

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO DE ELETRÔNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM ENGENHARIA ELÉTRICA**

ERICKSON DIOGO PEREIRA PUCHTA

**CONTROLE PID GAUSSIANO COM OTIMIZAÇÃO DOS PARÂMETROS DAS
FUNÇÕES GAUSSIANAS USANDO ALGORITMO GENÉTICO E PSO**

DISSERTAÇÃO

**PONTA GROSSA
2016**

ERICKSON DIOGO PEREIRA PUCHTA

**CONTROLE PID GAUSSIANO COM OTIMIZAÇÃO DOS PARÂMETROS DAS
FUNÇÕES GAUSSIANAS USANDO ALGORITMO GENÉTICO E PSO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Eletrônica do Câmpus Ponta Grossa da UTFPR como requisito parcial para a obtenção do título de mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Mauricio S. Kaster

Coorientador: Prof. Dr. Hugo Valadares Siqueira

**PONTA GROSSA
2016**

Ficha catalográfica elaborada pelo Departamento de Biblioteca
da Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa
n.07/17

P977 Puchta, Erickson Diogo Pereira

Controle PID gaussiano com otimização dos parâmetros das funções gaussianas usando algoritmo genético e PSO / Erickson Diogo Pereira Puchta. -- 2017.
75 f. : il. ; 30 cm.

Orientador: Prof. Dr. Maurício dos Santos Kaster

Coorientador: Prof. Dr. Hugo Valadares Siqueira

Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2017.

1. Sistemas de controle ajustável. 2. Controladores PID. 3. Algoritmos genéticos. I. Kaster, Maurício dos Santos. II. Siqueira, Hugo Valadares. III. Universidade Tecnológica Federal do Paraná. IV. Título.

CDD 621.3



Universidade Tecnológica Federal do Paraná
Câmpus Ponta Grossa
Diretoria de Pesquisa e Pós-Graduação
PROGRAMA DE PÓS GRADUAÇÃO EM
ENGENHARIA ELÉTRICA

FOLHA DE APROVAÇÃO

Título da Dissertação Nº 20/2016

CONTROLE PID GAUSSIANO COM OTIMIZAÇÃO DOS PARÂMETROS DAS
FUNÇÕES GAUSSIANAS USANDO ALGORITMO GENÉTICO E PSO

por

Erickson Diogo Pereira Puchta

Esta dissertação foi apresentada às 14 horas do dia 9 de dezembro de 2016 como requisito parcial para a obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA, com área de concentração em Controle e Processamento de Energia, Programa de Pós-Graduação em Engenharia Elétrica. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof^ª. Dr^ª. Grace Silva Deaecto (UNICAMP)

Prof. Dr. Heitor Silvério Lopes (UTFPR
Curitiba)

Prof. Dr. Angelo Marcelo Tusset (UTFPR)

Prof. Dr. Mauricio dos Santos Kaster
(UTFPR)
Orientador

Prof. Dr. Hugo Valadares Siqueira (UTFPR)
Co-orientador

Visto do Coordenador:

Prof. Dr. Claudinor Bitencourt Nascimento (UTFPR)
Coordenador do PPGEE

AGRADECIMENTOS

Agradeço especialmente à minha esposa e minhas filhas pelo apoio e compreensão pelas muitas renúncias no decorrer do trabalho.

Agradeço ao meu orientador Prof. Dr. Maurício dos Santos Kaster pela dedicação, atenção, sabedoria e principalmente pela oportunidade de desenvolvimento deste trabalho.

Agradeço ao meu co-orientador Prof. Dr. Hugo Valadares Siqueira, pela colaboração e contribuição para o desenvolvimento deste trabalho.

Agradeço também aos colegas de mestrado e aos demais professores da instituição que sempre estiveram dispostos a tentar contribuir de alguma forma para este trabalho.

Também agradeço à Universidade Tecnológica Federal do Paraná, pela disponibilização dos seus laboratórios e ambientes de ensino.

Enfim, a todos os que por algum motivo contribuíram para a realização desta pesquisa.

RESUMO

PUCHTA, ERICKSON. **Controle PID Gaussiano com Otimização dos Parâmetros das Funções Gaussianas Usando Algoritmo Genético e PSO**. 2016. 75 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2016.

Este trabalho propõe a utilização de uma técnica de controle PID adaptativo gaussiano (GAPID) com o objetivo de aumentar o desempenho do controle PID tradicional aplicado a um conversor Buck. A função gaussiana utilizada para definir os ganhos adaptativos tem características como: é uma função suave e com derivadas suaves, possui limites inferior e superior bem definidos e possui concavidade ajustável. Pelo fato de ser uma função suave, ajuda a evitar problemas relacionados às transições abruptas dos ganhos, comumente encontradas em outros métodos adaptativos. Entretanto, não há uma metodologia algébrica para obter os ganhos adaptativos, visto que originalmente o conjunto de parâmetros do GAPID é composto por oito elementos. Para tanto, utilizaram-se técnicas como otimização através de metaheurísticas bio-inspiradas, métricas avaliativas de desempenho, alteração no método de obtenção do tempo de acomodação, com o objetivo de aumentar o desempenho deste controlador (GAPID) e obter os ganhos adaptativos. O uso do conjunto de oito elementos na otimização gerou soluções ótimas, porém, muito especializadas, levando o controlador a não se comportar bem quando as condições de operação mudam. Desta forma, é proposto um vínculo entre os parâmetros não lineares das curvas gaussianas com os parâmetros lineares do controlador PID, que demonstrou gerar soluções quase tão boas quanto com parâmetros livres e menos especializadas, com comportamento mais homogêneo face a mudanças no ponto de operação do controlador e trazendo como principal vantagem a utilização dos mesmos requisitos de projeto do PID tradicional, o que facilitaria a migração do controlador PID para o GAPID dentro da maioria das indústrias. Os resultados obtidos, tanto na simulação quanto no protótipo foram semelhantes. Isso se deve ao cuidado com a modelagem e o rigor nos procedimentos de projeto, implementados da mesma forma no modelo e no protótipo.

Palavras-chave: Controle Adaptativo. Controle PID não linear. GAPID. Metaheurísticas Bio-inspiradas.

ABSTRACT

PUCHTA, ERICKSON. **Gaussian PID Control with Gaussian Function Parameters Optimization Using Genetic Algorithm and PSO**. 2016. 75 s. Masters Thesis – Post-Graduation Program in Electrical Engineering, Federal University of Technology, Paraná. Ponta Grossa, 2016.

This work proposes the use of a Gaussian adaptive PID control technique (GAPID) in order to increase the performance of the traditional PID control applied to a Buck converter. The Gaussian function used to define adaptive gains has characteristics such as; it is a smooth function with smooth derivatives, it has well defined lower and upper bounded and it has the adjustable concavity. Because it is a smooth function, it helps avoid problems related to abrupt gains transition, commonly found in other adaptive methods. However, there is no algebraic methodology to obtain the adaptive gains, since originally the GAPID parameter set consists of eight elements. Therefore, was used techniques such as optimization through bio-inspired metaheuristics, performance evaluation metrics, and change in the method to obtaining the settling-time, in order to increase the performance of this controller (GAPID) and obtain the adaptive gains. The use of the eight elements in the optimization generated optimized but very specialized solutions, causing the controller not to behave well when the operating conditions change. In this way, a link between the nonlinear parameters of the gaussian curves and the linear parameters of the PID controller was proposed, which demonstrated to generate solutions almost as good as with free and less specialized parameters, with a more homogeneous behavior in relation to changes in the operating point of the controller and bringing as a main advantage the use of the same traditional PID design requirements, which would facilitate the migration of PID controller to GAPID within most industries. The results obtained in both the simulation and the prototype were similar. This is due to careful modeling and rigor in design procedures, implemented in the same way in the model and the prototype..

Keywords: Adaptive Control. Nonlinear PID control. Bio-inspired Metaheuristics.

