datapool*.**

**Fonte: Autoria própria.**

Através das simulações foi comprovado que os valores obtidos de  $\varepsilon$  e  $\sigma$  são capazes de controlar o processo mesmo com a adição de um ruído aleatório uniforme de amplitude  $\pm 5\%$ .

### 5.2.3 Resultados experimentais

Foram realizados cinco ensaios no Kit *Datapool* para verificar o comportamento do sistema. Os resultados e comentários sobre cada ensaio são apresentados na sequência.

#### 5.2.3.1 Ensaio 1 - Valores otimizados de $\sigma$ e $\varepsilon$

Para validar a proposta do trabalho, os valores otimizados apresentados na Tabela 6 foram aplicados no controle do sistema. Foram considerados cinco degraus de referência em intervalos de aproximadamente seis segundos. Inicialmente a referência é de 2,5 rad/s, e posteriormente foi alterada para 3,5 rad/s, 4,5 rad/s, 4,0 rad/s e 3,5 rad/s. A resposta do sistema para cada um dos métodos de otimização são apresentadas nas Figuras 23, 24 e 25. Uma comparação entre estes três métodos, utilizando-se dos índices de desempenho  $J_E$  e  $J_U$ , é apresentada na Tabela 7.




Figura 23 – Kit *Datapool* - Controlador VSC/GMV otimizado pelo PSO (a) Resposta do sistema. (b) Ação de controle.

Fonte: Autoria própria.




Figura 24 – Kit *Datapool* - Controlador VSC/GMV otimizado pelo IWAPSO (a) Resposta do sistema. (b) Ação de controle.


Fonte: Autoria própria.

Tabela 7 – Índices de desempenho para os controladores da Tabela 6 - Kit *Datapool*.

Controlador	$J_E$	$J_U$
PSO	$42,620 \cdot 10^{-3}$	$20,705 \cdot 10^{-3}$
IWAPSO	$43,678 \cdot 10^{-3}$	$19,136 \cdot 10^{-3}$
ACO	$42,467 \cdot 10^{-3}$	$19,411 \cdot 10^{-3}$

Fonte: Autoria própria.





**Figura 25 – Kit *Datapool* - Controlador VSC/GMV otimizado pelo ACO (a) Resposta do sistema. (b) Ação de controle.**

**Fonte: Autoria própria.**

Analisando-se as Figuras 23, 24 e 25 e a Tabela 7 percebe-se que todos os métodos apresentaram respostas satisfatórias e similares. A pequena diferença ocorre devido aos ruídos existentes no sistema. O controlador otimizado pelo ACO foi considerado o melhor, pois apresentou o menor valor para  $J_E$  e o segundo menor valor para  $J_U$ . Os ensaios a seguir serão realizados utilizando-se somente os valores de  $\sigma$  e  $\varepsilon$  obtidos pelo ACO.

#### 5.2.3.2 Ensaio 2 - Valores empíricos de $\sigma$ e $\varepsilon$

Como ilustração, foi realizado um ajuste empírico dos valores de  $\sigma$  e  $\varepsilon$  para ilustrar o comportamento do sistema. Foram considerados os mesmos degraus de referência do Ensaio 1. É ilustrado nas Figuras 26 e 27 uma comparação do comportamento da resposta do sistema e o comportamento da ação de controle que é aplicada no sistema para valores de  $\sigma = 0,2$  e  $\varepsilon = 120$  e os valores otimizados pelo ACO. Tais valores foram selecionados para ilustrar a diferença que estes influenciam no comportamento do controlador.

Os índices de desempenho  $J_E$  e  $J_U$  para este ensaio são apresentados na Tabela 8.

**Tabela 8 – Índices de desempenho para controlador empírico e otimizado pelo ACO - Kit *Datapool*.**

Controlador	$J_E$	$J_U$
ACO	$42,467 \cdot 10^{-3}$	$19,411 \cdot 10^{-3}$
Empírico	$28,99 \cdot 10^{-3}$	$32,842 \cdot 10^{-3}$

**Fonte: Autoria própria.**




Figura 26 – Comportamento da resposta do sistema para os parâmetros com otimização e sem otimização - Kit *Datapool*.

Fonte: Autoria própria.




Figura 27 – Comportamento da ação de controle para os parâmetros com otimização e sem otimização - Kit *Datapool*.

Fonte: Autoria própria.

O controlador ajustado empiricamente apresenta um índice  $J_E$  menor do que o controlador otimizado. Essa diferença se deve ao fato de que este controlador apresenta um tempo de subida menor do que o controlador otimizado. Porém, pode-se visualizar em destaque na Figura 26, que o controlador empírico apresenta sobressinal. Já o índice  $J_U$  indica um melhor desempenho do controlador otimizado. Esta informação é reforçada quando a Figura 27 é observada.

### 5.2.3.3 Ensaio 3 - Comparação com controlador PI

Neste ensaio, o controlador obtido através do ACO também foi comparado com um controlador PI. Esta comparação é justificada pela grande aplicação deste controlador em diversas malhas de controle. As características deste ensaio são as mesmas dos ensaios 1 e 2. Nas Figuras 28 e 29 são apresentados o comportamento do sistema para o teste de seguimento de referência e o comportamento da ação de controle que atua no sistema. Os índices de desempenho desses controladores são apresentados na Tabela 9.

**Tabela 9 – Índices de desempenho para os controladores VSC/GMV e PI - Kit *Datapool*.**

<b>Controlador</b>	$J_E$	$J_U$
PI	$23,300 \cdot 10^{-3}$	$30,912 \cdot 10^{-3}$
ACO	$42,620 \cdot 10^{-3}$	$19,411 \cdot 10^{-3}$

**Fonte: Autoria própria.**

Como pode ser visto na Figura 28, a resposta do controlador PI apresentou um sobressinal de aproximadamente 24% no início do ensaio, enquanto o controlador VSC/GMV teve um tempo de subida maior do que o PI, porém não apresentou sobressinal. Através do destaque na Figura 28 é possível comprovar que mesmo apresentando um tempo de subida maior do que o PI, o controlador VSC/GMV obteve um tempo de acomodação menor.

Na Figura 29 observa-se que a variação da ação de controle gerada pelo PI é maior do que a variação da ação de controle gerada pelo VSC/GMV, alcançando o valor de 3,21 V no início do ensaio.

Analisando os índices  $J_E$  e  $J_U$  apresentados na Tabela 9, constata-se que o controlador VSC/GMV alcançou um melhor desempenho em relação à energia de controle. Em relação ao erro de rastreamento, o controlador PI apresentou o melhor desempenho do que o controlador GMV/VSC. Este fato se deve ao início do ensaio, onde o controlador PI apresenta um tempo de subida menor. Mas quando os controladores estão em regime, o controlador VSC/GMV apresenta um melhor desempenho.




Figura 28 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI - Kit *Data-pool*.

Fonte: Autoria própria.





Figura 29 – Comportamento da ação de controle para os controladores VSC/GMV e PI - Kit *Datapool*.

Fonte: Autoria própria.

#### 5.2.3.4 Ensaio 4 - Comparação com controlador PI para uma única referência

Para elucidar a afirmação anterior, um novo ensaio foi realizado considerando uma única referência. Através deste ensaio é possível observar o comportamento do sistema operando em regime permanente. É ilustrado na Figura 30 a resposta do sistema para uma referência de 2,5 rad/s e o comportamento da ação de controle para os dois controladores na Figura 31.



**Figura 30 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI - Kit *Data-pool*.**


Fonte: Autoria própria.

Assim como no ensaio anterior, o controlador PI apresentou um sobressinal no início do ensaio, no valor de 29,2%. Mais uma vez a ação de controle do controlador VSC/GMV otimizado pelo ACO apresentou uma menor variação. Os índices de desempenho para este ensaio são apresentados na Tabela 10. O cálculo dos valores de  $\sigma_y^2$  e  $\sigma_u^2$  foi realizado considerando o sistema operando em regime, ou seja, após aproximadamente sete segundos de ensaio.

**Tabela 10 – Índices de desempenho para o ensaio com uma única referência - Kit *Datapool*.**


Controlador	$J_E$	$J_U$	$\sigma_y^2$	$\sigma_u^2$
PI	$6,904 \cdot 10^{-3}$	$7,999 \cdot 10^{-3}$	$2,634 \cdot 10^{-3}$	$4,437 \cdot 10^{-3}$
ACO	$9,486 \cdot 10^{-3}$	$2,660 \cdot 10^{-3}$	$1,190 \cdot 10^{-3}$	$0,837 \cdot 10^{-3}$

Fonte: Autoria própria.



**Figura 31 – Comportamento da ação de controle para os controladores VSC/GMV e PI - Kit *Datapool*.  
Fonte: Autoria própria.**

O controlador VSC/GMV com os parâmetros otimizados pelo ACO apresentou melhor desempenho em quase todos os índices, com destaque para a variância da ação de controle. A única exceção foi o índice  $J_E$ , onde o PI apresentou um melhor resultado. Através da Figura 32(a) pode-se observar o comportamento do índice  $J_E$  e a Figura 32(b) apresenta o comportamento do índice  $J_U$  durante o ensaio.



**Figura 32 – Kit *Datapool* - (a) Comportamento do índice  $J_E$  (b) Comportamento do índice  $J_U$ .  
Fonte: Autoria própria.**

Repare que, nas primeiras amostras do ensaio, existe uma grande diferença entre os valores do controlador VSC/GMV e do controlador PI. Porém, quando o sistema opera

em regime, essa diferença apresenta a tendência de se tornar menor. Na Tabela 11 é apresentada uma comparação entre alguns valores de  $J_E$  para alguns pontos do gráfico.

**Tabela 11 – Comparação do comportamento do índice  $J_E$  durante o ensaio - Kit *Datapool*.**

	100	500	1500	2500	3500
$J_{EPI}$	$4,303 \cdot 10^{-3}$	$4,655 \cdot 10^{-3}$	$5,402 \cdot 10^{-3}$	$6,163 \cdot 10^{-3}$	$6,904 \cdot 10^{-3}$
$J_{EACO}$	$8,333 \cdot 10^{-3}$	$8,467 \cdot 10^{-3}$	$8,816 \cdot 10^{-3}$	$9,158 \cdot 10^{-3}$	$9,486 \cdot 10^{-3}$
$J_{EACO} - J_{EPI}$	$4,030 \cdot 10^{-3}$	$3,812 \cdot 10^{-3}$	$3,414 \cdot 10^{-3}$	$2,995 \cdot 10^{-3}$	$2,582 \cdot 10^{-3}$

**Fonte: Autoria própria.**

Percebe-se uma redução do índice  $J_E$  durante o ensaio. Pode-se afirmar que, considerando um ensaio com um número maior de amostras e em condições similares a este ensaio realizado, o controlador VSC/GMV irá apresentar um desempenho melhor do que o controlador PI, em relação ao índice  $J_E$ .

Uma análise similar é realizada com o comportamento índice  $J_U$ , ilustrado na Figura 32(b). Mostra-se na Tabela 12 uma comparação entre alguns valores de  $J_U$  para alguns pontos do gráfico.

**Tabela 12 – Comparação do comportamento do índice  $J_U$  durante o ensaio - Kit *Datapool*.**

	100	500	1500	2500	3500
$J_{UPI}$	$4,084 \cdot 10^{-3}$	$4,522 \cdot 10^{-3}$	$5,680 \cdot 10^{-3}$	$6,836 \cdot 10^{-3}$	$7,999 \cdot 10^{-3}$
$J_{UACO}$	$0,289 \cdot 10^{-3}$	$0,543 \cdot 10^{-3}$	$1,299 \cdot 10^{-3}$	$1,984 \cdot 10^{-3}$	$2,660 \cdot 10^{-3}$
$J_{UPI} - J_{UACO}$	$3,795 \cdot 10^{-3}$	$3,979 \cdot 10^{-3}$	$4,381 \cdot 10^{-3}$	$4,852 \cdot 10^{-3}$	$5,339 \cdot 10^{-3}$


**Fonte: Autoria própria.**

Conclui-se, considerando um ensaio com um número maior de amostras e em condições similares a este ensaio realizado, que o desempenho do controlador VSC/GMV será cada vez melhor do que o desempenho do controlador PI em relação ao esforço de controle aplicado no sistema. Portanto, tanto em relação ao esforço de controle e ao erro de rastreamento, o desempenho do controlador VSC/GMV em regime estacionário é superior ao controlador PI, para as condições nas quais o ensaio foi realizado.