LISTA DE FIGURAS

Figura 1 – Conversor Buck.....	23
Figura 2 – Estado de corte do Mosfet Q	24
Figura 3 – Estado de condução do Mosfet Q	24
Figura 4 – Modelo Simulink® utilizado para validação.	27
Figura 5 – Resposta do sistema para validação do modelo	27
Figura 6 – Função Gaussiana: (a) função do ganho proporcional (b) função do ganho integral	29
Figura 7 – Descontinuidade do tempo de acomodação para 5% e 2%	32
Figura 8 – Envelopamento do transitório	33
Figura 9 – Tempo de acomodação obtido via envelopamento do transitório para 5% e 2%	34
Figura 10 – Comparativo entre as técnicas de análise de desempenho	35
Figura 11 – (a) crossover 1 ponto, (b) crossover 2 pontos, (c) crossover uniforme.....	39
Figura 12 – Mutação Uniforme	40
Figura 13 – Seleção por Roleta	41
Figura 14 – Seleção por Torneio.....	41
Figura 15 – Evolução temporal do <i>fitness</i>	43
Figura 16 – Fluxograma básico do algorithmo PSO	45
Figura 17 – Conversor Buck.....	47
Figura 18 – Modelo do Buck no Simulink®	48
Figura 19 – Esquemático do conversor e sistema de controle.	48
Figura 20 – Organização do enxame de partículas.....	50
Figura 21 – Evolução do <i>fitness</i> no estudo paramétrico (PSO)	51
Figura 22 – Transitório de resposta após a otimização (PSO)	52
Figura 23 – Evolução temporal do <i>fitness</i> (PSO)	54
Figura 24 – Comparativo entre as respostas do sistema para diferentes técnicas de <i>fitness</i>	54
Figura 25 – Evolução dos parâmetros otimizados do PSO.	56
Figura 26 – Resposta ao transitório para o PID linear e o GAPID (PSO)	57
Figura 27 – Variação dos ganhos adaptativos $k_p(\delta)$, $k_i(\delta)$ e $k_d(\delta)$ e o resultado do sinal de controle durante o transitório de partida (PSO)	58
Figura 28 – Resposta do transitório de partida para PID e GAPID no protótipo (PSO)(Ch.1: 500mA/div; Ch.2: 3V/div, Time: 500 μ s/div).....	59
Figura 29 – Estrutura dos genes para AG	59
Figura 30 – Evolução temporal do <i>fitness</i> (AG): média (em vermelho), o melhor resultado (em azul).	60
Figura 31 – Resposta do transitório para o PID linear(linha pontilhada cor preto) e GAPID (linha sólida cor azul) (AG).....	60
Figura 32 – Variação dos ganhos adaptativos $k_p(\delta)$, $k_i(\delta)$ e $k_d(\delta)$ e o resultado do sinal de controle durante o transitório de partida (AG).	61
Figura 33 – Comparação entre PID e GAPID quando ocorre uma variação de carga (Ch.1: 500 mA/div; Ch.2: 3 V/div, Time: 500 μ s/div).....	62
Figura 34 – Resposta do transitório de partida para PID e GAPID no protótipo (AG) (Ch.1: 500 mA/div; Ch.2: 3 V/div, Time: 500 μ s/div).....	63
Figura 35 – Comparativo entre PSO e AG utilizando ITSE	63
Figura 36 – Varredura de carga utilizando PSO com <i>fitness</i> IAE para parâmetros vinculados ...	64
Figura 37 – Resposta do sistema para variação de carga com parâmetros vinculados	65
Figura 38 – Varredura de carga utilizando PSO com <i>fitness</i> IAE para parâmetros livres	65
Figura 39 – Resposta do sistema para variação de carga com parâmetros livres	66

LISTA DE QUADROS

Quadro 1 – Parâmetros usados no Buck para estudos preliminares.....	26
Quadro 2 – Relação da terminologia do AG com a Biologia.....	38
Quadro 3 – Parâmetros usados no projeto do conversor Buck	49
Quadro 4 – Parâmetros do PSO.....	52
Quadro 5 – Parâmetros de controle otimizados (PSO)	55
Quadro 6 – Parâmetros AG	56
Quadro 7 – Parâmetros de controle otimizados (AG).	57

LISTA DE TABELAS

Tabela 1	– Resultados obtidos do estudo paramétrico utilizando PSO	51
Tabela 2	– Comparativo entre técnicas de <i>fitness</i> (PSO)	53
Tabela 3	– Comparativo de performance do GAPID otimizado com PSO	55
Tabela 4	– Comparativo de performance do GAPID otimizado com AG.	58
Tabela 5	– Comparativo entre PSO e AG utilizando ITSE	64

LISTA DE SIGLAS

ACO	<i>Ant Colony Optimization</i>
AG	Algoritmo genético
ANLPID-GGF	Adaptive Non- Linear PID – Gaussian Gain Functions
CC	Corrente Contínua
COP	Coeficiente de performance
CS	<i>Cuckoo Search</i>
DAELE	Departamento de Eletrônica
DSP	<i>Digital signal processing</i>
ESO	<i>Elector Survey Optimization</i>
FPGA	<i>Field Programmable Gate Array</i>
GAPID	<i>Gaussian Adaptive PID</i>
HCPLD	<i>High Capacity Programable Logic Device</i>
IAE	<i>Integral absolute error</i>
ISE	<i>Integral square error</i>
ITAE	<i>Integral time absolute error</i>
ITSE	<i>Integral time square error</i>
LQR	<i>Linear Quadratic Regulator</i>
PID	Proporcional-Integral-Derivativo
PLC	<i>Programmable Logic Controller</i>
PLL	<i>Phase-locked loop</i>
PPGEE	Programa de Pós-Graduação em Engenharia Elétrica
PSO	<i>Particle swarm optimization</i>
PWM	<i>Pulse With Modulation</i>
SDRE	<i>State Dependent Riccati Equation</i>
THD	<i>Total Harmonic Distortion</i>
UTFPR	Universidade Tecnológica Federal do Paraná

LISTA DE SÍMBOLOS

C	Capacitância
R_c	Resistência do capacitor
f	Frequência de comutação
L	Indutor do conversor Buck
R_L	Resistência do indutor
V_i	Tensão de entrada do conversor Buck
V_o	Tensão de saída do conversor Buck
T_{on}	Período que a chave Q está ligada (1)
Q	Transistor do conversor Buck
V_D	Tensão sobre o diodo do conversor Buck
u_t	Lei de Controle
δ	Sinal de entrada do controlador (erro)
T_{off}	Período que a chave Q está desligada (0)
T	Período de um ciclo de chaveamento (Q)
i_L	Corrente sobre o indutor do conversor Buck
i_R	Corrente sobre a carga do conversor Buck
λ	Varição percentual da faixa entre K_{x0} e K_{x1} , usada para definir o parâmetro p_x da curva Gaussiana (x pode ser p , i ou d)
$st_{2\%}$	Tempo de acomodação considerando margem de 2%
$st_{5\%}$	Tempo de acomodação considerando margem de 5%
w_n	Frequência de oscilação natural
ζ	Coefficiente de Amortecimento
M_p	Máximo sobressinal admissível (Overshooting)
T_s	Tempo de acomodação (Settling Time)
$M_{\%}$	Porcentagem admissível para o máximo sobressinal
fit	Função avaliadora de desempenho (<i>fitness</i>)
$cost$	Função custo
$p(t)$	População
$p1$	Indivíduo 1 selecionado da população para realizar o processo de recombinação no AG
$p2$	Indivíduo 2 selecionado da população para realizar o processo de recombinação no AG
$f1$	Filho 1 gerado após processo de recombinação no AG
$f2$	Filho 2 gerado após processo de recombinação no AG
J_{fit}	Função custo para aumentar o grau de adaptação do indivíduo
N_{pop}	Número de indivíduos que irão compor a população
x_p	Posição atual de uma partícula

$c1$	Coeficiente cognitivo
$c2$	Coeficiente social
w	Momento de inércia
K_p	Ganho Proporcional do PID convencional
K_i	Ganho Integral do PID convencional
K_d	Ganho Derivativo do PID convencional
K_{x0}	Valor do ganho adaptativo gaussiano quando $ \delta = 0$ (x pode ser p, i ou d)
K_{x1}	Valor do ganho adaptativo gaussiano quando $ \delta = 0$ (x pode ser p, i ou d)
p_n	Partícula hexadimensional
δ_x	Erro de referência, usado para determinação do parâmetro p_x (x pode ser p, i ou d)
p_x	Variável que regula a concavidade da curva gaussiana (x pode ser p, i ou d)
T_r	Tempo de subida
w_{in}	Coeficiente de inércia inicial
w_{fim}	Coeficiente de inércia final
$c1_{in}$	Coeficiente de cognitivo inicial
$c1_{fim}$	Coeficiente de cognitivo final
$c2_{in}$	Coeficiente de social inicial
$c2_{fim}$	Coeficiente de social final
v_p	Velocidade atual de uma partícula
it	Iteração atual
$pbest$	Melhor posição que a partícula p já obteve durante a busca
$gbest$	Melhor posição encontrada na vizinhança da partícula p

SUMÁRIO

1	INTRODUÇÃO	15
1.1	JUSTIFICATIVA	19
1.2	OBJETIVOS	20
1.2.1	Objetivo Geral	20
1.2.2	Objetivos Específicos	20
1.3	METODOLOGIA	21
1.4	ORGANIZAÇÃO DO TRABALHO	21
2	MODELAGEM DO CONVERSOR <i>BUCK</i>	22
2.1	INTRODUÇÃO	22
2.2	CONVERSOR <i>BUCK</i>	22
2.3	MODELAGEM	23
2.3.1	Análise de espaço de estados aplicado ao modelo	25
2.3.2	Modelo MATLAB/SIMULINK®	26
3	CONTROLE GAPID	28
3.1	INTRODUÇÃO	28
3.2	CONTROLADOR GAPID	28
4	MÉTRICAS AVALIADORAS DE DESEMPENHO	32
4.1	INTRODUÇÃO	32
4.2	ENVELOPAMENTO DO TRANSITÓRIO DE PARTIDA	32
4.3	AGENTES MÉTRICAS AVALIADORAS DE DESEMPENHO	33
5	FERRAMENTAS DE OTIMIZAÇÃO	37
5.1	INTRODUÇÃO	37
5.2	ALGORITMO GENÉTICO	37
5.2.1	População Inicial	38
5.2.2	<i>Crossover</i> (Recombinação)	39
5.2.3	Mutação	39
5.2.4	Seleção	40
5.2.5	Avaliação do Grau de Adaptação do Indivíduo	41
5.2.6	Busca Local e Elitismo	42
5.2.7	Etapas do Algoritmo Genético Clássico	42
5.2.8	Evolução Temporal do Fitness no AG	42
5.3	OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO)	43
6	RESULTADOS EXPERIMENTAIS	47
6.1	INTRODUÇÃO	47
6.2	PROTÓTIPO	47
6.3	ESTUDO PARAMÉTRICO PARA O PSO	49
6.4	OTIMIZAÇÃO UTILIZANDO PSO	53
6.5	OTIMIZAÇÃO UTILIZANDO ALGORITMO GENÉTICO	55
6.6	COMPARATIVO ENTRE PSO E AG	59
6.7	ESTUDO DE TENDÊNCIA	61
6.7.1	Varredura de Carga com Parâmetros Vinculados	61

6.7.2	Varredura de Carga com Parâmetros Livres.....	62
6.7.3	Análise Geral.....	63
6.8	CONCLUSÃO DO CAPÍTULO.....	64
7	CONCLUSÃO	67
	REFERÊNCIAS	70

1 INTRODUÇÃO

No decorrer da história, vários registros de métodos de controle foram introduzidos. Porém, nenhum deles teve maior destaque do que o tradicional PID (controlador Proporcional, Integral e Derivativo) linear, criado na década de 40 e acompanhado por uma forma simples de ajuste sugerido por Ziegler-Nichols (OGATA, 2009). Este controlador foi e é o mais utilizado nas indústrias modernas. Embora haja técnicas mais eficientes, o grau de complexidade na implantação e ajuste é muito mais elevado que o PID.

Outro controlador que vem se destacando na indústria é o baseado em lógica *fuzzy*, onde um conhecimento prévio do sistema que pode ser traduzido de forma linguística possibilitando a construção de várias regras que facilitam a modelagem dos problemas tornando-os, assim, menos complexos. Um exemplo disso é a empresa Coca-Cola Femsa® em Jundiaí - SP (Alisson, 2013), onde pequenas variações na pressão com a qual as garrafas são preenchidas com refrigerante podem afetar a velocidade de enchimento e provocar a perda da bebida por borbulhamento e variações de nível do líquido injetado. Para resolver esse problema, um sistema de controle baseado em lógica *fuzzy* foi implementado, o que possibilitou controlar simultaneamente as válvulas de pressão e de vazão da linha engarrafadora e gerar uma economia de 500 mil litros de Coca-Cola e de 100 mil garrafas PET por ano.

Outro indicador relevante são as empresas desenvolvedoras de produtos para automação industrial, como a Siemens® e Rockwell®, que desenvolveram um *toolbox* para desenvolvimento de projetos com controladores *fuzzy*. Desta forma, ambas disponibilizam para o usuário os controladores PID e *fuzzy* para serem utilizados nos controladores lógicos programáveis (PLC).

Atualmente com a evolução dos processos fabris e industriais, as plantas de controle passaram a possuir muitas entradas e saídas, tornando a sua síntese e análise cada vez mais complexas, uma vez que a modelagem requer um número elevado de equações para se chegar ao comportamento da planta.

CONTROLE NÃO LINEAR

Por vários anos muitos pesquisadores têm procurado aumentar o desempenho dos conversores de potência aumentando sua eficiência, reduzindo perdas e eliminando ruídos. Entretanto, frequentemente os métodos clássicos não alcançam os resultados esperados, forçando o projetista a procurar por novas metodologias ou efetuar melhorias em técnicas existentes. Neste sentido, técnicas não lineares podem melhorar o desempenho do controlador, como o método adaptativo ((XIAO et al., 2010), (KASTER et al., 2015)), modos deslizantes ((SARINANA; BACHA; BORNARD, 2000), (WEI et al., 2013), (SAHU; SHAW; MAITY, 2015)), controladores ótimos (LQR - *Linear-quadratic regulator* ((LEUNG; TAM; LI, 1993), (NALLUSAMY; VELAYUTHAM; GOVINDARAJAN, 2015), (MISTRY et al., 2016)) e SDRE - *State Dependent Riccati Equation* ((FUJIMOTO; TABUCHI; YOKOYAMA, 2010), (PEDROSO et al., 2013), (DO et al., 2014), (KHAMIS, 2015), (ÇIMEN, 2010))). Entretanto, a imple-

mentação de tais metodologias é mais complexa que o controlador tradicional e ainda pode apresentar efeitos indesejáveis, como o chaveamento em alta frequência (*chattering*) para controladores por modos deslizantes. Na indústria, onde a maioria dos controladores são baseados no PID linear, uma solução adaptativa coloca-se como uma boa opção, já que não apresenta grande impacto na transição do linear para o adaptativo, pois preserva a simplicidade da estrutura do PID linear e muitas vezes permite aproveitar os mesmos requisitos de projeto.

Dentro do universo dos controles adaptativos, a maioria dos autores propõem ganhos constantes por segmentos, ou seja, funcionam como se o controlador PID linear possuísse dois ou mais conjuntos de ganhos, um para cada faixa de operação. Porém, dentro de cada faixa o controlador opera da forma linear tradicional ((ALEXANDROV, 1999), (RAFAEL; SANTOS; PIRES, 2013), (NUCHKRUA; LEEPHAKPREEDA, 2013), (SINGH; KUMAR, 2015), (WANG; ZHANG, 2016)). O problema é que a transição dos ganhos acaba sendo abrupta (descontínua) podendo causar alguns efeitos secundários indesejados.

Uma parcela bem menor de autores propõe o uso de alguma função adaptativa contínua dos ganhos ((ISAYED M. B.; HAWWA, 2007), (XIAO et al., 2010), (KASTER et al., 2015), (JIMENEZ-URIBE et al., 2015),) e é neste grupo que se insere o trabalho aqui proposto.

Com o intuito de melhorar o desempenho do controlador PID tradicional, (KASTER et al., 2011) propôs o uso de um controlador PID adaptativo baseado em uma função Gaussiana. Neste caso, os ganhos do PID são adaptados de acordo com uma função Gaussiana do erro de entrada. Tal função é suave e com derivadas suaves o que propicia transições também suaves para os ganhos do controlador, evitando transições abruptas nos ganhos, característica de alguns tipos de controladores adaptativos. Em sistemas com ocorrência de erro em regime permanente existe a possibilidade de transição repetitiva dos ganhos caso o erro em regime permanente esteja na vizinhança do valor da transição dos ganhos. Esse problema não existe no caso de funções de adaptação suaves.

Em 2012, (SANTOS; KASTER; SILVA, 2012) realizou uma comparação entre um algoritmo de PLL (*Phase-locked loop*) monofásico (pPLL) controlado por um controlador PI convencional e um controlador PI não linear adaptativo (Proporcional, Integral) baseado em uma função Gaussiana, onde os parâmetros das funções Gaussianas foram obtidos através de uma varredura de cada ganho individualmente e avaliando os resultados. O gráfico do desempenho como função do parâmetro avaliado permitiu verificar a curva de tendência do desempenho dentro de uma faixa pré-estabelecida de ganhos e adotar então o melhor resultado. Embora esta não seja a metodologia de projeto mais adequada, por não avaliar o efeito do conjunto dos parâmetros, o controlador resultante teve um desempenho melhor quando comparado ao PI convencional.

(PEDROSO et al., 2013) realizou um estudo comparativo entre o controlador PID convencional, o controlador PID adaptativo com ganhos Gaussianos (chamado na época de ANLPID-GGF - *Adaptive Non-Linear PID – Gaussian Gain Functions*) e controladores ótimos (LQR e SDRE). Os tempos de resposta ao transitório de partida do ANLPID-GGF, LQR e SDRE foram menores que do PID convencional. Como o LQR e o SDRE não possuem ação de controle integral, eles obrigatoriamente exibem um erro em regime permanente que é tão menor quanto maior o ganho do controlador. Sabe-

se, entretanto, que a elevação do ganho também traz efeitos indesejáveis, como a amplificação do ruído de realimentação e, em alguns casos, a redução da margem de estabilidade. O SDRE, que de certa forma também pode ser considerado um controlador adaptativo, foi o que obteve os melhores resultados, mas também se mostrou muito sensível a ruídos.

(SANTOS; KASTER, 2015) propôs em seu trabalho um controlador adaptativo não linear baseado em uma função Gaussiana ao invés de um PI, para controlar um filtro ativo monofásico. Este foi projetado tendo como base os ganhos do controlador PID convencional, resultando em uma melhoria no controle de tensão quando comparado ao primeiro.