#### 5.2.3.5 Ensaio 5 - Comparação com controlador PI na presença de perturbação

Outro ensaio realizado foi uma comparação entre o controlador VSC/GMV e o controlador PI operando em regime perante uma perturbação de aproximadamente 33%. Tal perturbação é realizada manualmente através de um botão existente no Kit *Datapool*. Embora seja realizado de maneira manual, buscou-se realizá-lo de maneira coerente em ambos os ensaios, tanto em intensidade como no instante da inserção e retirada da perturbação no sistema. Neste ensaio foi considerado apenas uma única referência no valor

de 3,5 rad/s. Nas Figuras 33 e 34 são apresentados o comportamento do sistema para a aplicação de uma perturbação e o ação de controle aplicada no sistema.



**Figura 33 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI com a presença de perturbação - Kit *Datapool*.**

Fonte: Autoria própria.

Os índices de desempenho podem ser observados na Tabela 13. Neste ensaio, os índices foram calculados para comparar os desempenhos dos controladores enquanto a perturbação estava inserida. Portanto, a análise foi realizada somente no intervalo em que a perturbação estava inserida. O intervalo de análise foi definido considerando-se 50 amostras antes da inserção da perturbação até 50 amostras após a retirada da mesma.


**Tabela 13 – Índices de desempenho para o ensaio com a presença de perturbação - Kit *Datapool*.**

Controlador	$J_E$	$J_U$
PI	$6,084 \cdot 10^{-3}$	$4,702 \cdot 10^{-3}$
ACO	$7,735 \cdot 10^{-3}$	$4,336 \cdot 10^{-3}$

Fonte: Autoria própria.

Ambos os controladores conseguiram seguir a referência após a inserção e retirada da perturbação. Analisando os índices da Tabela 13, o controlador VSC/GMV apresentou melhor desempenho que o controlador PI em relação ao índice  $J_U$  e apresentou pior desempenho em relação ao índice  $J_E$ .





**Figura 34 – Comportamento da ação de controle para os controladores VSC/GMV e PI com a presença de perturbação - Kit *Datapool*.**

Fonte: Autoria própria.


### 5.3 PLANTA DIDÁTICA FESTO - CONTROLE DE NÍVEL

Para os próximos ensaios é utilizada uma planta didática do fabricante Festo. No trabalho de Almeida (2012)<sup>2</sup> foi realizada uma reabilitação da planta, pois a mesma se encontrava fora de utilização por um grande período de tempo. Uma foto da planta didática Festo após esta reabilitação é apresentada na Figura 35.

O presente modelo da planta apresenta possibilidades de controle em 4 malhas: malha de temperatura, malha de pressão, malha de nível e malha de vazão. Dentre os principais equipamentos que compõe estas malhas, destacam-se: reservatórios de acrílico, bombas centrífugas, válvulas solenóide, válvula proporcional, válvulas manuais e diversos sensores para medição.

Inicialmente, a automação da planta era totalmente baseada em um Controlador Lógico Programável (CLP). Posteriormente, foi desenvolvido um módulo de condicionamento de sinais para que fosse possível a utilização de uma placa de aquisição de dados da *National Instruments* (Modelo USB 6221). Através deste módulo, é possível realizar o acionamento das bombas e das válvulas, além da aquisição dos dados medidos pelos sensores nas diferentes malhas da planta, o que permite deixar toda a lógica de controle em

<sup>2</sup>Maiores informações sobre a readequação operacional da planta didática podem ser encontradas neste trabalho.



**Figura 35 – Planta Didática Festo.**

**Fonte: Aatoria própria.**

um computador remoto através do *software* MATLAB (FERREIRA JR., 2013; FERREIRA JR.; FREIRE; ANGÉLICO, 2013)<sup>3</sup>.

De acordo com Balbinot e Brusamarello (2011) a medição de nível é necessária em diversas situações, destacando-se a medição de nível de grãos em silos, em reservatórios de água e combustíveis e em ambientes naturais, como lagos e oceanos. O sistema de nível da planta didática é composto por dois tanques: o primeiro tanque é utilizado para realizar o controle de nível de água e o outro tanque serve como reservatório de água que é enviada para o primeiro tanque. Uma imagem do sistema é apresentada na Figura 36 e o diagrama do processo e seus principais elementos são ilustrados na Figura 37.

A entrada de água no tanque de controle é realizada através de uma bomba centrífuga que é acionada através da placa de condicionamento em conjunto com a placa de aquisição de dados. A tensão máxima de saída fornecida pela DAQ é de 10 V. Foi considerado um valor mínimo de 3,5 V como tensão mínima. Para valores menores abaixo de 3,5 V, o nível da coluna de água não se altera. A saída de água do tanque de controle para o reservatório é realizada através de uma válvula manual (V-39). Durante todos os ensaios realizados, esta válvula sempre está totalmente aberta. A medição de nível é realizada por um sensor ultrassônico. Este tipo de sensor apresenta como desvantagem que

<sup>3</sup>Maiores informações sobre o desenvolvimento do módulo de condicionamento de sinais utilizado em conjunto com a placa de aquisição de dados USB 6221 podem ser encontradas nestes trabalhos.




Figura 36 – Malha de controle de nível.  
Fonte: Autoria própria.

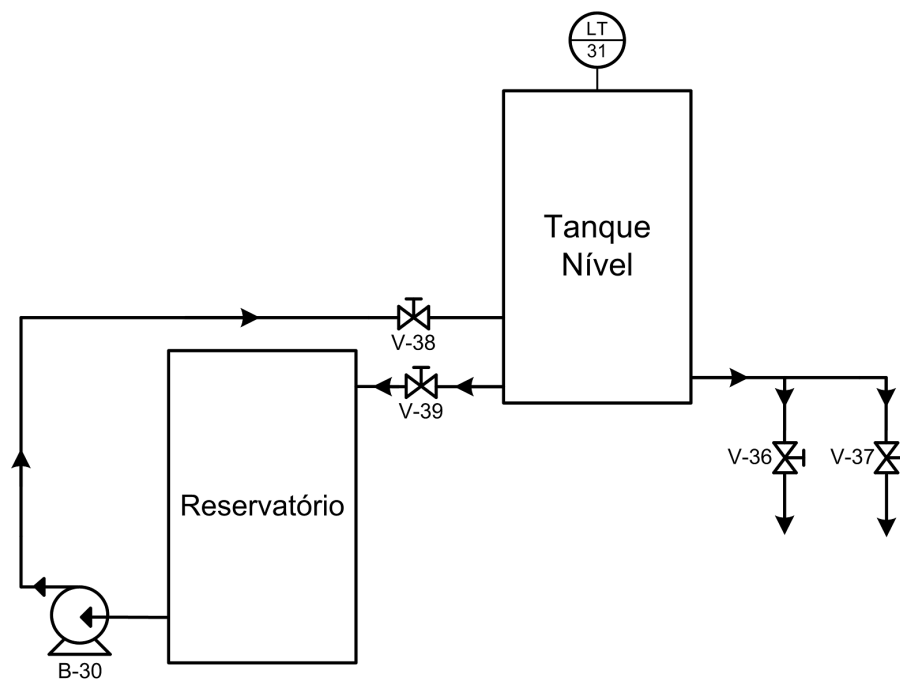



Figura 37 – Diagrama da malha de controle com seus principais elementos - Planta Festo Nível.  
Fonte: Autoria própria.

turbulências do líquido no local onde ocorre à medição podem causar ruídos indesejados (BALBINOT; BRUSAMARELLO, 2011). Este sensor gera um sinal 0 a 10 V proporcional ao nível da coluna de água do tanque de controle. Este sinal é inserido em uma AI da placa de aquisição de dados.

### 5.3.1 Identificação do sistema

Para se obter o modelo matemático que representa o comportamento do sistema foi aplicado um degrau de 6,5 V no *driver* de acionamento da bomba centrífuga. A resposta do sistema é apresentada na Figura 38(a). Utilizando-se do algoritmo dos mínimos quadrados não-recursivo obtém-se os coeficientes dos polinômios  $A(z^{-1})$  e  $B(z^{-1})$  para duas estruturas diferentes. A Figura 38(b) apresenta a estimação destas estruturas comparadas à curva real do sistema. Neste ensaio foram coletadas 3500 amostras. Os dados de entrada para este ensaio são em relação à tensão aplicada no *driver* de acionamento da bomba centrífuga. Já os dados de saída utilizados nesta etapa de identificação foram amostras de tensão fornecida pelo sensor ultrassônico.



**Figura 38 – Planta Festo Nível - (a) Resposta do sistema para um degrau de 6,5 V. (b) Comparação entre a resposta do sistema e as respostas estimadas.**

**Fonte: Autoria própria.**

Para quantificar qual estrutura apresentou maior proximidade com os dados coletados, utiliza-se o índice MSE apresentados na Tabela 14. O valor mínimo de nível que o sensor consegue medir é de aproximadamente 60 mm, este valor é desconsiderado no procedimento de identificação.

Tabela 14 – Valor de MSE para diferentes estruturas - Planta Festo Nível.

Estrutura	MSE
$n_a=2$	$3,3368 \cdot 10^{-3}$
$n_b=1$	
$n_a=3$	$1,9186 \cdot 10^{-3}$
$n_b=1$	

Fonte: Autoria própria.

A equação de diferenças que descreve o comportamento do sistema é a representado pela Equação 51, para um valor de  $d = 5$ .

$$y(k) = 0,3312y(k-1) + 0,3469y(k-2) + 0,3188y(k-3) + 0,0128u(k-5) - 0,0097u(k-6) \quad (51)$$

Para o projeto do controlador VSC/GMV nesta malha de controle foi considerado  $W(z^{-1}) = 1 - 2,85z^{-1} + 2,93z^{-2} - 1,26z^{-3} + 0,18z^{-4}$  e  $T_s = 0,2$ .

A curva de ganho estático do processo é apresentada na Figura 39.




Figura 39 – Curva de ganho estático - Planta Festo Nível.

Fonte: Autoria própria.

### 5.3.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$

De maneira semelhante à realizada no Kit *Datapool*, utilizam-se o PSO e o ACO para obter os parâmetros  $\varepsilon$  e  $\sigma$  do controlador através de simulações. Durante cada simu-

lação, são aplicados três degraus de referência. A referência inicial é de 120 mm, e depois é variada para 140mm e 130 mm. O ruído aleatório inserido em cada simulação apresenta amplitude de  $\pm 1\%$ .

Os parâmetros dos algoritmos PSO, IWAPSO e ACO utilizados nesta etapa foram os mesmos utilizados no Kit *Datapool* (Tabelas 3, 4 e 5).


A Tabela 15 apresenta os resultados obtidos ao término dos processos de otimização, onde foram considerados os valores médios obtido entre as 15 simulações.

**Tabela 15 – Comparação entre o desempenho dos métodos de otimização - Planta Festo Nível.**

	PSO	IWAPSO	ACO
$\sigma$	0,4564	0,4608	0,4480
$\varepsilon$	214,03	195,41	265,16
$J_{opt}$	37,6437	37,6320	37,73
Tempo de execução (s)	82,01	81,37	97,07

Fonte: Autoria própria.

Pode-se observar através da Tabela 15 que os resultados obtidos pelos três métodos foram similares. Foram realizadas simulações para verificar o comportamento do sistema utilizando os valores otimizados. Na Figura 40 a resposta do sistema em simulação para os três métodos de otimização é apresentada.



**Figura 40 – Comportamento da resposta do sistema em simulação para os valores otimizados - Planta Festo Nível.**

Fonte: Autoria própria.


### 5.3.3 Resultados experimentais

Foram realizados cinco ensaios para validar o controlador VSC/GMV. Nestes ensaios são considerados os valores de  $\sigma$  e  $\varepsilon$  otimizados, valores de  $\sigma$  e  $\varepsilon$  empíricos além comparações com um controlador PI.

Como citado anteriormente, devido ao *range* de operação do sensor ultrassônico, a bomba centrífuga é acionada e assim que o valor de 60 mm é atingido, inicia-se os ensaios.