MÉTRICAS AVALIATIVAS DE DESEMPENHO

Um sistema de medição de desempenho é constituído por um conjunto de medidas utilizadas para quantificar a eficácia de um processo. As medidas de desempenho podem ser classificadas de diferentes maneiras: pelo tempo de acomodação (T_s), pelo nível de sobressinal ou pela integração dos erros. Os indicadores também podem ser estabelecidos para avaliar se o resultado foi alcançado e se o desempenho do processo é satisfatório. Os indicadores de resultados avaliam o atendimento aos objetivos definidos pelo projetista.

No trabalho proposto por (ANSARI; IBRAHEEM; KATIYAR, 2014) houve a necessidade de escolher uma função de avaliação (*fitness*) para um agente otimizador baseado no comportamento de uma colônia de formigas (ACO - *Ant Colony Optimization*). O ITAE (*Integral Time Absolute Error*) foi a melhor opção para avaliar o processo de otimização para se obter os ganhos de um controlador PID. Da mesma forma, em (KISHNANI; PAREEK; GUPTA, 2014) os autores concluíram que a utilização do ITAE (*Integral Time Absolute Error*) seria a melhor escolha para avaliar o processo de otimização baseado na postura de ovos do pássaro cuckoo (Cuckoo Search - CS) resultando na obtenção dos ganhos de um controlador PID. (WENGE et al., 2010) utilizou outra técnica de otimização baseada em um sistema eleitoral (Elector Survey Optimization - ESO), que simula a motivação dos candidatos às eleições para o maior apoio na campanha. Neste trabalho o ISE (*Integral Square Error*) obteve o melhor desempenho na obtenção dos ganhos de um controlador PID comparado com o método Ziegler-Nichols.

Embora a integração dos erros seja consolidada como agente avaliador de performance, em (KUMAR; NEMA; PADHY, 2014) os autores alteraram a forma original do ISE (*Integral Square Error*) inserindo dois termos que auxiliam na ponderação dos resultados obtidos pela integração quadrática dos erros com o máximo sobressinal (Mp) a cada transitório ($Cost_{Fn} = \alpha ISE + \beta Mp$). Desta forma, α e β agem como agentes limitadores da função. Assim, de posse de um agente avaliador aplicado ao algoritmo CS obteve-se os ganhos otimizados para um controlador PID convencional.

O estudo destas métricas, servirá como ferramenta avaliativa para as metaheurísticas bio-inspiradas que serão utilizadas neste trabalho.

METAHEURÍSTICAS BIO-INSPIRADAS

Com o desenvolvimento do cálculo integral e diferencial por Leibnitz e Newton no século XVIII, o problema de encontrar máximos e mínimos em funções tornou-se solúvel em um primeiro momento, uma forma analítica de encontrar os pontos de nulidade do gradiente de uma função. Com esta ferramenta em mãos foi possível encontrar as melhores soluções para um problema (otimização) que poderia também ser resolvido analiticamente se o problema tivesse uma estrutura simples (SOUZA, 2001). A falta de um método universal para a otimização de problemas mais complexos que ocorrem na realidade, conduziu-nos ao desenvolvimento de diferentes estratégias de otimização impulsionadas pela observação da natureza e pelo avanço da matemática e o aumento do poder de processamento dos computadores modernos. Estes algoritmos incluem os métodos determinísticos (LEE; LEE; LEE, 2009) e os heurísticos (PUSPITASARI; FATTA; WIBOWO, 2015) .

As técnicas baseadas em informação da derivada ou Hessiana da função custo são, ainda, as de maior utilização. Sua aplicação, como explicitado, é restrita à funções em que tais informações podem ser calculadas ou estimadas. Entretanto, o processo de diferenciação pode não ser simples ou mesmo possível de ser computado. Ainda, cada inicialização das técnicas clássicas consegue encontrar o ótimo da bacia de atração em que foi inicializado. Além disso, o passo do algoritmo torna-se essencial para a convergência do mesmo, pois um passo muito pequeno pode levar a uma elevada demora, enquanto um muito grande pode não estacionar em um ponto ótimo.

Neste sentido, metaheurísticas bio-inspiradas de otimização aparecem como candidatas viáveis para a solução de diversos problemas. Por serem técnicas populacionais, possuem intrinsecamente potencial de busca local e global. A maioria destas são inspiradas por sistemas naturais. É possível citar por exemplo: recozimento simulado ((PUSPITASARI; FATTA; WIBOWO, 2015), (KRIPKA; KRIPKA, 2013)), que é inspirado por um processo metalúrgico, algoritmos evolutivos e algoritmos genéticos ((RAMPAZZO; YAMAKAMI; FRANÇA, 2013), (SILVA et al., 2013), (ABENSUR, 2013)) que são inspirados por princípios da evolução Darwiniana e biológica, busca tabu ((ARMENTANO; BRANCHINI, 2013), (ARMENTANO et al., 2013)), inspirado pela memória de seres humanos, algoritmos baseados em inteligência de enxames como o algoritmo otimização de enxame de partículas (PSO - *Particle Swarm Optimization*) (NASCIMENTO et al., 2013), o algoritmo de colônia de formigas (NÉIA et al., 2013), o algoritmo colônias de abelhas (KRAUSE; CORDEIRO; LOPES, 2013), algoritmo do cuckoo (YANG; DEB, 2009) e pelos algoritmos de otimização inspirados pelo comportamento social de algumas espécies que evoluem em grupos. Como existe uma gama enorme de métodos otimizadores, escolher uma depende do objeto da investigação.

Em 2008, (KHEIRMAND et al., 2008) realizou um estudo para verificar o desempenho no processo de otimização entre duas técnicas bem conhecidas, o algoritmo genético (AG) e o PSO, para melhorar o desempenho de um conversor CC-CC, utilizando um controlador por alocação de polos. Neste caso, o PSO se destacou pela facilidade de implementação e a velocidade de convergência. (MOGHADAM; GHAREHPETIAN; ABYANEH, 2010) utilizou em sua pesquisa o AG para melhorar o desempenho de um controlador PI na regulação de um link de tensão CC (Corrente Contínua) para

inversores de potência.

Outro problema frequentemente discutido está relacionado à forma de onda gerada por inversores de potência. A distorção na saída afeta o tipo de filtro requerido e o valor dos componentes que deve ser selecionado para atender às restrições do THD (*Total Harmonic Distortion*) máximo permitidos pelos órgãos regulamentadores da rede elétrica. Sendo assim, (SARVI; SALIMIAN, 2010) utilizou o algoritmo genético e o PSO para aumentar o desempenho em inversores multiníveis, reduzindo harmônicos (THD). Neste trabalho o algoritmo genético se destacou por produzir resultados melhores.

De fato observa-se nos últimos anos um crescimento significativo de trabalhos utilizando métodos bio-inspirados de otimização. Esta tendência pode ser observada em todos os campos da ciência. (LEÓN-ALDACO; CALLEJA; ALQUICIRA, 2015) investigou a participação de metaheurísticas no melhoramento do desempenho em conversores de potência nas publicações dos anos anteriores a 2015. Aproximadamente 62% destas publicações utilizaram algoritmos evolucionários, sendo que 86% destes utilizaram o algoritmo genético. Cerca de 36% utilizaram inteligência de enxame, de forma que o PSO se destacou com uma participação de 88%, e somente 2% utilizaram redes neurais.

1.1 JUSTIFICATIVA

Dentro de uma indústria há vários processos com características altamente não lineares, de maneira que um controlador PID convencional não se coloca como alternativa mais adequada como elemento controlador. Entretanto, devido à popularidade deste, muitos fabricantes o fornecem como biblioteca dentro da ferramenta de desenvolvimento. É comum observar nos sistemas de controle industrial blocos de controle PID padrão, nas quais o programador seleciona e o insere em seu programa. A facilidade de parametrização destes blocos e o sistema “*auto-tunning*” faz com que o programador de fato não conheça a fundo o processo, induzindo-o a um erro pois normalmente o sistema de “*auto-tunning*” é acionado antes de iniciar a produção.

Quando o controle fica ineficiente devido a uma perturbação inserida ou uma instabilidade, um operador especialista é acionado para efetuar os ajustes necessários. Estes podem incluir uma nova definição de *setpoint* para a variável de processo, dos ganhos de controle, ou simplesmente alterar a calibração do elemento atuador.

O baixo desempenho deste controlador dentro da indústria já foi relatado por vários autores (ASTROM K. J.; HAGGLUND, 1995). Entretanto, o dinamismo do sistema corporativo dentro de uma indústria não propicia um estudo ou uma modelagem da planta para um correto projeto de controle, o que força o projetista a utilizar blocos prontos e de fácil parametrização.

Desta forma, o objeto de estudo deste trabalho visa propor um controle adaptativo que aproveite a estrutura do controlador PID, porém, melhorando o seu desempenho através do uso de funções adaptativas Gaussianas (GAPID - Gaussian Adaptive PID). O aproveitamento da estrutura visa facilitar sua inserção dentro dos processos industriais. A escolha por funções Gaussianas justifica-se por suas características consideradas desejáveis: transição suave entre dois patamares distintos de

ganhos com possibilidade de ajuste da concavidade da função.

Por não haver ainda metodologia de projeto algebrico, adota-se uma solução de otimização eficiente e de bastante aceitação através de meta-heurísticas bioinspiradas. No caso, a escolha recai em algoritmos genéticos (AG) e otimização por enxame de partículas (PSO), até mesmo para que se possa fazer uma comparação no desempenho de ambas.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

O objetivo principal desse trabalho é desenvolver uma metodologia para calcular os ganhos de um controlador PID não linear baseado em uma função Gaussiana, aplicado em um conversor CC-CC de topologia Buck. Observa-se que esta tarefa pode ser vista como um problema de otimização não-linear, de maneira que metaheurísticas bio-inspiradas colocam-se como candidatas a solução do problema. Estas serão aplicadas para encontrar uma solução para esse problema, e espera-se que na convergência haja uma melhora no desempenho do sistema. Assim, serão avaliados os desempenhos obtidos por meio dos algoritmos genéticos e otimização por enxame de partículas (PSO).

1.2.2 Objetivos Específicos

Os objetivos específicos deste estudo podem ser sumarizados abaixo:

- Obter o modelo matemático do conversor Buck;
- Realizar estudos para alterar a forma de obtenção do tempo de acomodação (*Settling Time*) para um transitório;
- Construir um modelo matemático do conversor utilizando-se o software Matlab/Simulink®;
- Realizar estudos para escolha de duas técnicas de otimização bio-inspiradas: algoritmo genético e otimização por enxame de partículas;
- Verificar e implementar técnicas de avaliação de desempenho para o processo de otimização, ou seja, definir a melhor função custo a ser otimizada;
- Desenvolver um programa de otimização paralelo para processamento em uma *cluster*, onde serão simulados e coletados os dados do modelo matemático do conversor (*software Matlab/Simulink®*);
- Validar o modelo matemático com o um protótipo desenvolvido em laboratório;
- Realizar estudos de variação paramétrica para obtenção de uma curva de tendência do comportamento do controlador GAPID;

- Propor uma metodologia algébrica para obtenção dos ganhos da função Gaussiana;
- Elaborar documentos e artigos científicos.

1.3 METODOLOGIA

Para atingir a metas propostas, será adotada a seguinte metodologia:

- Elaboração estrutural do objeto de pesquisa, o foco do trabalho e o impacto no mundo científico;
- Utilizar técnicas de gerenciamento de projeto, pautando cada atividade dentro de um cronograma exequível;
- Realização de pesquisa bibliográfica, buscando verificar os trabalhos mais recentes sobre o tema;
- Elaboração dos modelos matemáticos para simulação computacional do sistema proposto, automatizando o sistema de coleta de dados através de uma programação paralela;
- Documentação do desenvolvimento e dos resultados, visando perpetuação dos resultados por futuros pesquisadores.

1.4 ORGANIZAÇÃO DO TRABALHO

Este trabalho seguirá com a seguinte estrutura:

- No Capítulo 2 é apresentada a modelagem do sistema de aplicação utilizando um conversor CC-CC tipo Buck;
- No Capítulo 3 aborda-se de forma mais aprofundada a proposta do controle PID não linear adaptativo baseado em funções Gaussianas (GAPID);
- No Capítulo 4 são apresentadas as formas de se avaliar o desempenho, ou seja, a determinação da função custo a ser otimizada. Para tal, técnicas consolidadas no meio científico como, ITSE, ISE, IAE, serão testadas para verificação de qual delas se faz mais adequada;
- No Capítulo 5 são apresentadas duas técnicas bio-inspiradas para otimização do processo de obtenção dos ganhos do controlador GAPID, a saber o algoritmo genético e otimização por enxame de partícula;
- No Capítulo 6 são mostrados e discutidos os resultados experimentais obtidos;
- Por fim, no Capítulo 7 serão apresentadas as conclusões do trabalho e sugestões de continuidade da pesquisa.

2 MODELAGEM DO CONVERSOR *BUCK*

2.1 INTRODUÇÃO

Devido à sua simplicidade construtiva e seu desempenho em diversas aplicações, os conversores CC-CC *Buck* são amplamente utilizados em áreas que vão desde medicina até dispositivos eletrônicos portáteis. Com uma dinâmica bem conhecida e largamente explorada no meio acadêmico, esta topologia foi selecionada pois permite ao pesquisador focar na aplicação de controle, sem ter que despender grandes esforços no seu funcionamento. Esta foi uma das várias vantagens que nortearam a escolha desta topologia como planta para aplicar as técnicas de controle desta dissertação. Nos tópicos seguintes serão abordadas todas as características deste conversor, bem como sua modelagem.

2.2 CONVERSOR *BUCK*

O conversor *Buck* caracteriza-se por ser um conversor *step-down*, ou conversor abaixador (Figura 1). Os engenheiros projetistas de fontes fazem uso dessa topologia porque a tensão de saída é sempre menor que a tensão de entrada e possui a mesma polaridade. A corrente de entrada do *Buck* é descontínua ou pulsada devido à comutação da chave Q , que varia a corrente de zero até I a cada ciclo de chaveamento, produzindo um valor médio de tensão na saída inferior ao valor médio da tensão de entrada, enquanto a corrente média de saída é maior que a corrente média de entrada.

Na Figura 1 é apresentado o diagrama esquemático deste conversor.

Quando a chave Q é comutada, ela insere ou retira a fonte de tensão de entrada V_i do circuito. A combinação indutor (L) e capacitor (C) forma um filtro passa-baixas que transforma a tensão pulsada vinda da chave Q em tensão aproximadamente contínua sobre a carga (V_o). No período que a chave está conduzindo (T_{on} Figura 2) o diodo V_D está cortado, ocasionando a transferência de energia da fonte para o indutor L . Neste transitório, a corrente i_c é maior que a corrente i_R até alcançar o regime. Quando a chave passa para corte (T_{off}), o diodo conduz, mantendo a corrente na carga constante conforme ilustrado na Figura 2. A partir deste momento a energia armazenada no indutor é transferida para o capacitor e a carga até que o valor instantâneo da corrente que passa pelo indutor seja maior que a carga ($i_L > i_R$). Caso contrário ($i_L < i_R$), o capacitor descarrega mantendo constante a corrente na carga.

A variável de controle que atua sobre a chave é discreta, assumindo valores 0 (*false*) ou 1 (*true*) com duração variável no tempo. Sendo assim, o valor médio dessa variação está dentro de um período de comutação PWM (*Pulse Width Modulation*), que é definido como razão cíclica ($d(t) \cong q(t)$) que está representada na Equação 2.2:

$$T = T_{on} + T_{off} \quad (2.1)$$




Figura 1 – Conversor Buck

Fonte: Autoria própria.

$$d(t) \cong d(kT) = \frac{1}{T} \int_{kT}^{(k+1)T} q(t) dt = \frac{T_{on}}{T} \quad (2.2)$$

onde:

T período de um ciclo;

T_{on} período em que a chave Q está ligada;

T_{off} período em que a chave Q está desligada.

2.3 MODELAGEM

A modelagem de uma planta é a sintetização das características físicas de um sistema na forma de equações diferenciais, buscando a compreensão dos fenômenos que o cercam. Este modelo matemático será composto por parâmetros, que por sua vez estão intrínsecos ao sistema. Quando o modelo tenta retratar um fenômeno que consiste na interação entre duas características, pode-se adotar simplificações (até certo ponto). Entretanto a maioria dos sistemas físicos são inerentemente não-lineares forçando a simplificação por técnicas de linearização ((UDDIN; KRAUSE; MARTIN, 2016), (ABDULAZIZ et al., 2016)).

Para a realização dos cálculos a seguir considera-se os dois estados de funcionamento analisados anteriormente. Quando $q = 0$ a fonte V_i passa a não fazer parte do circuito (Figura 2). Aplicando-se técnicas de análise de malha obtemos as Equações 2.3 e 2.4:

$$V_D + V_L + r_L i_L + r_C i_C + V_C = 0 \quad (2.3)$$

$$i_L = i_C + i_R \quad (2.4)$$

onde:

V_D : tensão de junção do diodo;

V_L : tensão do indutor;

r_L : resistência intrínseca do indutor;




Figura 2 – Estado de corte do Mosfet Q

Fonte: Autoria própria.

i_L : corrente sobre o indutor do conversor Buck;

r_C : resistência intrínseca do capacitor;

i_C : corrente sobre o capacitor do conversor Buck;

V_C : tensão do capacitor;

i_R : corrente da carga.

Quando $q = 1$ a fonte V_i é inserida no circuito e começa a fornecer energia para os demais componentes (Figura 3). Realizando uma análise do circuito obtemos as expressões 2.5, 2.6 e 2.7:




Figura 3 – Estado de condução do Mosfet Q

Fonte: Autoria própria.

$$-V_i + r_s i_L + V_L + r_L i_L + V_C + r_C i_C = 0 \quad (2.5)$$

$$V_L = V_i - (r_s + r_L) i_L - r_C i_C - V_C \quad (2.6)$$

$$i_C = i_L + \frac{V_C + r_C i_C}{R} \quad (2.7)$$

onde:

V_i : tensão de alimentação do circuito;

r_s : resistência intrínseca da chave;

r_s : resistência intrínseca da chave;

R : resistência da carga.