#### 5.3.3.1 Ensaio 1 - Valores otimizados de $\sigma$ e $\varepsilon$

Buscando validar a proposta do trabalho, os valores de  $\sigma$  e  $\varepsilon$  na Tabela 15 foram aplicados no controlador VSC/GMV. Foram considerados três degraus de referência durante o ensaio. Inicialmente a referência é de 130 mm, e posteriormente foi alterada para 160 mm e reduzida para 145 mm. O comportamento do sistema e à ação de controle do controlador VSC/GMV otimizado pelo PSO, IWAPSO e ACO são apresentadas nas Figuras 41, 42 e 43, respectivamente.



**Figura 41 – Planta Festo Nível - Controlador VSC/GMV otimizado pelo PSO (a) Resposta do sistema. (b) Ação de controle.**

**Fonte: Autoria própria.**

Analisando apenas as Figuras 41, 42 e 43, não é possível determinar qual método de otimização apresentou os melhores resultados, uma vez que qualitativamente os resultados são similares. Através dos índices  $J_E$  e  $J_U$  da Tabela 16, é determinado que o controlador VSC/GMV otimizado pelo ACO apresentou os melhores resultados, alcançando o melhor desempenho em relação ao índice  $J_U$  e o segundo melhor desempenho em relação ao índice  $J_E$ , porém muito próximo ao valor alcançado pelo PSO.




Figura 42 – Planta Festo Nível - Controlador VSC/GMV otimizado pelo IWAPSO (a) Resposta do sistema. (b) Ação de controle.

Fonte: Autoria própria.




Figura 43 – Planta Festo Nível - Controlador VSC/GMV otimizado pelo ACO (a) Resposta do sistema. (b) Ação de controle.

Fonte: Autoria própria.

Tabela 16 – Índices de desempenho para os controladores da Tabela 15 - Planta Festo Nível.

Controlador	$J_E$	$J_U$
PSO	$413,686 \cdot 10^{-3}$	$564,772 \cdot 10^{-3}$
IWAPSO	$422,180 \cdot 10^{-3}$	$505,285 \cdot 10^{-3}$
ACO	$416,746 \cdot 10^{-3}$	$490,854 \cdot 10^{-3}$


Fonte: Autoria própria.



Portanto, os próximos ensaios são considerados apenas os valores de  $\sigma$  e  $\varepsilon$  obtidos pelo ACO.

### 5.3.3.2 Ensaio 2 - Valores empíricos de $\sigma$ e $\varepsilon$

Um ensaio considerando valores empíricos para  $\sigma$  e  $\varepsilon$  é realizado para demonstrar o efeito desses valores no comportamento do sistema. As características deste ensaio são as mesmas do Ensaio 1. Foi escolhido empiricamente os valores de  $\sigma = 0,8$  e  $\varepsilon = 75$ . A comparação do comportamento do sistema entre valores de  $\sigma$  e  $\varepsilon$  otimizados e empíricos é apresentada na Figura 44. Ilustra-se na Figura 45 o comportamento da ação de controle aplicada no sistema.



**Figura 44 – Comportamento da resposta do sistema para os parâmetros com otimização e sem otimização - Planta Festo Nível.**


Fonte: Autoria própria.

Os índices de desempenho para este ensaio são apresentados na Tabela 17.

**Tabela 17 – Índices de desempenho para controlador empírico e otimizado pelo ACO - Planta Festo Nível.**

Controlador	$J_E$	$J_U$
ACO	$416,746 \cdot 10^{-3}$	$490,854 \cdot 10^{-3}$
Empírico	$465,04 \cdot 10^{-3}$	$1042,3 \cdot 10^{-3}$

Fonte: Autoria própria.



**Figura 45 – Comportamento da ação de controle para os parâmetros com otimização e sem otimização - Planta Festo Nível.**

**Fonte: Autoria própria.**


Observando-se apenas a Figura 44 tem-se a impressão que os controladores apresentam desempenho semelhante. Entretanto, a Figura 45 evidencia a vantagem que a otimização dos valores de  $\sigma$  e  $\varepsilon$  trás a comportamento da ação de controle do sistema. O índice  $J_U$  reforça esta afirmação, onde o valor de  $J_U$  para o controlador ajustado empiricamente chega a ser quase duas vezes mais elevado do que o controlador otimizado.

### 5.3.3.3 Ensaio 3 - Comparação com controlador PI

O controlador VSC/GMV foi comparado com um controlador PI em um ensaio com as mesmas características dos Ensaio 1 e 2. A resposta do sistema para os dois controladores é apresentada na Figura 46 e a ação de controle gerada pelos dois controladores é apresentada na Figura 47.


Realizando uma análise qualitativa do desempenho dos controladores, percebe-se que ambos apresentam desempenhos satisfatórios. Em destaque na Figura 46, observa-se que o controlador PI apresenta um pequeno sobressinal. Uma análise quantitativa do desempenho dos controladores pode-se ser realizada observando-se os índices  $J_E$  e  $J_U$ , apresentados na Tabela 18.

Observa-se que nestas condições de ensaio o controlador PI teve um melhor desempenho nos dois índices, principalmente em relação ao índice  $J_U$ . Essa diferença se deve às mudanças de referência existentes durante o ensaio. Em destaque na Figura



**Figura 46 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI - Planta Festo Nível.**

Fonte: Autoria própria.



**Figura 47 – Comportamento da ação de controle para os controladores VSC/GMV e PI - Planta Festo Nível.**

Fonte: Autoria própria.

Tabela 18 – Índices de desempenho para os controladores VSC/GMV e PI - Planta Festo Nível.

Controlador	$J_E$	$J_U$
PI	$411,229 \cdot 10^{-3}$	$422,423 \cdot 10^{-3}$
ACO	$416,746 \cdot 10^{-3}$	$490,854 \cdot 10^{-3}$

Fonte: Autoria própria.

47 percebe-se que o sinal de controle gerado pelo VSC/GMV apresenta uma frequências menor do que o sinal de controle do PI.

#### 5.3.3.4 Ensaio 4 - Comparação com controlador PI para uma única referência

Para verificar o comportamento dos controladores operando em regime, foi realizado um ensaio considerando apenas uma única referência de 170 mm, durante um maior período de tempo. Neste ensaio foi considerado um total de 4000 amostras, cinco vezes mais do que nos ensaios anteriores.

A resposta do sistema e da ação de controle gerada pelos controladores VSC/GMV e PI são ilustradas nas Figuras 48 e 49, respectivamente.





Figura 48 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI - Planta Festo Nível.

Fonte: Autoria própria.

Através das Figuras 48 e 49 percebe-se que os controladores apresentam um desempenho similar. Em destaque na Figura 49 percebe-se que à ação de controle do



**Figura 49 – Comportamento da ação de controle para os controladores VSC/GMV e PI - Planta Festo Nível.**

Fonte: Autoria própria.

controlador PI apresenta maiores oscilações do que a ação de controle do VSC/GMV. Os índices  $J_E$  e  $J_U$  para este ensaio são apresentados na Tabela 19. Para o cálculo de  $\sigma_y^2$  e  $\sigma_u^2$  foi considerado apenas após o momento que o sistema entrou em regime, em aproximadamente 45 segundos de ensaio, conforme indicado nas Figuras 48 e 49.

**Tabela 19 – Índices de desempenho para o ensaio com uma única referência - Planta Festo Nível.**

Controlador	$J_E$	$J_U$	$\sigma_y^2$	$\sigma_u^2$
PI	$278,41 \cdot 10^{-3}$	$258,63 \cdot 10^{-3}$	$0,482 \cdot 10^{-3}$	$111,33 \cdot 10^{-3}$
ACO	$280,52 \cdot 10^{-3}$	$100,54 \cdot 10^{-3}$	$0,582 \cdot 10^{-3}$	$193,7 \cdot 10^{-3}$


Fonte: Autoria própria.

O controlador VSC/GMV apresentou melhor desempenho no índice  $J_U$  em relação ao controlador PI e teve desempenho um pouco pior em relação ao  $J_E$ . A diferença em relação ao índice  $J_E$  é devido ao início do ensaio, onde o controlador PI apresentou um tempo de subida menor do que o controlador VSC/GMV.

A variância da variável medida em regime para os dois controladores apresentou valores pequenos, com uma pequena vantagem para o controlador PI. Já a variância da ação de controle do controlador PI foi menor do que a do controlador VSC/GMV. Porém, o índice  $J_U$  aponta que o controlador PI apresentou maior variação entre os valores de ação

de controle gerados pelo controlador. Concluí-se que o controlador VSC/GMV apresenta uma menor variação entre os valores de ação de controle, porém esses valores estão mais afastado do valor médio de ação de controle durante este ensaio (5,8564). Já ação de controle do controlador PI apresenta uma maior variação entre seus valores, porém essa variação ocorre mais próxima da média do ensaio em regime (5,8925). Pode-se observar este fato através das ilustrações em destaque nas Figuras 47 e 49, onde é possível verificar que as oscilações apresentadas pelo controlador PI apresenta uma frequência maior do que as do controlador VSC/GMV.

Um comparativo dos índices  $J_E$  e  $J_U$  durante a realização do ensaio é apresentado nas Tabelas 20 e 21. Ilustra-se através da Figura 50(a) o comportamento do índice  $J_E$  e através da Figura 50(b) o comportamento do índice  $J_U$  durante o ensaio.



**Figura 50 – Planta Festo Nível - (a) Comportamento do índice  $J_E$  (b) Comportamento do índice  $J_U$ .**  
Fonte: Autoria própria.

**Tabela 20 – Comparação do comportamento do índice  $J_E$  durante o ensaio - Planta Festo Nível.**

	100	1000	2000	3000	4000
$J_{EPI}$	$269,82 \cdot 10^{-3}$	$278,05 \cdot 10^{-3}$	$278,17 \cdot 10^{-3}$	$278,29 \cdot 10^{-3}$	$278,41 \cdot 10^{-3}$
$J_{EACO}$	$272,98 \cdot 10^{-3}$	$280,08 \cdot 10^{-3}$	$280,22 \cdot 10^{-3}$	$280,38 \cdot 10^{-3}$	$280,52 \cdot 10^{-3}$
$J_{EACO} - J_{EPI}$	$3,16 \cdot 10^{-3}$	$2,03 \cdot 10^{-3}$	$2,05 \cdot 10^{-3}$	$2,09 \cdot 10^{-3}$	$2,11 \cdot 10^{-3}$

Fonte: Autoria própria.

Através da Figura 50(a) e dos valores da Tabela 20 percebe-se que a diferença existente no valor de  $J_E$  entre os controladores é devido ao início do ensaio. Quando o sistema entre em regime, os dois controladores apresentam desempenho praticamente idêntico, e a diferença entre  $J_E$  é praticamente inalterada.

**Tabela 21 – Comparação do comportamento do índice  $J_U$  durante o ensaio - Planta Festo Nível.**

	100	1000	2000	3000	4000
$J_{UPI}$	$25,00 \cdot 10^{-3}$	$74,54 \cdot 10^{-3}$	$133,91 \cdot 10^{-3}$	$196,83 \cdot 10^{-3}$	$258,63 \cdot 10^{-3}$
$J_{UACO}$	$34,75 \cdot 10^{-3}$	$49,36 \cdot 10^{-3}$	$65,02 \cdot 10^{-3}$	$83,03 \cdot 10^{-3}$	$100,54 \cdot 10^{-3}$
$J_{UPI} - J_{UACO}$	$-9,75 \cdot 10^{-3}$	$25,18 \cdot 10^{-3}$	$68,89 \cdot 10^{-3}$	$113,8 \cdot 10^{-3}$	$158,09 \cdot 10^{-3}$

Fonte: Autoria própria.

Através da Figura 50(b) e dos valores da Tabela 21 percebe-se que no início do ensaio o controlador PI apresenta vantagem em relação ao controlador VSC/GMV. Porém, com o sistema em regime, o controlador VSC/GMV mostra-se superior e a diferença de desempenho em relação ao índice  $J_U$  é cada vez maior.