2.3.1 Análise de espaço de estados aplicado ao modelo

Considerando o conversor *Buck* como ideal ($r_s = r_L = r_C = V_D = 0$) e utilizando as equações acima descritas obtém-se as Equações 2.8 e 2.9 as quais representam a dinâmica do circuito quando é inserida ou retirada a fonte V_i do sistema através de um comutador.

$$L \frac{di_L}{d(t)} = qV_i - V_C \quad (2.8)$$

$$C \frac{dv_c}{d(t)} = i_L - \frac{v_C}{R}. \quad (2.9)$$

Tomando os estados $x_1 = i_L$, $x_2 = v_C$ e $q = u$, chega-se a:

$$\dot{x}_1 = -\frac{x_2}{L} + \frac{V_i}{L}u \quad (2.10)$$

$$\dot{x}_2 = \frac{x_1}{C} - \frac{x_2}{RC}. \quad (2.11)$$

Em termos de equações matriciais no espaço de estados, a equação anterior pode ser escrita como:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & -\frac{1}{L} \\ \frac{1}{C} & -\frac{1}{RC} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} \frac{V_i}{L} \\ 0 \end{bmatrix} u \quad (2.12)$$

$$y = \begin{bmatrix} 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} + [0] \cdot u \quad (2.13)$$

Aplicando a transformada de Laplace nas Equações 2.8 e 2.9, chega-se às expressões 2.14 e 2.15:

$$Ls\hat{i}_L = u\hat{V}_i - \hat{V}_C \quad (2.14)$$

$$Cs\hat{V}_C = \hat{i}_L - \frac{\hat{V}_C}{R}. \quad (2.15)$$

Isolando \hat{i}_L na Equação 2.15 tem-se

$$\hat{i}_L = \frac{\hat{V}_C(CRs + 1)}{R}. \quad (2.16)$$

Substituindo 2.16 na Equação 2.14, obtém-se:

$$Ls \left(\frac{\hat{V}_C(CRs + 1)}{R} \right) = u\hat{V}_i - \hat{V}_C. \quad (2.17)$$

Em seguida, isolando \hat{V}_C na Equação 2.17, chega-se a:

$$\hat{V}_C = \frac{u\hat{V}_i R}{LCRs^2 + Ls + R}. \quad (2.18)$$

Para obtermos a função de transferência ($\frac{\hat{V}_c}{u}$), dividimos ambos os lados por u

$$\frac{\hat{V}_c}{u} = \frac{\hat{V}_i R}{LCRs^2 + Ls + R}. \quad (2.19)$$

Isolando V_c na Equação 2.14 e substituindo na Equação 2.15 tem-se a expressão 2.20.

$$\hat{i}_L = \frac{u\hat{V}_i(RCs + 1)}{LCRs^2 + Ls + R}. \quad (2.20)$$

Por fim, para obtenção da função de transferência ($\frac{\hat{i}_L}{u}$), divide-se ambos os lados por u , resultando

$$\frac{\hat{i}_L}{u} = \frac{\hat{V}_i(RCs + 1)}{LCRs^2 + Ls + R}. \quad (2.21)$$

2.3.2 Modelo MATLAB/SIMULINK®

O modelo completo utilizado para a realização das simulações de validação da modelagem é apresentado na Figura 4. Observa-se os três blocos que representam a estrutura do conversor Buck na forma de blocos: *ssBuck* é a modelagem por espaço de estados (Equações 2.8 e 2.9), *ftBuck* é a modelagem por função de transferência (Equações 2.21 e 2.19) e *spsBuck* é o modelo utilizando a biblioteca *SimPowerSystem* do Matlab/Simulink®.

Para poder confrontar os resultados utilizou-se os mesmos parâmetros para todos os blocos apresentados no Quadro 1. Estes foram validados comprovando a eficácia da modelagem, tal como apresentado na Figura 5.

Grandeza	Valor
Tensão de alimentação (V_i)	50V
Tensão de saída (V_o)	20V
Indutor (L)	2,47mH
Capacitor (C)	100 μ F
Carga (R)	10 Ω

Quadro 1 – Parâmetros usados no Buck para estudos preliminares.

Fonte: Autoria própria.

No próximo Capítulo será apresentada uma técnica de controle adaptativo usada para esse conversor, visando melhorar o seu desempenho em relação ao controle PID tradicional na regulação da tensão de saída.

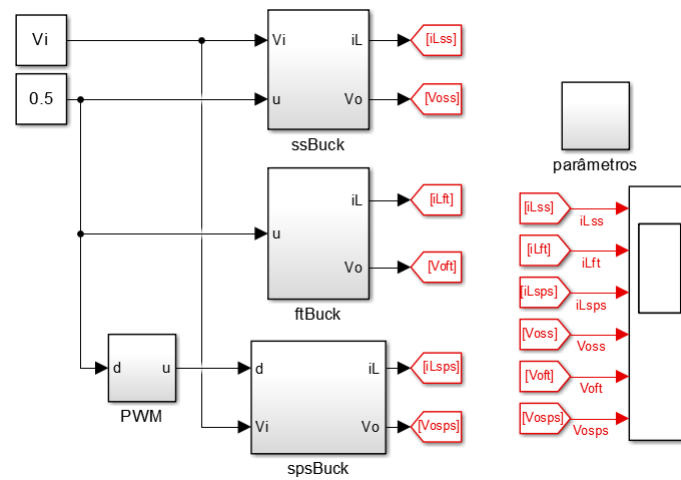


Figura 4 – Modelo Simulink® utilizado para validação.

Fonte: Autoria própria.




Figura 5 – Resposta do sistema para validação do modelo

Fonte: Autoria própria.

3 CONTROLE GAPID

3.1 INTRODUÇÃO

Neste capítulo será apresentada a descrição da técnica de controle não linear baseada em uma função Gaussiana (*Gaussian Adaptive PID - GAPID*), no qual utiliza-se a estrutura de um controlador PID convencional e faz-se com que os ganhos variem através de uma curva Gaussiana relacionada com a amplitude do erro.

A seguir será apresentada a função Gaussiana que determina a regra adaptativa do controlador e comentários a respeito da direção da concavidade da função e do parâmetro que determina o grau da concavidade. Posteriormente, será abordada a questão do agrupamento ou não dos parâmetros, definindo os termos “parâmetros livres” ou “parâmetros vinculados” que serão utilizados em capítulos posteriores.

3.2 CONTROLADOR GAPID

O controle adaptativo proposto é baseado no controle PID linear, tendo como regra adaptativa o uso de funções Gaussianas. A função Gaussiana possui como características desejáveis o fato de ser uma função suave com derivadas suaves, com limites superior e inferior bem definidos e concavidade ajustável.

Essa função dos ganhos do GAPID é dada pela Equação 3.1

$$f(\delta) = k_1 - (k_1 - k_0)e^{-p\delta^2} \quad (3.1)$$

onde δ é o sinal de entrada do controlador, representado pelo erro do sistema, k_0 e k_1 são os ganhos limitadores para entrada nula e entrada infinita, respectivamente, e p é a variável que regula o grau da concavidade da curva Gaussiana.

Trata-se de uma função par, sensível, portanto, ao módulo do sinal de entrada e que permite estabelecer dois patamares de saída: um para valores grandes em módulo do sinal de entrada e outro para valores pequenos.

Há uma região da curva onde estão as maiores derivadas, ou seja, onde a transição dos valores de saída é mais acentuada. A concavidade ajustável permite estabelecer o quão fechada ou aberta a curva Gaussiana será. Isso permite ajustar a posição da faixa dos valores de entrada onde ocorre a transição entre k_0 e k_1 . Quando se pensa em um sistema de controle, pode-se imaginar que há um tipo de controle com ganhos k_0 atuando quando os erros são pequenos e outro com ganhos k_1 quando os erros são grandes. A concavidade, de certa forma, atua como um ajuste na proporção de participação de k_0 e k_1 no controle final.

O parâmetro p possui um significado um tanto abstrato para o projetista e fica difícil ter-se uma noção de qual valor atribuir a este parâmetro. Como alternativa, o valor de p pode ser determinado

como uma função do percentual λ da faixa entre k_0 e k_1 no ponto δ_r , representado pela equação:

$$p = -\frac{\ln\left(\frac{k_1 - f(\delta)}{k_1 - k_0}\right)}{\delta_r^2} = -\frac{\ln(1 - \lambda)}{\delta_r^2}. \quad (3.2)$$

Neste caso, δ_r é um valor de referência escolhido pelo projetista, que pode ser a amplitude do transitório de partida ou de alguma perturbação conhecida.