#### 5.3.3.5 Ensaio 5 - Comparação com controlador PI na presença de perturbação

Neste ensaio é realizada uma perturbação no sistema e o comportamento do controlador VSC/GMV é novamente comparado ao controlador PI. A referência de nível neste ensaio é de 190 mm. Com aproximadamente 60 segundos de ensaio as válvulas manuais V-36 e V-37 são abertas, aumentando a vazão total de saída do sistema em aproximadamente 36%. Cerca de 40 segundos após a inserção da perturbação, as válvulas são fechadas, normalizando a vazão do sistema.

Mostra-se nas Figuras 51 e 52 a resposta do sistema e o comportamento da ação de controle aplicada no sistema. Percebe-se que ambos os controladores conseguem seguir a referência sem maiores problemas.

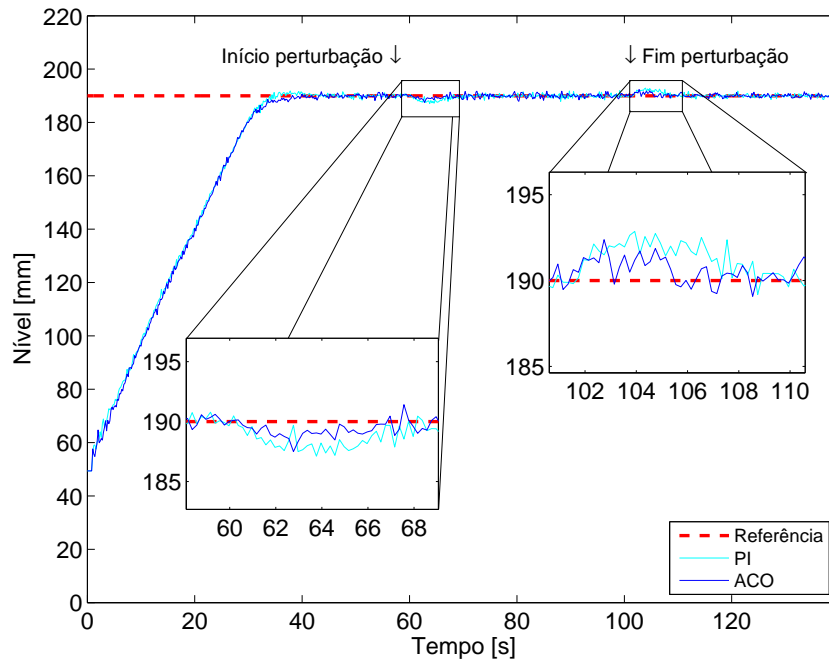
Os índices de desempenho podem ser observados na Tabela 22. A análise foi realizada somente no intervalo em que a perturbação estava inserida. O intervalo de análise foi definido considerando-se 50 amostras antes da inserção da perturbação até 50 amostras após a retirada da mesma.

**Tabela 22 – Índices de desempenho para o ensaio com a presença de perturbação - Planta Festo Nível.**

Controlador	$J_E$	$J_U$
PI	$2,111 \cdot 10^{-2}$	$437,85 \cdot 10^{-3}$
ACO	$1,216 \cdot 10^{-2}$	$173,92 \cdot 10^{-3}$


Fonte: Autoria própria.

Analisando os valores da Tabela 22, observa-se que o controlador VSC/GMV apresentou melhor desempenho em ambos os índices para este ensaio.



**Figura 51 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI com a presença de perturbação - Planta Festo Nível.**

Fonte: Autoria própria.



**Figura 52 – Comportamento da ação de controle para os controladores VSC/GMV e PI com a presença de perturbação - Planta Festo Nível.**

Fonte: Autoria própria.



Em relação à malha de controle de nível, com exceção do ensaio 5, pode-se observar que os resultados obtidos pelo controlador PI apresentaram melhor desempenho em relação ao índice  $J_E$  que o controlador VSC/GMV.

Buscou-se então melhorar o desempenho do controlador VSC/GMV em relação ao índice  $J_E$ . Para isto, os valores de  $\alpha_1$  e  $\alpha_2$  das Tabelas 3, 4 e 5 foram invertidos, para a obtenção de novos parâmetros  $\sigma$  e  $\varepsilon$ .

Os resultados obtidos pelas metaheurísticas após a inversão dos valores de  $\alpha_1$  e  $\alpha_2$  são apresentados na Tabela 23.

**Tabela 23 – Comparação entre o desempenho dos métodos de otimização com  $\alpha_1 = 2$  e  $\alpha_2 = 1$  - Planta Festo Nível.**

	PSO	IWAPSO	ACO
$\sigma$	0,4130	0,4102	0,4145
$\varepsilon$	159,74	161,94	160,05
$J_{opt}$	55,593	55,649	55,622
Tempo de execução (s)	86,90	91,96	107,98

Fonte: Autoria própria.

Em seguida, o Ensaio 1 foi repetido com as mesmas características apresentadas anteriormente, mas com os novos valores de  $\sigma$  e  $\varepsilon$  da Tabela 23. Os índices  $J_E$  e  $J_U$  são apresentados na Tabela 24.


**Tabela 24 – Índices de desempenho para os controladores da Tabela 23 - Planta Festo Nível.**

Controlador	$J_E$	$J_U$
PSO	$380,55 \cdot 10^{-3}$	$552,57 \cdot 10^{-3}$
IWAPSO	$390,95 \cdot 10^{-3}$	$539,02 \cdot 10^{-3}$
ACO	$377,30 \cdot 10^{-3}$	$555,44 \cdot 10^{-3}$

Fonte: Autoria própria.

Os índices apresentados na Tabela 24 apontam que os três métodos de otimização alcançaram desempenho similares. Ilustra-se na Figura 53 apenas o comportamento do controlador VSC/GMV otimizado pelo ACO.

Comparando os valores da Tabelas 16 e 24 observa-se que houve uma redução nos valores do índice  $J_E$  em todos os ensaios. Por outro lado, observando o índice  $J_U$  verifica-se que ocorreu um aumento entre os valores das Tabelas 16 e 24. Tais valores de  $J_U$  continuam superiores ao valor apresentado pelo controlador PI (Tabela 18). Como explicado anteriormente, isto ocorre devido ao *ringing* existente nas mudanças aplicadas durante o ensaio.



**Figura 53 – Planta Festo Nível - Controlador VSC/GMV otimizado pelo PSO com  $\alpha_1 = 2$  e  $\alpha_2 = 1$  (a) Resposta do sistema. (b) Ação de controle.**


Fonte: Autoria própria.

#### 5.4 PLANTA DIDÁTICA FESTO - CONTROLE DE VAZÃO

Assim como no controle de nível, foi utilizada a planta didática da Festo para controlar o processo de vazão. Balbinot e Brusamarello (2011) afirmam que a medição de vazão é essencial para garantir eficiência e economia em processos industriais, destacando-se processos de distribuição de água, distribuição de combustível e extração de óleo. Na Figura 54 é apresentada uma imagem da malha de vazão utilizada neste experimento e a através da Figura 55 é apresentado o diagrama do processo com seus principais elementos.

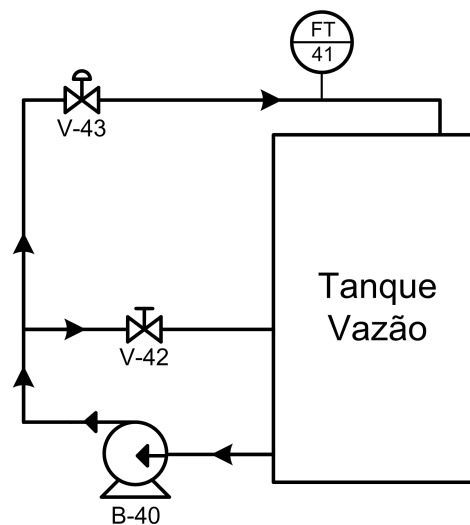
Neste experimento o elemento de controle final é uma válvula proporcional, uma vez que a bomba centrífuga é acionada em sua potência máxima durante este experimento. Através da válvula proporcional é possível controlar o fluxo através da mesma, com a aplicação de um sinal de controle. Através da placa de aquisição de dados, é fornecida uma tensão de 0 até 10 V para a válvula, aumentando ou diminuindo a vazão que percorre a tubulação. Durante os ensaios, foi possível notar que para um tensão menor do que 5,5 V a vazão de água que percorria o sistema era inexistente. Portanto, é considerado o valor de 5,5 V como tensão mínima a ser aplicada no sistema.

A vazão de água é medida por meio de um sensor do tipo redemoinho. Através do fluxo de água, as pás internas do equipamento giram proporcionalmente a este fluxo, gerando pulsos cuja frequência também é proporcional à rotação das pás. Um condicionador de sinais produz uma tensão de 0 até 10 V proporcional à frequência dos pulsos. Esta tensão é inserida em uma entrada analógica da placa de aquisição.



**Figura 54 – Malha de controle de vazão.**

Fonte: Autoria própria.



**Figura 55 – Diagrama da malha de controle com seus principais elementos - Planta Festo Vazão.**


Fonte: Autoria própria.

#### 5.4.1 Identificação do sistema

Para realizar a identificação do sistema, foi aplicado um degrau de 10 V na válvula proporcional, proporcionando o máximo de abertura da mesma. É importante lembrar que a bomba centrífuga já estava acionada antes da inserção deste degrau. Na Figura 56(a) o comportamento do sistema para este degrau é apresentado e na Figura 56(b) é realizada

uma comparação visual entre duas estruturas diferentes obtidas através do método dos mínimos quadrados.

Os dados de entrada para este ensaio são em relação à tensão na válvula proporcional. Já os dados de saída utilizados nesta etapa de identificação foi o valor de tensão medido pelo sensor de vazão.



**Figura 56 – Planta Festo Vazão - (a) Resposta do sistema para um degrau de 10 V. (b) Comparação entre a resposta do sistema e as respostas estimadas.**

Fonte: Autoria própria.

Através da Tabela 25 é possível realizar a comparação quantitativa e escolher a estrutura que melhor representa o comportamento do sistema.

**Tabela 25 – Valor de MSE para diferentes estruturas - Planta Festo Vazão.**

Estrutura	MSE
$n_a=2$ $n_b=1$	0,0026
$n_a=3$ $n_b=1$	0,0033


Fonte: Autoria própria.

Portanto o modelo com  $n_a = 2$  e  $n_b = 1$  apresentou um erro quadrático médio menor em relação aos dados do sistema. Na Equação 52 é apresentada o modelo discreto que representa este sistema, considerando  $d = 3$ .

$$y(k) = 0,5106y(k-1) + 0,4241y(k-2) - 0,0026u(k-3) + 0,0153u(k-4) \quad (52)$$

Para o projeto do controlador VSC/GMV nesta malha de controle foi considerado  $W(z^{-1}) = 1 - 2,1z^{-1} + 1,4175z^{-2} - 3038z^{-3}$  e  $T_s = 0,015$ .

A curva de ganho estático da malha de vazão é apresentada na Figura 57.



**Figura 57 – Curva de ganho estático - Planta Festo Vazão.**

Fonte: Autoria própria.

Para valores de entrada menores do que 7 V, o valor medido na saída era praticamente nulo. Durante a experimentação, pode-se observar que para valores entre 5,5 e 7 V, existia uma quantidade mínima de água circulando no sistema. Porém o sensor de vazão não foi capaz de medir a vazão do sistema para este *range* de entrada.

#### 5.4.2 Otimização dos parâmetros $\sigma$ e $\varepsilon$

Assim como nos outros sistemas, foram utilizados o ACO e o PSO para encontrar os valores de  $\sigma$  e  $\varepsilon$  que apresentem o melhor desempenho baseado na função custo representada pela Equação 45. Os parâmetros dos algoritmos de otimização são os mesmos utilizados anteriormente, apresentados nas Tabelas 3, 4 e 5.

As simulações realizadas durante o procedimento de otimização são compostas na aplicação de três degraus de referência, sendo eles: 1,4 l/min, 1,8 l/min e 1,6 l/min. Foram realizadas 15 simulações, onde cada simulação é composta por 80 iterações. Em cada simulação foi acrescentado um ruído aleatório uniforme com amplitude de  $\pm 1\%$  no sinal de saída do sistema.

Os resultados obtidos pelos métodos de otimização são apresentados na Tabela 26, onde foram considerado o valor médio de  $\sigma$ ,  $\varepsilon$  e  $J_{opt}$  entre as 15 simulações.

Tabela 26 – Comparação entre o desempenho dos métodos de otimização - Planta Festo Vazão.

	PSO	IWAPSO	ACO
$\sigma$	0,4008	0,4009	0,3904
$\varepsilon$	297,84	288,98	305,69
$J_{opt}$	8,0909	8,1283	7,9425
Tempo de execução (s)	68,55	69,02	82,55

Fonte: Autoria própria.

Observa-se que os valores dos parâmetros obtidos pelos três métodos são próximos entre si. Com os valores otimizados, foram realizadas simulações para verificar o comportamento do sistema para estes valores. Os resultados são ilustrados na Figura 58.




Figura 58 – Comportamento da resposta do sistema em simulação para os valores otimizados - Planta Festo Vazão.


Fonte: Autoria própria.

#### 5.4.3 Resultados experimentais

A seguir são apresentados diferentes ensaios realizados para verificar o comportamento do controlador VSC/GMV. Mostram-se cinco diferentes ensaios para analisar o comportamento do controlador VSC/GMV. Nestes ensaios são considerados vários pontos de operação, mudanças de referência, análise do comportamento do sistema em regime permanente e o comportamento do controlador com a presença de uma perturbação. Também são realizadas comparações com o controlador PI em alguns destes ensaios.


### 5.4.3.1 Ensaio 1 - Valores otimizados de $\sigma$ e $\varepsilon$

Os valores otimizados apresentados na Tabela 26 foram aplicados no controle do sistema. Foram considerados quatro degraus de referência em intervalos de aproximadamente 7,5 segundos. Inicialmente a referência é de 1,2 l/min, depois é alterada para 1,5 l/min, 1,3 l/min e 1,6 l/min. As Figuras 59, 60 e 61 apresentam a resposta do sistema para cada um dos métodos de otimização.




**Figura 59 – Planta Festo Vazão - Controlador VSC/GMV otimizado pelo PSO (a) Resposta do sistema. (b) Ação de controle.**

Fonte: Autoria própria.



**Figura 60 – Planta Festo Vazão - Controlador VSC/GMV otimizado pelo IWAPSO (a) Resposta do sistema. (b) Ação de controle.**

Fonte: Autoria própria.



**Figura 61 – Planta Festo Vazão - Controlador VSC/GMV otimizado pelo ACO (a) Resposta do sistema. (b) Ação de controle.**

Fonte: Autoria própria.

Na Tabela 27 os índices de desempenho  $J_E$  e  $J_U$  são apresentados para todos os métodos.

**Tabela 27 – Índices de desempenho para os controladores da Tabela 26 - Planta Festo Vazão.**

<b>Controlador</b>	$J_E$	$J_U$
PSO	$9,3219 \cdot 10^{-3}$	$98,7983 \cdot 10^{-3}$
IWAPSO	$9,3771 \cdot 10^{-3}$	$97,4230 \cdot 10^{-3}$
ACO	$9,5084 \cdot 10^{-3}$	$99,6953 \cdot 10^{-3}$


Fonte: Autoria própria.

Observando-se apenas as Figuras 59, 60 e 61 percebe-se que todos os métodos apresentaram respostas similares. Através dos índices da Tabela 27, conclui-se que o desempenho do controlador VSC/GMV otimizado pelo IWAPSO apresentou uma pequena vantagem em relação aos outros métodos. Portanto, os ensaios a seguir levam em consideração apenas os valores de  $\sigma$  e  $\varepsilon$  do controlador VSC/GMV obtidos através do IWAPSO.

#### 5.4.3.2 Ensaio 2 - Valores empíricos de $\sigma$ e $\varepsilon$


Como ilustração, foi realizado um ajuste empírico dos valores de  $\sigma$  e  $\varepsilon$  para avaliar o comportamento do sistema. As características deste ensaio são as mesmas do Ensaio 1. É ilustrado nas Figuras 62 e 63 uma comparação do comportamento da resposta do sistema e o comportamento da ação de controle que é aplicada no sistema para valores de  $\sigma = 0,7$  e  $\varepsilon = 230$  e os valores otimizados pelo ACO. Os índices  $J_E$  e  $J_U$  são apresentados na Tabela 28.





**Figura 62 – Comportamento da resposta do sistema para os parâmetros com otimização e sem otimização - Planta Festo Vazão.**

Fonte: Autoria própria.



**Figura 63 – Comportamento da ação de controle para os parâmetros com otimização e sem otimização - Planta Festo Vazão.**

Fonte: Autoria própria.

**Tabela 28 – Índices de desempenho para controlador empírico e otimizado pelo IWAPSO - Planta Festo Vazão.**


Controlador	$J_E$	$J_U$
IWAPSO	$9,3771 \cdot 10^{-3}$	$97,4230 \cdot 10^{-3}$
Empírico	$11,7034 \cdot 10^{-3}$	$1303,00 \cdot 10^{-3}$

Fonte: Autoria própria.

Os resultados apresentados pelas Figuras 62 e 63 e pela Tabela 28 comprovam que o controlador otimizado apresenta um melhor desempenho do que o controlador ajustado empiricamente. Nesta situação, o controlador otimizado apresentou um melhor comportamento do sinal de controle.


#### 5.4.3.3 Ensaio 3 - Comparação com controlador PI

Também é realizado um ensaio comparativo entre o controlador obtido através do IWAPSO e um controlador PI. As características deste ensaio são as mesmas utilizadas no Ensaio 1. Nas Figuras 64 e 65 são apresentados o comportamento do sistema para o teste de seguimento de referência e o comportamento da ação de controle que atua no sistema. Os índices de desempenho deste ensaio são apresentados na Tabela 29.



**Figura 64 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI - Planta Festo Vazão.**

Fonte: Autoria própria.



**Figura 65 – Comportamento da ação de controle para os controladores VSC/GMV e PI - Planta Festo Vazão.**

Fonte: Autoria própria.

Observando-se a Figura 64 fica claro que o controlador VSC/GMV apresenta um tempo de subida e um tempo de resposta menor do que o controlador PI. O tempo de acomodação do controlador VSC/GMV foi de aproximadamente 6 vezes menor do que o controlador PI. Em destaque na Figura 64, é possível verificar que em regime os controladores apresentam desempenho similar.

Através da Figura 65 comprova-se que a ação de controle do controlador VSC/GMV apresentou uma menor variação do que a ação de controle gerada pelo controlador PI, exceto nos instantes onde ocorre a mudança de referência.

**Tabela 29 – Índices de desempenho para os controladores VSC/GMV e PI - Planta Festo Vazão.**

<b>Controlador</b>	$J_E$	$J_U$
PI	$21,8632 \cdot 10^{-3}$	$209,1448 \cdot 10^{-3}$
IWAPSO	$9,3771 \cdot 10^{-3}$	$97,4230 \cdot 10^{-3}$


Fonte: Autoria própria.

Observa-se através dos índices da Tabela 29 que o controlador VSC/GMV apresentou o melhor desempenho. Nos dois índices,  $J_E$  e  $J_U$ , os valores destes índices do controlador VSC/GMV foram duas vezes menores do que o controlador PI.

#### 5.4.3.4 Ensaio 4 - Comparação com controlador PI para uma única referência

Neste ensaio, será considerada uma referência fixa durante todo o ensaio (1,5 l/min). Além disto, este ensaio será realizado por mais tempo. Nos Ensaios 1, 2 e 3, foram consideradas 2000 amostras. Já no Ensaio 4 é considerado um total de 6000 amostras, ou seja, uma duração três vezes maior do que os ensaios anteriores.

O comportamento da resposta do sistema e da ação de controle gerada pelos controladores VSC/GMV e PI são ilustradas nas Figuras 66 e 67, respectivamente.



**Figura 66 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI - Planta Festo Vazão.**

Fonte: Autoria própria.

A Tabela 30 apresenta os índices de desempenho para este ensaio. Para o cálculo de  $\sigma_y^2$  e  $\sigma_u^2$  foi considerado apenas após o momento que o sistema entrou em regime de operação, em aproximadamente 12 segundos de ensaio.

**Tabela 30 – Índices de desempenho para o ensaio com uma única referência - Planta Festo Vazão.**


Controlador	$J_E$	$J_U$	$\sigma_y^2$	$\sigma_u^2$
PI	$16,143 \cdot 10^{-3}$	$205,17 \cdot 10^{-3}$	$0,3626 \cdot 10^{-3}$	$105,91 \cdot 10^{-3}$
IWAPSO	$5,4533 \cdot 10^{-3}$	$41,648 \cdot 10^{-3}$	$0,3429 \cdot 10^{-3}$	$62,552 \cdot 10^{-3}$

Fonte: Autoria própria.

Através da Figura 66 percebe-se que o controlador VSC/GMV novamente apresentou um menor tempo de acomodação e de subida do que o controlador PI. Destaca-se

na Figura 67 que o comportamento da ação de controle gerada pelo VSC/GMV apresenta menos oscilações do que à ação de controle do controlador PI.


Em todos os índices apresentados pela Tabela 30 o controlador VSC/GMV mostrou-se superior ao controlador PI, principalmente em relação aos índices referente à ação de controle.



**Figura 67 – Comportamento da ação de controle para os controladores VSC/GMV e PI - Planta Festo Vazão.**

Fonte: Autoria própria.

Ilustra-se na Figura 68 o comportamento dos índice  $J_E$   $J_U$  durante o ensaio.



**Figura 68 – Planta Festo Vazão - (a) Comportamento do índice  $J_E$  (b) Comportamento do índice  $J_U$ .**

Fonte: Autoria própria.

Um comparativo dos índices  $J_E$  e  $J_U$  durante a realização do ensaio é apresentado nas Tabelas 31 e 32.

**Tabela 31 – Comparação do comportamento do índice  $J_E$  durante o ensaio - Planta Festo Vazão.**

	100	1500	3000	4500	6000
$J_{EPI}$	$12,05 \cdot 10^{-3}$	$15,85 \cdot 10^{-3}$	$15,96 \cdot 10^{-3}$	$16,04 \cdot 10^{-3}$	$16,14 \cdot 10^{-3}$
$J_{EIWAPSO}$	$5,111 \cdot 10^{-3}$	$5,195 \cdot 10^{-3}$	$5,273 \cdot 10^{-3}$	$5,360 \cdot 10^{-3}$	$5,453 \cdot 10^{-3}$
$J_{EPI} - J_{EIWAPSO}$	$6,939 \cdot 10^{-3}$	$10,654 \cdot 10^{-3}$	$10,687 \cdot 10^{-3}$	$10,680 \cdot 10^{-3}$	$10,687 \cdot 10^{-3}$

Fonte: Autoria própria.

**Tabela 32 – Comparação do comportamento do índice  $J_U$  durante o ensaio - Planta Festo Vazão.**

	100	1500	3000	4500	6000
$J_{UPI}$	$21,93 \cdot 10^{-3}$	$66,55 \cdot 10^{-3}$	$112,55 \cdot 10^{-3}$	$153,79 \cdot 10^{-3}$	$205,1 \cdot 10^{-3}$
$J_{UIWAPSO}$	$6,965 \cdot 10^{-3}$	$15,35 \cdot 10^{-3}$	$23,51 \cdot 10^{-3}$	$32,01 \cdot 10^{-3}$	$41,65 \cdot 10^{-3}$
$J_{UPI} - J_{UIWAPSO}$	$14,96 \cdot 10^{-3}$	$51,19 \cdot 10^{-3}$	$89,04 \cdot 10^{-3}$	$121,78 \cdot 10^{-3}$	$163,45 \cdot 10^{-3}$

Fonte: Autoria própria.


Analisando as Figuras 66 e 68(a) e os resultados da Tabela 31 concluí-se que a grande diferença em relação ao índice  $J_E$  entre o controlador VSC/GMV e o controlador PI, é devido ao período inicial do ensaio. Uma vez que o sistema entra em regime ambos os controladores apresentam desempenho semelhante, em relação ao índice  $J_E$ .

Analisando as Figuras 67 e 68(b) e os resultados da Tabela 32 percebe-se uma grande vantagem do controlador VSC/GMV em relação ao controlador PI durante todo o ensaio. Se fosse realizado o ensaio por mais tempo, essa diferença de desempenho seria ainda maior.