A Figura 6 mostra a função Gaussiana nas duas concavidades possíveis. A direção da concavidade para cima ocorre quando $k_0 < k_1$ enquanto a concavidade para baixo quando $k_0 > k_1$. As concavidades das Gaussianas dos ganhos proporcional, integral e derivativo serão determinadas durante o processo de otimização, que será visto no Capítulo 5. Apesar disso, é razoável afirmar que interessa ter-se ganhos derivativo e proporcional mais altos e integral mais baixo quando o erro é grande, invertendo essa proporção na medida que o erro diminui. Isso ajuda a dar uma ideia das concavidades das Gaussianas desses ganhos.




Figura 6 – Função Gaussiana: (a) função do ganho proporcional (b) função do ganho integral

Fonte: Autoria própria.

As funções estabelecidas para os ganhos proporcional, integral e derivativo do GAPID são definidas por:

$$k_p(\delta) = k_{p1} - (k_{p1} - k_{p0}) e^{-p_p \cdot \delta^2} \quad (3.3)$$

$$k_i(\delta) = k_{i1} - (k_{i1} - k_{i0}) e^{-p_i \cdot \delta^2} \quad (3.4)$$

$$k_d(\delta) = k_{d1} - (k_{d1} - k_{d0}) e^{-p_d \cdot \delta^2} \quad (3.5)$$

onde:

k_{p0}, k_{i0}, k_{d0} : limites das Gaussianas $p-i-d$ quando a entrada é nula;

k_{p1}, k_{i1}, k_{d1} : limites das Gaussianas $p-i-d$ quando a entrada tende a infinito;

p_p, p_i, p_d : concavidades das Gaussianas $p-i-d$;

δ : variável de entrada (erro do sistema).

Ao iniciar um transitório no qual o erro é alto, a função proporcional oferece um ganho elevado conforme ilustrado na Figura 6(a) ajudando a acelerar a resposta transitória. À medida que o tempo

passa e o erro diminui, o ganho vai sendo gradualmente reduzido, desacelerando a resposta do transitório e auxiliando na redução do sobressinal.

A concavidade da Gaussiana para o ganho integral é o inverso do ganho proporcional. Isso se dá pelo fato de que ganho integral elevado pode levar um sistema a respostas mais lentas, prejudicando o desempenho durante o transitório. Desta forma, para grandes erros deseja-se ganho integral pequeno. À medida que o erro diminui, o ganho integral aumenta, de modo a aumentar o desempenho na correção de erros não nulos pequenos.

O ganho derivativo auxilia na aceleração do transitório e na diminuição do sobressinal. Entretanto, este apresenta o efeito indesejável de amplificação dos ruídos. Sendo assim, utiliza-se o ganho derivativo de uma forma similar ao ganho proporcional, porém considera-se $k_{d0} = 0$ para que o ganho seja nulo quando alcançar o regime permanente. Nesse ponto, o controlador PID passa a ser apenas um PI. Assim, a equação inicial para o ganho derivativo, dada pela Equação 3.5, assume uma forma reduzida, dada pela Equação 3.6.

$$k_d(\delta) = k_{d1} - k_{d1} e^{-p_d \cdot \delta^2} \quad (3.6)$$

Quando se desenvolve um projeto de um PID linear, obtém-se como resultado ganhos lineares fixos (k_p, k_i, k_d) que atendam determinados requisitos de projeto. Porém, no caso do GAPID, embora a estrutura contenha integrador, diferenciador e ganhos como no PID, os ganhos são variáveis e um comportamento bem diferente pode ser obtido. O desafio é encontrar a combinação apropriada dos parâmetros superior, inferior e concavidade que resultem na melhor resposta possível, considerando-se o objetivo do projeto de controle.

Originalmente, o conjunto de parâmetros do GAPID é composto por 8 elementos: $k_{p0}, k_{p1}, p_p, k_{i0}, k_{i1}, p_i, k_{d1}, p_d$. Chamaremos esse conjunto de parâmetros individuais de “parâmetros livres”.

A otimização via parâmetros livres leva a sistemas muito especializados que costumam funcionar bem somente quando trabalham nas condições de operação usadas na otimização. Pequenas mudanças nas condições de operação podem deixar o sistema pouco eficiente. Observou-se que existe um conjunto de ganhos bastante distintos que produzem respostas muito parecidas. Uma delas acaba sendo a melhor, às vezes com diferenças bem pequenas em relação às outras soluções. Essa solução “melhor” é a solução especializada que produz a melhor resposta para aquela condição de otimização em particular, mas pode ser ruim em outra condição de operação. Para tentar contornar esse problema, resolveu-se criar outro conjunto de parâmetros, estes vinculados aos ganhos de um controle PID linear e que, dessa forma, aproveitasse os mesmos requisitos de projeto deste, porém, com desempenho melhorado. Observou-se que, embora a otimização baseada em parâmetros vinculados não leve a soluções tão boas quanto usando os parâmetros livres, as soluções não são tão especializadas e comportam-se melhor face a mudanças das condições de operação.

Assim, neste trabalho é proposta uma forma de vínculo bastante razoável: os limites superior e inferior possuem uma relação na forma $x ; 1/x$ em relação ao ganho linear. A exceção é o ganho derivativo, onde se busca zerar o ganho derivativo quando o sistema entrar em regime, para ajudar a minimizar o efeito da amplificação dos ruídos de alta frequência sobre o controle. Nesse caso, existe

apenas a relação 'z' para o ganho derivativo relacionado ao limite superior da Gaussiana. Desta forma, a expressão completa dessas relações das funções Gaussianas com os ganhos lineares é representada pelas Equações 3.7.

$$\begin{aligned}
 k_{p0} &= x \cdot k_p \quad , \quad k_{1p} = 1/x \cdot k_p \quad , \quad p_p = -\ln(1-\lambda)/\delta_p^2 \\
 k_{i0} &= y \cdot k_i \quad , \quad k_{1i} = 1/y \cdot k_i \quad , \quad p_i = -\ln(1-\lambda)/\delta_i^2 \\
 k_{d1} &= z \cdot k_d \quad , \quad p_d = -\ln(1-\lambda)/\delta_d^2.
 \end{aligned}
 \tag{3.7}$$

Com a vinculação apresentada nas Equações 3.7, o conjunto de parâmetros passa a ter 6 elementos: $x, y, z, \delta_p, \delta_i, \delta_d$. Chamaremos o conjunto desses parâmetros de “parâmetros vinculados”. Esses dois termos serão usados posteriormente para especificar a estratégia de otimização a ser usada.

Em 2015, (KASTER et al., 2015) propôs a utilização de um algoritmo de varredura paramétrica para encontrar os parâmetros vinculados para cada um dos ganhos proporcional, integral e derivativo (conforme Equação 3.7). Esse método demanda um esforço computacional elevado devido ao número de combinações existentes, ou seja, a extensão do espaço de busca, proporcional ao número de pontos considerados em cada parâmetro. A cada combinação efetuada, deve-se testar no modelo e avaliar o desempenho resultante. Desta forma ao final do processo elege-se os parâmetros que tiveram os melhores resultados.

Nesta mesma linha, este trabalho busca incrementar o desempenho obtendo esses ganhos através de metaheurísticas bio-inspiradas de otimização, as quais serão discutidas no Capítulo 5.

4 MÉTRICAS AVALIADORAS DE DESEMPENHO

4.1 INTRODUÇÃO

As métricas são sistemas de mensuração que avaliam quantitativamente uma tendência ou comportamento, permitindo medir e avaliar o desempenho de qualquer ação proveniente do objeto avaliado. Esta ferramenta propicia sustentar de forma estratégica as decisões, permitindo retirar conclusões relevantes do objeto avaliado. Algumas métricas podem ser altamente especialistas, como no caso do objeto estudado neste trabalho: o controle.

Neste capítulo será apresentado um estudo sobre tratamento de variáveis de processo a serem entregues às métricas, bem como as métricas avaliadoras de desempenho.

4.2 ENVELOPAMENTO DO TRANSITÓRIO DE PARTIDA

Quando se utiliza o *settling-time* (tempo de acomodação) como indicador de desempenho, é necessário considerar que se trata de uma função descontínua. Na Figura 7 são apresentados os tempos de acomodação (2% e 5% de margem) como função da variação do coeficiente de amortecimento (ζ), onde é possível evidenciar essa descontinuidade.




Figura 7 – Descontinuidade do tempo de acomodação para 5% e 2%

Fonte: Autoria própria.

Para solucionar esse problema, inclusive para simplificar a obtenção dos tempos de acomodação, optou-se por traçar uma envoltória na resposta obtida (Figura 8).

Esta envoltória inserida na resposta, também chamada de envelopamento da curva, possibilita a obtenção do tempo de acomodação de uma forma suave e sem descontinuidades para um determinado intervalo de coeficientes de amortecimento ($0 < \zeta < 1$). A curva de resposta sempre permanece com um par de envoltórias regidas pela Equação 4.1. A constante de tempo deste envelopamento é dada por $\frac{1}{\zeta\omega_n}$, onde a velocidade de decaimento da resposta do transitório depende do

valor desta constante (OGATA, 2009). Assim, para determinar o tempo de acomodação basta percorrer a envoltória até atingir o limite estipulado no projeto para o sobressinal. Quando a envoltória tocar esse limite obtemos o tempo de acomodação.

$$1 \pm \left(\frac{e^{-\zeta \omega_n t}}{\sqrt{1-\zeta^2}} \right) \quad (4.1)$$




Figura 8 – Envolturamento do transitório

Fonte: Autoria própria.