#### 5.4.3.5 Ensaio 5 - Comparação com controlador PI na presença de perturbação


Outro ensaio realizado foi uma comparação entre o controlador VSC/GMV e o controlador PI operando em regime perante uma perturbação. A referência durante o ensaio é de 1,5 l/min. É inserido uma perturbação no sistema através da bomba centrífuga que é responsável por enviar água através da tubulação. Em aproximadamente 9 segundos de ensaio a tensão aplicada na bomba é reduzida em 15%. Após cerca de 3 segundos, a bomba volta à condição normal de operação. O comportamento do sistema é apresentado na Figura 69 e à ação de controle é ilustrada na Figura 70.

Percebe-se através das Figuras que o controlador VSC/GMV conseguiu controlar o processo com a inserção desta perturbação. Já o controlador PI não conseguiu seguir



**Figura 69 – Comportamento da resposta do sistema para os controladores VSC/GMV e PI com a presença de perturbação - Planta Festo Vazão.**

Fonte: Autoria própria.



**Figura 70 – Comportamento da ação de controle para os controladores VSC/GMV e PI com a presença de perturbação - Planta Festo Vazão.**

Fonte: Autoria própria.

a referência com a perturbação inserida no sistema. Quando a perturbação foi retirada, a resposta do sistema demorou para alcançar a referência. Durante o período em que a perturbação está presente, à ação de controle dos dois controladores apresentam maiores oscilações. Porém à ação de controle do controlador PI se degrada muito, refletindo na resposta do sistema.

Os índices de desempenho podem ser observados na Tabela 33. A análise foi realizada somente no intervalo em que a perturbação estava inserida no processo. O intervalo de análise foi definido considerando-se 100 amostras antes da inserção da perturbação até 100 amostras após a retirada da mesma.

**Tabela 33 – Índices de desempenho para o ensaio com a presença de perturbação - Planta Festo Vazão.**

<b>Controlador</b>	$J_E$	$J_U$
PI	$27,483 \cdot 10^{-3}$	$711,02 \cdot 10^{-3}$
IWAPSO	$1,161 \cdot 10^{-3}$	$81,468 \cdot 10^{-3}$

**Fonte: Autoria própria.**

O controlador VSC/GMV apresentou um índice  $J_E$  cerca de 23 vezes menor que o controlador PI e um índice  $J_U$  cerca de 8,7 vezes menor que o controlador PI. Portanto, neste ensaio, o controlador VSC/GMV apresentou um desempenho superior ao controlador PI.

Os resultados apresentados neste capítulo mostram que o controlador VSC/GMV é capaz de apresentar um desempenho satisfatório no controle de processos em tempo real. Em todos os ensaios o controlador VSC/GMV foi capaz de alcançar a referência e também conseguiu rejeitar a perturbação inserida durante alguns ensaios. Baseado nas comparações com o controlador PI, o controlador VSC/GMV apresentou como principal vantagem a baixa variação no sinal de controle nos ensaios em regime permanente. Tais resultados abrem perspectivas para que no futuro este controlador possa ser aplicado em processos industriais.



## 6 CONSIDERAÇÕES FINAIS

O presente trabalho apresentou um estudo sobre o controlador de estrutura variável via projeto GMV (VSC/GMV), apresentado em Sumar (2002). Este controlador é baseado na estrutura R-S-T e sua ação de controle é composta por duas parcelas distintas: uma parcela linear calculada pelo GMV e uma parcela não linear calculada pela estrutura variável.

A parcela não linear do controlador é gerada pela estrutura variável. Esta parcela depende diretamente de dois parâmetros ( $\sigma$  e  $\varepsilon$ ) para calcular sua contribuição no sinal de controle total. Para obter os valores destes parâmetros, foram aplicadas metaheurísticas populacionais.

Foram consideradas duas metaheurísticas neste trabalho: o ACO baseado nos trabalhos de Socha (2008) e Socha e Dorigo (2008) e o PSO de Shi e Eberhart (1998). Também foi utilizado o IWAPSO, apresentado em Mohamed, Rao e Hasan (2010), porém este método é considerado apenas uma variação do PSO original. A partir destas metaheurísticas, foi possível obter valores de  $\sigma$  e  $\varepsilon$  do controlador VSC/GMV que minimizam uma função custo composta pelo erro de rastreamento e pela variação da ação de controle. Os valores de  $\sigma$  e  $\varepsilon$  obtidos pelas metaheurísticas foram avaliados em simulações e posteriormente em situações práticas.

Para avaliar o desempenho dos controladores foram utilizados índices para medir o erro de rastreamento do sistema e a variação da ação de controle. Tais índices comprovaram o melhor desempenho do controlador VSC/GMV otimizado pelas metaheurísticas em relação a um controlador com os parâmetros  $\sigma$  e  $\varepsilon$  escolhidos empiricamente.

Na malha de controle de velocidade de um motor de corrente contínua, o controlador VSC/GMV apresentou uma grande vantagem em relação ao controlador PI principalmente em regime permanente. Nesta situação o VSC/GMV apresentou uma menor variação da ação de controle e uma menor variância, tanto no sinal medido na saída como no sinal de controle aplicado no processo. Nesta malha de controle, o controlador PI apresentou melhor desempenho em relação ao índice  $J_E$  em todos os ensaios. Isto ocorre devido ao menor tempo de subida deste controlador, conforme demonstrado no ensaio em regime permanente. Entretanto o controlador PI apresentou sobressinal em diversos ensaios.

Na malha nível, o Ensaio 4 demonstrou que o controlador VSC/GMV apresentou melhor desempenho em relação ao índice  $J_U$  do que o controlador PI. Ou seja, os valores de tensão que são aplicados na bomba centrífuga nos intervalos amostrais variam menos entre as iterações. Desta maneira, ocorre menos variação no fluxo eletromagnético

produzido pelo circuito de armadura da máquina, causando menos desgaste mecânico e, possivelmente, aumentando a vida útil do atuador.

Nos demais ensaios foi observado que o controlador PI apresentou melhor desempenho em relação ao índice  $J_E$ . Para tentar melhorar o desempenho do controlador VSC/GMV, os valores de  $\alpha_1$  e  $\alpha_2$ , utilizados na função custo das metaheurísticas, foram invertidos. Os novos valores obtidos de  $\sigma$  e  $\varepsilon$  foram testados e os resultados apontaram uma redução do índice  $J_E$ , mostrando que a qualidade dos resultados é sensível à escolha dos parâmetros  $\sigma$  e  $\varepsilon$ .

No início do projeto do controlador da malha de nível, foi considerado um valor de  $d = 1$  para facilitar o projeto do mesmo. Foi observado que o controlador foi capaz de seguir a referência, porém apresentava uma oscilação considerável em torno dela. O sinal de controle aplicado na bomba apresentava características de um controle *bang-bang*, podendo causar desgaste ao equipamento no futuro. O valor de  $d = 5$  foi obtido através da observação da resposta de malha aberta do sistema e se mostrou a melhor escolha para este valor, baseado no comportamento do controlador. Portanto, verificou-se que a escolha errada do valor de  $d$  afeta o comportamento do controlador.

Já na malha de vazão o controlador VSC/GMV apresentou uma grande superioridade ao controlador PI utilizados nos ensaios. O VSC/GMV apresentou um menor tempo de subida (sem apresentar sobressinal) e menor variação da ação de controle em todos os ensaios. Além disto, no Ensaio 5, constatou-se que o controlador VSC/GMV conseguiu seguir a referência mesmo com a aplicação de uma perturbação no sistema, enquanto que o controlador PI não conseguiu tal feito.

Observando-se os índices de desempenho e os gráficos contendo a resposta do sistema e o sinal de controle aplicado nas malhas, constatou-se que o VSC/GMV apresentou bons resultados. Em todos os ensaios o controlador foi capaz de seguir a referência sem apresentar sobressinal, além de não apresentar oscilações significativas em torno da referência. Conclui-se através dos experimentos práticos, que mesmo com o ruído existente no sinal, o controlador VSC/GMV apresentou um bom desempenho. Em todos os ensaios o VSC/GMV alcançou resultados adequados. As comparações com o controlador PI clássico mostraram que o VSC/GMV apresentou como grande vantagem uma menor variação do sinal de controle aplicado no processo, medido pelo índice de desempenho  $J_U$ .

Um grande problema do controlador VSC/GMV observado foi o *ringing* existente quando ocorre a mudança de referência do sistema. Mesmo alocando os polos de malha fechada do sistema sobre o eixo real positivo do plano- $z$ , foi observado a ocorrência de *ringing*. Além disto, quanto maior o valor de  $d$  considerado, maior era a ocorrência de

*ringing* nas mudanças de referência, deteriorando a eficiência do controlador nestas situações. Porém, com o sistema operando em regime permanente, o controlador VSC/GMV apresentou melhor desempenho em todos os ensaios em relação ao índice  $J_U$ .

## 6.1 PROPOSTAS DE CONTINUIDADE

- Utilizar uma abordagem multiobjetivo no processo de otimização dos valores de  $\sigma$  e  $\varepsilon$ .
- Flexibilizar o projeto do controlador VSC/GMV para que este possa ser implementado em linguagem Ladder ou texto estruturado, para posteriormente ser embarcado em um CLP.
- Comparar o controlador VSC/GMV com outras técnicas de controle preditivo, como o GPC.
- Observar o comportamento do controlador com a presença de filtros nas saídas dos sensores. Nas simulações realizadas sem a inserção de ruídos, o controlador VSC/GMV apresentou excelente desempenho, principalmente em regime permanente. Constatou-se também que o ruído inserido em simulação prejudicava mais o controlador VSC/GMV do que o controlador PI.
- Investigar alguma estratégia para diminuir o *ringing* apresentado pelo VSC/GMV nas mudanças de referência e as saturações ocorridas no sinal de controle.

## 6.2 ARTIGO PRODUZIDO

O desenvolvimento deste trabalho de mestrado resultou na elaboração do seguinte artigo:

BERTACHI, A. H.; SUMAR, R. R.; ANGÉLICO, B. A. Otimização dos parâmetros de um controlador de estrutura variável discreto através da metaheurística de otimização por exame de partículas. In: **XI Simpósio Brasileiro de Automação Inteligente (SBAI 2013)**. Fortaleza - CE: 2013 (Publicado).



## REFERÊNCIAS

- AGUIRRE, L. A. **Enciclopédia de automática: controle e automação**. São Paulo, SP: Blucher, 2007.
- AGUIRRE, L. A. **Introdução à identificação de sistemas**. 3. ed. Belo Horizonte, MG: Editora UFMG, 2007.
- ALMEIDA, J. P. L. S. de. **Automação de uma planta didática de sistemas de controle**. Trabalho de Conclusão de Curso (Graduação) — Curso Superior de Tecnologia em Automação Industrial. Universidade Tecnológica Federal do Paraná: Cornélio Procópio, 2012.
- ÅSTRÖM, K.; HÄGGLUND, T. **PID controllers: theory, design and tuning**. 2nd. ed. Research Triangle Park: Instrument Society of America, 1995.
- ÅSTRÖM, K.; HÄGGLUND, T. IFAC workshop on digital control: Past, present and future of PID control. **Benchmark Systems for PID Control**, Terrassa - Espanha, p. 181–182, 2000.
- ÅSTRÖM, K.; HÄGGLUND, T. The future of PID control. **Control Engineering Practice**, v. 9, n. 1, p. 1163 – 1175, 2001.
- ÅSTRÖM, K.; HÄGGLUND, T.; HANG, C.; HO, W. Automatic tuning and adaptation for PID controllers - A survey. **Control Engineering Practice**, v. 1, n. 4, p. 699 – 714, 1993.
- ÅSTRÖM, K.; WITTENMARK, B. On self-tuning regulators. **Automatica**, v. 9, n. 2, p. 185–199, 1973.
- BALBINOT, A.; BRUSAMARELLO, V. J. **Instrumentação e fundamentos de medidas**. 2. ed. Rio de Janeiro, RJ: LTC, 2011.
- BLUM, C. Ant colony optimization: Introduction and recent trends. **Physics of Life Reviews**, v. 2, n. 4, p. 353 – 373, 2005.
- CARMO, M. J. **Ambiente educacional multifuncional integrado para sintonia e avaliação do desempenho de malhas industriais de controle**. 127 p. Dissertação (Mestrado) — Centro Federal de Educação Tecnológica de Minas Gerais - CEFET-MG, Juiz de Fora, MG, Agosto 2006.
- CASTOLDI, M. F. **Algoritmo híbrido para projeto de controladores de amortecimento de sistemas elétricos de potência utilizando algoritmos genéticos e gradiente descendente**. 172 p. Tese (Doutorado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2011.
- CLARKE, D.; GAWTHROP, P. Self-tuning controller. **Proceedings of the Institution of Electrical Engineers**, v. 122, n. 9, p. 929–934, 1975.
- COELHO, A. A. R.; COELHO, L. S. **Identificação de sistemas dinâmicos lineares**. Florianópolis, SC: Ed. da UFSC, 2004.

COHEN, G. H.; COON, G. A. Theoretical considerations of retarded control. **ASME Transactions**, v. 75, p. 827–834, 1953.

CORRADINI, M.; ORLANDO, G. A discrete adaptive variable-structure controller for MIMO systems, and its application to an underwater ROV. **IEEE Transactions on Control Systems Technology**, v. 5, n. 3, p. 349–359, 1997.

CORRADINI, M. L.; ORLANDO, G. A MIMO VSS-type self-tuning control for a remotely operated vehicle. **1st IFAC Workshop on New Trends in Design of Control Systems**, p. 19–24, 1994.

CORRADINI, M. L.; ORLANDO, G. Discrete variable structure control for nonlinear systems. **European Control Conference**, v. 2, p. 1465–1470, 1995.

COSTA, B. L. G.; ALMEIDA, J. P. L. S.; ANGÉLICO, B. A. Application of optimization heuristics in tuning decentralized PID controllers. **INDUSCON 2012**, 2012.

DESBOROUGH, L.; MILLER, R. Increasing customer value of industrial control performance monitoring - Honeywell's experience. Thousand Oaks, CA, 2000.

DORIGO, M. **Optimization, learning and natural algorithms**. Tese (Doutorado) — Instituto Politécnico de Milão, Milão, Itália, 1992.

DORIGO, M.; STÜTZLE, T. **Ant Colony Optimization**. Cambridge, MA: MIT Press, 2004.

EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. In: **Sixth International Symposium on Micro Machine and Human Science (MHS)**. Nagoya, Japan: [s.n.], 1995. p. 39–43.

EPE. **Anuário estatístico de energia elétrica 2012**. 2012.

FERNANDES, R. A. S. **Localização e identificação de consumidores com alta contribuição para distorção harmônica de tensão em sistemas de distribuição**. 170 p. Tese (Doutorado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2011.

FERREIRA JR., P. A. **Automação e controle digital assistido por computador de uma planta didática industrial**. Trabalho de Conclusão de Curso (Graduação) — Curso de Engenharia Industrial Elétrica. Universidade Tecnológica Federal do Paraná: Cornélio Procopio, 2013.

FERREIRA JR., P. A.; FREIRE, V. J.; ANGÉLICO, B. A. Controle digital de malha de nível de uma planta didática industrial. In: **Anais do XLI Congresso Brasileiro de Educação em Engenharia - COBENGE**. Gramado, RS: [s.n.], 2013.

GUO, J.; ZHANG, X. Advance in discrete-time sliding mode variable structure control theory. In: **4th World Congress on Intelligent Control and Automation**. [S.l.: s.n.], 2002. v. 2, p. 878–882.

HAUGEN, F. Comparing PI tuning methods in a real benchmark temperature control system. **Modeling Identification and control**, v. 31, n. 3, p. 79–91, 2010.

HAUPT, R.; HAUPT, S. **Practical Genetic Algorithms**. New Jersey: Wiley, 2004.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2. ed. [S.l.]: Prentice Hall, 1999.

HUNG, J. Y.; GAO, W.; JUNG, J. C. Variable structure control: A survey. **IEEE Transactions on Industrial Electronics**, v. 40, p. 2–22, 1993.

KNIHS, V.; FRANCA, A.; SILVEIRA, A.; GOMES, F.; COELHO, A. A. R. Avaliação e projeto de um controlador *self-tuning* na estabilização de sistemas oscilatórios. In: **IEEE/IAS International Conference on Industry Applications (INDUSCON)**. São Paulo, SP: [s.n.], 2010.

KNIHS, V. L. **Projetos de controlador GMV em malhas de controle na indústria**. 166 p. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2011.

KNOSPE, C. PID control. **IEEE Control Systems**, v. 26, n. 1, p. 30–31, 2006.

KPONYO, J.; KUANG, Y.; LI, Z. Real time status collection and dynamic vehicular traffic control using ant colony optimization. In: **International Conference on Computational Problem-Solving (ICCP)**. Leshan, China: [s.n.], 2012. p. 69–72.

LANDAU, I. The R-S-T digital controller design and applications. **Control Engineering Practice**, v. 6, n. 2, p. 155 – 165, 1998.

LEE, K. Tutorial on intelligent optimization and control for power systems: an introduction. In: **International Conference on Intelligent Systems Application to Power Systems**. Arlington, VA: [s.n.], 2005. p. 2–5.

LUZ, A. F. **Uma metodologia baseada no algoritmo de otimização por enxame de partículas para manutenção preventiva focada em confiabilidade e custo**. 66 p. Dissertação (Mestrado) — Instituto de Engenharia Nuclear, Rio de Janeiro, RJ, 2009.

MAZUCATO JR., S. C.; COSTA, B. L. G.; CASTOLDI, M. F.; A. ANGÉLICO, B.; SANCHES, D. S.; RAMOS, R. A. Sintonia simultânea, paralela e coordenada de PSSs utilizando otimização por colônia de formigas. In: **Anais do XI Simpósio Brasileiro de Automação Inteligente (SBAI 2013)**. Fortaleza, CE: [s.n.], 2013.

MEJÍA, R. I. G. **Métodos para a análise do desempenho e da robustez de processos industriais orientados a dados: abordagem determinística e estocástica**. 320 p. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2008.

MOHAMED, K.; RAO, K. S. R.; HASAN, K. Application of particle swarm optimization and its variants to interline power flow controllers and optimal power flow. In: **International Conference on Intelligent and Advanced Systems (ICIAS)**. Petronas, Malaysia: [s.n.], 2010.

OGATA, K. **Engenharia de controle moderno**. 5. ed. São Paulo, SP: Pearson Prentice Hall, 2010. 809 p.

PEREZ, R.; BEHDINAN, K. Particle swarm approach for structural design optimization. **Computers & Structures**, v. 85, n. 19, p. 1579 – 1588, 2007.

RAHIMIAN, M.; RAAHEMIFAR, K. Optimal PID controller design for AVR system using particle swarm optimization algorithm. In: **Canadian Conference on Electrical and Computer Engineering (CCECE)**. Calgary, Canada: [s.n.], 2011. p. 337–340.

RAO, S. S. **Engineering optimization: theory and practice**. 4. ed. New Jersey: John Wiley & Sons, Inc, 2009.

RENDERS, J.; NORDVIK, J.; BERSINI, H. Genetic algorithms for process control: A survey. **Annual Review in Automatic Programming**, v. 17, n. 0, p. 323 – 328, 1992.

ROCHA, R. R.; LOPES, L. C. O.; MURATA, V. V. Implementação e avaliação de técnicas de identificação de sistemas lineares usando software livre. **4a. semana do servidor e 5a. semana acadêmica**, Uberlândia - MG, 2008.

RUDERMAN, M.; KRETTEK, J.; HOFFMANN, F.; BERTRAM, T. Optimal state space control of DC motor. **17th IFAC World Congress**, Seoul, Korea, p. 5798 – 5801, 2008.

SALAMANCA, H. L. L. **Análise, sintonia e experimentação de controladores PID via projetos GMV e GPC**. 143 p. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2007.

SANTOS, J. E. **Controle Preditivo Não Linear para sistemas de Hammerstein**. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2007.

SARPTURK, S.; ISTEFANOPULOS, Y.; KAYNAK, O. On the stability of discrete-time sliding mode control systems. **IEEE Transactions on Automatic Control**, v. 32, n. 10, 1987.

SEBORG, D.; MELLICHAMP, D.; EDGAR, T.; DOYLE, F. **Process dynamics and control**. [S.l.]: John Wiley & Sons, 2010.

SHI, Y.; EBERHART, R. A modified particle swarm optimizer. In: **IEEE International Conference on Evolutionary Computation Proceedings, IEEE World Congress on Computational Intelligence**. Anchorage, AK: [s.n.], 1998. p. 69–73.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo, SP: Artliber, 2010. 399 p.

SILVEIRA, A. S. **Contribuições ao controle de variância mínima generalizado: abordagem de projeto no espaço de estados**. 147 p. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2012.

SOCHA, K. **Ant colony optimization for continuous and mixed-variable domains**. 177 p. Tese (Doutorado) — Universidade Livre de Bruxelas, Bélgica, 2008.

SOCHA, K.; DORIGO, M. Ant colony optimization for continuous domains. **European Journal of Operational Research**, v. 185, n. 3, p. 1155 – 1173, 2008.

SUMAR, R. R. **Combinação da abordagem estrutura variável na síntese de algoritmos de controle preditivo e nebuloso**. 107 p. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2002.

TALBI, E.-G. **Metaheuristics - From Design to implementation**. Hoboken: John Wiley & Sons, Inc, 2009.



TENGLONG, K.; XIAOYING, Z.; JIAN, W.; YIHAN, D. A modified ACO algorithm for the optimization of antenna layout. In: **International Conference on Electrical and Control Engineering (ICECE)**. Yichang, China: [s.n.], 2011. p. 4269–4272.

TOKSARI, M. D. Ant colony optimization for finding the global minimum. **Applied Mathematics and Computation**, v. 176, n. 1, p. 308 – 316, 2006.

TVERSKY, A.; KAHNEMAN, D. Judgment under uncertainty: Heuristics and biases. **Science**, v. 185, p. 1124 – 1131, 1974.

UTKIN, V. I. Variable structure systems with sliding control. **IEEE Transactions on Automatic Control**, AC-22, p. 212–222, 1977.

VALERDI, R. Heuristics for systems engineering cost estimation. **IEEE Systems Journal**, v. 5, n. 1, p. 91–98, 2011.

VANDOREN, V. **Techniques for Adaptive Control**. Burlington, MA: Elsevier Science, 2003.

XIAO, L.; SU, H.; ZHANG, X.; CHU, J. Discrete variable structure control algorithm for nonlinear systems via sliding mode prediction. In: **American Control Conference**. Minneapolis, MN: [s.n.], 2006. p. 4712 – 4717.

YANG, X.-S. A new metaheuristic bat-inspired algorithm. **Studies in Computational Intelligence**, v. 284, p. 65–74, 2010.

YOUNG, K.; UTKIN, V.; OZGUNER, U. A control engineer's guide to sliding mode control. **IEEE Transactions on Control Systems Technology**, v. 7, n. 3, 1999.

YU, X.; XU, J.-X. **Variable structure systems: towards the 21st century**. [S.l.]: Springer, 2002.



## APÊNDICE A – PROJETO DOS CONTROLADORES PI

### A.1 CONSIDERAÇÕES DE PROJETO

Esta seção apresenta o projeto dos controladores PI/PID utilizados no Capítulo 5 deste trabalho. A estrutura do controlador PID considerada neste trabalho é o PID paralelo, representada pela Figura 71.

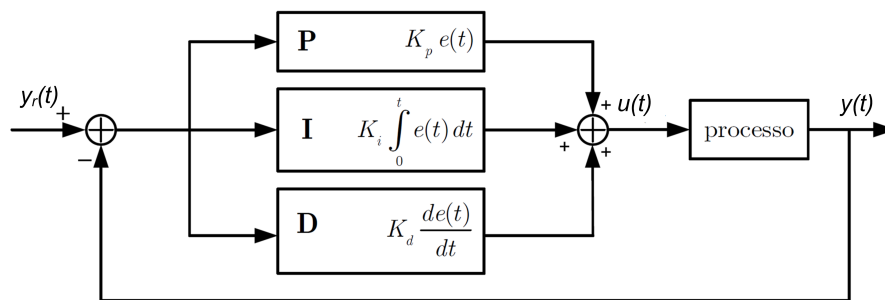


Figura 71 – Estrutura PID paralelo.

Fonte: Autoria própria.

Este tipo de controlador é composto por um termo proporcional ao erro, um termo integral do erro e um termo derivativo do erro. A ação de controle PID é dada pela Equação 54.

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

$$\Rightarrow \frac{U(s)}{E(s)} = K_p + \frac{K_i}{s} + K_d s = \frac{K_d s^2 + K_p s + K_i}{s} \quad (54)$$

onde  $K_p$  é o ganho proporcional,  $K_i$  é o ganho integral e  $K_d$  é o ganho derivativo.

Para se obter a versão discreta deste controlador foi utilizada a aproximação *backward* para o termo derivativo e a aproximação de *tustin* para termo integral. A Equação (55) apresenta a equação de diferenças que descreve a ação de controle calculada pelo controlador PID.

$$u(k) = u(k-1) + a(e(k) - e(k-1)) + \frac{b}{2}(e(k) + e(k-1)) + c(e(k) - 2e(k-1) + e(k-2)) \quad (55)$$

onde  $a = K_p$ ,  $b = K_i \cdot T_s$  e  $c = \frac{K_d}{T_s}$ .

A Tabela 34 apresenta o método de sintonia de Cohen-Coon para a obtenção dos ganhos do controlador PID (COHEN; COON, 1953; ÅSTRÖM; HÄGGLUND, 1995).

Tabela 34 – Sintonia dos ganhos do controlador PID pelo método de Cohen-Coon.

Controlador	$K_p$	$T_i$	$T_d$
P	$\frac{\tau}{K_e \theta} \left( 1 + \frac{0,35R}{1-R} \right)$		
PI	$\frac{0,9\tau}{K_e \theta} \left( 1 + \frac{0,92R}{1-R} \right)$	$\frac{3,3-3R}{1+1,2R}$	
PID	$\frac{1,35\tau}{K_e \theta} \left( 1 + \frac{0,18R}{1-R} \right)$	$\frac{2,5-2R}{1-0,39R} \theta$	$\frac{0,37-0,37R}{1-0,81R} \theta$

Fonte: Adaptado de Åström e Hägglund (1995).

onde  $R = \frac{\theta}{\theta + \tau}$ .

## A.2 KIT DATAPOOL - CONTROLE DE VELOCIDADE

Para se obter o modelo matemático contínuo do processo, representado pela Equação (1), foi aplicado um degrau de 0,5 V na entrada do processo. Foram utilizados os métodos de Smith e SK para encontrar os parâmetros  $K_e$ ,  $\tau$  e  $\theta$ . A Figura 72 apresenta a comparação entre estes dois métodos e a curva real do sistema.




Figura 72 – Comparação entre a resposta do sistema e as curvas estimadas pelos modelos de Smith e SK - Kit *Datapool*.

Fonte: Autoria própria.

Para encontrar qual dos modelos apresentou a maior precisão com os dados coletados foi utilizado o índice MSE. A Tabela 35 apresenta os resultados.

Portanto, o modelo matemático obtido através do método de Smith é mais próximo

Tabela 35 – Valores de MSE para os métodos de Smith e SK.

Método	MSE
Smith	0,0011
SK	0,0012

Fonte: Autoria própria.

do modelo real. A Equação (57) apresenta o modelo obtido. Foi considerado na saída do sistema o valor medido de velocidade e na entrada do sistema a tensão no motor.

$$G(s) = \frac{4,022}{0,23 \cdot s + 1} e^{-0,0471 \cdot s} \quad (57)$$

Utilizando-se do método de sintonia de Cohen-Coon, os parâmetros obtidos para o controlador do tipo PI são:  $K_p = 1,2986$  e  $K_i = 0,5604$ .

### A.3 PLANTA DIDÁTICA FESTO - CONTROLE DE NÍVEL

Para se obter o modelo matemático contínuo do processo foi aplicado um degrau de 6,5 V no *driver* que aciona a bomba centrífuga, responsável pela entrada de água no tanque. Portanto o valor real de tensão aplicado na bomba foi de 15,6 V. Foram utilizados os métodos de Smith e SK para encontrar os parâmetros  $K_e$ ,  $\tau$  e  $\theta$  que representa o sistema. A Figura 73 apresenta a comparação entre estes dois métodos e a curva real do sistema. Apresenta-se os valores de MSE para ambos os métodos na Tabela 36.

Tabela 36 – Valores de MSE para os métodos de Smith e SK - Planta Festo Nível.


Método	MSE
Smith	0,0027
SK	0,0017

Fonte: Autoria própria.

Portanto, o modelo matemático obtido através do método de Smith é mais próximo do modelo real. A Equação (59) apresenta o modelo obtido. Foi considerado na saída do sistema o valor de nível (em mm) medido pelo sensor de nível e na entrada do sistema a tensão aplicada na bomba centrífuga, fornecida pelo *driver* de acionamento.

$$G(s) = \frac{9,607}{68,06 \cdot s + 1} e^{-0,43 \cdot s} \quad (58)$$

Utilizando-se do método de sintonia de Cohen-Coon, os parâmetros obtidos para o controlador do tipo PI são:  $K_p = 15,07$  e  $K_i = 4,62$ .



**Figura 73 – Comparação entre a resposta do sistema e as curvas estimadas pelos modelos de Smith e SK - Planta Festo Nível.**

**Fonte: Autoria própria.**

#### A.4 PLANTA DIDÁTICA FESTO - CONTROLE DE VAZÃO

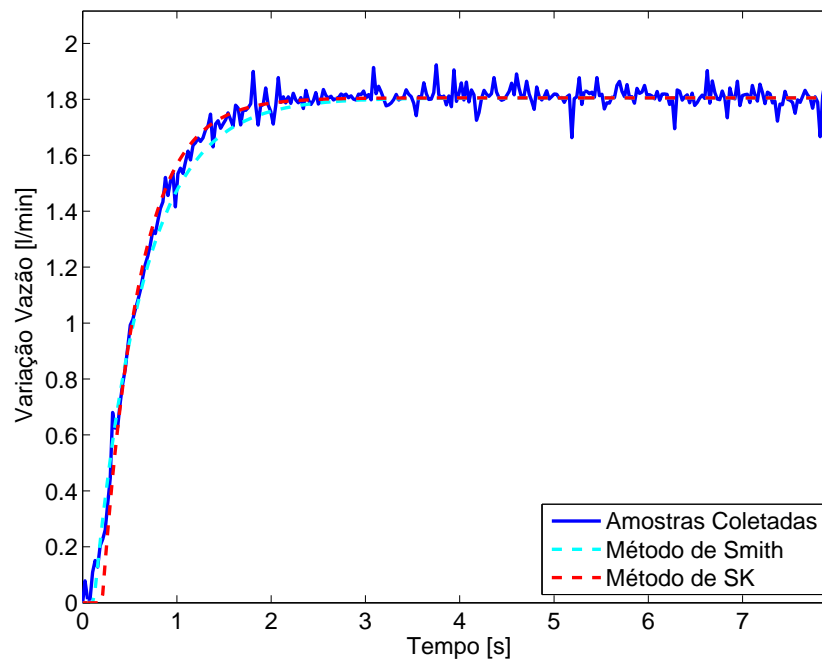
Para a obtenção do modelo matemático do sistema foi aplicada uma tensão de 10 V no *driver* que aciona a bomba centrífuga. Um degrau de 10 V de tensão foi aplicado na válvula proporcional, proporcionando a vazão máxima do sistema. Foram utilizados os métodos de Smith e SK para encontrar os parâmetros  $K_e$ ,  $\tau$  e  $\theta$  que representa o sistema. A Figura 74 apresenta a comparação entre estes dois métodos e a curva real do sistema. Os valores de MSE para cada métodos são apresentados na Tabela 37.

**Tabela 37 – Valores de MSE para os métodos de Smith e SK - Planta Festo Vazão.**

<b>Método</b>	<b>MSE</b>
Smith	0,0019
SK	0,0018

**Fonte: Autoria própria.**

Portanto, o modelo matemático obtido através do método de SK é mais próximo do modelo real. A Equação (59) apresenta o modelo obtido. Foi considerado na saída do sistema o valor de tensão fornecido pelo sensor de vazão e na entrada do sistema a tensão



**Figura 74 – Comparação entre a resposta do sistema e as curvas estimadas pelos métodos de Smith e SK - Planta Festo Vazão.**

**Fonte: Autoria própria.**

aplicada na válvula proporcional.

$$G(s) = \frac{0,1805}{0,3922 \cdot s + 1} e^{-0,206 \cdot s} \quad (59)$$

Utilizando-se do método de sintonia de Cohen-Coon, os parâmetros obtidos para o controlador do tipo PI são:  $K_p = 14,08$  e  $K_i = 8,77$ .





## APÊNDICE B – ALGORITMOS VSC/GMV

```

%% ALGORITMO DE CONTROLE
%Informações do ensaio
tf = 8;
ts = 0.05;
t=0:ts:tf;
step1=round(num_am/2);
step2=round(2*num_am/2);
r(1:step1)=8;
r(step1+1:step2+5)=16;
% Dados da planta
A=[1 -1.3 0.42];
B=[1 -0.8];
d=1;
%Polos de MF
zW = [0.8 0.1 0.1];
%Calculo dos polinomios P T S R
[P,T,S,R] = para_vsc_v2(A,B,zW,d);
eps=30;
sigma=0.4;
% Ajustes de inicialização
tam_A = length(A)-1;
for(i=1:6)
    y(i)=0;
    e(i)=0;
    varul(i)=0;
    s(i)=0;
    v(i)=0;
    varunl(i)=0;
    ut(i)=0;
    varu(i)=0;
end
%Controle
for k=tam_A+1:length(t)
    if k==tam_A+1
        y(k)=-A(2)*y(k-1)-A(3)*ym2+B(2)*ut(k-1);
    else
        y(k)=-A(2)*y(k-1)-A(3)*y(k-2)+B(1)*ut(k-1)+B(2)*ut(k-2);
    end
end

```

```

end
e(k)=y(k)-r(k);
if k==tam_A
    varul(k)=(1/R(1))*(T(1)*r(k+1)+T(2)*r(k)+T(3)*r(k-1)...
    -S(1)*y(k)-S(2)*y(k-1)-S(3)*ym2-R(2)*varul(k-1));
else
    varul(k)=(1/R(1))*(T(1)*r(k+1)+T(2)*r(k)+T(3)*r(k-1)...
    -S(1)*y(k)-S(2)*y(k-1)-S(3)*y(k-2)-R(2)*varul(k-1));
end
if k==tam_A
    s(k)=T(1)*e(k)+T(2)*e(k-1)+T(3)*em2+P*varu(k-1);
else
    s(k)=T(1)*e(k)+T(2)*e(k-1)+T(3)*e(k-2)+P*varu(k-1);
end
if abs(s(k)) >= sqrt(eps)
    v(k)=-2*sigma*eps/s(k);
else
    v(k)=-2*sigma*s(k);
end
varunl(k)=(1/R(1))*(s(k)+v(k)-R(2)*varunl(k-1));
varu(k)=varul(k)+varunl(k);
ut(k)=ut(k-1)+varu(k);
end

```

```

% function para_vsc_v2
function [P,T,S,R] = para_vsc_v2(A,B,zw,d)
gr_A = length(A)-1;
tam_A = length(A);
gr_B = length(B)-1;
tam_B = length(B);
gr_W = length(zw);
W = poly(zw);
tam_W = length(W);
delt_A = conv(A,[1 -1]);
for(i=1:length(delt_A))
    xa(i) = delt_A(i);
end

aux = [xa(1) B(1) 0 0;
xa(2) B(2) B(1) 0;
xa(3) 0 B(2) B(1);
xa(4) 0 0 B(2)];

```

```
w = [W(1); W(2); W(3); W(4)];  
Para = inv(aux)*w;  
P = Para(1);  
T = [Para(2) Para(3) Para(4)];  
E = T(1);  
S=[T 0]-conv(E,delt_A);  
S=S(2:4); %Para retirar o atraso de z^-1;  
R=conv(E,B)+[P 0];
```