O tempo de acomodação (T_s) obtido através do envolturamento não apresenta descontinuidade para a variação do coeficiente de amortecimento (ζ). Desta forma obtêm-se resultados confiáveis, com transições suaves até atingir o regime permanente (Figura 9).

4.3 AGENTES MÉTRICAS AVALIADORAS DE DESEMPENHO

Como o objetivo é criar um critério de análise de desempenho, utilizando-se do artifício de envolturamento da curva de resposta para obtenção do tempo de acomodação, adotou-se como métrica de medição de desempenho uma função quadrática que pondera em uma escala percentual do máximo sobressinal admissível com o menor tempo de acomodação. Desta forma, o *COP* (coeficiente de performance, Equação 4.2) penaliza as resposta com um percentual de sobressinal acima do admissível determinado pela constante α (Equação 4.3), tendo como preponderante o tempo de acomodação:

$$COP = T_s(1 + \alpha M_p^2) \quad (4.2)$$

$$\alpha = \left(\frac{1}{M_{\%}} \right)^2 \quad (4.3)$$




Figura 9 – Tempo de acomodação obtido via envelopamento do transitório para 5% e 2%
Fonte: Autoria própria.

onde:

T_s : tempo de acomodação (*settling time*);

M_p : máximo sobressinal admissível;

α : coeficiente percentual quadrático;

$M_{\%}$: porcentagem admissível para o máximo sobressinal.

A curva do valor do COP como função de ζ é apresentada na Figura 10 (a).

Outra forma para obtenção do índice de desempenho é a utilização de técnicas de integração dos erros. Estas visam analisar o erro em função do tempo e determinar um índice de desempenho. Elas podem ser dadas pela integração quadrática dos erros (ISE), integração absoluta dos erros (IAE) e integração quadrática dos erros ponderada no tempo (ITSE), (JAGATHEESAN; ANAND, 2012) descritas respectivamente a seguir.

ISE (*Integral Square Error*): O desempenho do sistema é avaliado pela Equação 4.4:

$$ISE = \int_0^{\infty} e^2(t) dt. \quad (4.4)$$

A característica do resultado desta medida de desempenho é que este método penalizará grandes erros mais do que os menores (já que o quadrado de um grande erro será muito maior). Portanto, o resultado ISE tenderá a eliminar grandes erros rapidamente, mas irá tolerar os pequenos que persistem durante um longo período de tempo. Muitas vezes isso leva a respostas rápidas, mas pode demorar a amortecer pequenas oscilações (Figura 10 (c)).

IAE (*Integral Absolute Error*): Integra o valor absoluto do erro ao longo do tempo, conforme a Equação 4.5

$$IAE = \int_0^{\infty} |e(t)| dt. \quad (4.5)$$

Observa-se que este indicador de desempenho reduz a penalização para os grandes erros iniciais e aumenta a penalização dos erros pequenos que ocorrem mais tarde (Figura 10 (d)).

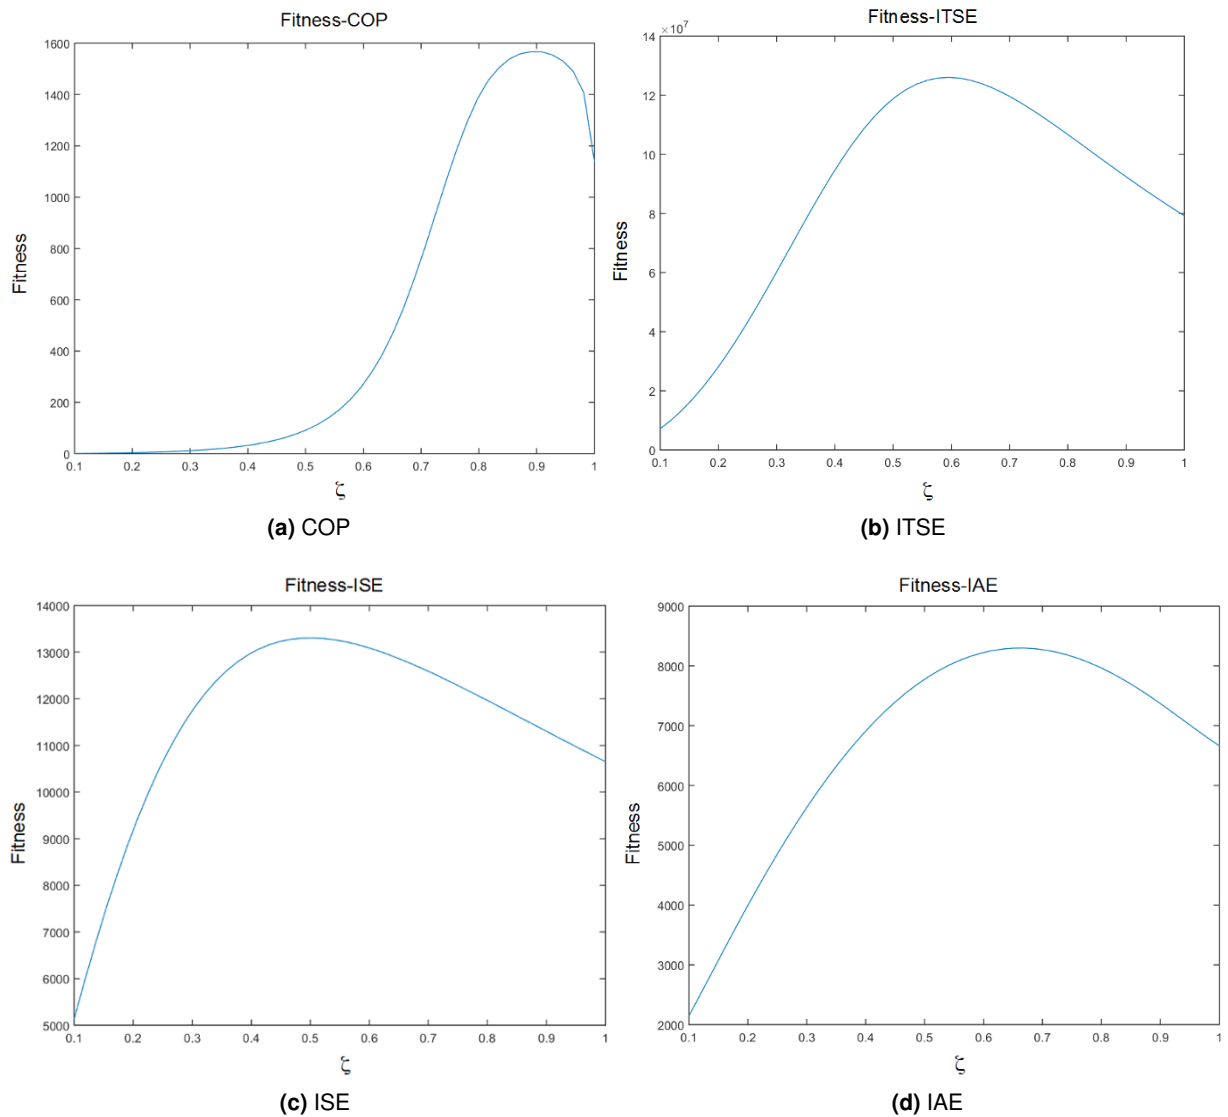


Figura 10 – Comparativo entre as técnicas de análise de desempenho

Fonte: Autoria própria.

ITSE (*Integral Time Square Error*): Uma característica deste método é que o sistema penaliza mais os erros que ocorrem mais tarde do que os iniciais, como evidenciado na Equação 4.6 (Figura 10 (b)):

$$ITSE = \int_0^{\infty} te^2(t)dt. \quad (4.6)$$

Quando aplica-se as técnicas discutidas até agora em um sistema oscilatório, mantendo a frequência natural constante (ω_n) e variando o coeficiente de amortecimento ($0 < \zeta < 1$), obtém-se um comparativo dos resultados das análises de desempenho (performance) Figura 10. Para que a análise seja feita de forma justa, utilizou-se uma função denominada *fit* para ponderar as penalizações de acordo com as premissas do projeto. Sendo assim, quanto maior o erro, menor a nota atribuída à resposta.

$$fit = 1/cost \quad (4.7)$$

A Equação 4.7 será utilizada mais adiante como agente avaliadora de desempenho na otimização, na qual a função custo (*cost*) será uma das métricas analisadas anteriormente.

Da análise dos gráficos da Figura 10 pode-se tirar uma conclusão bastante importante: para cada uma das métricas apresentadas anteriormente, observa-se que a função de avaliação possui um valor máximo ($Fitness_{max}$) que ocorre para um dado valor do coeficiente de amortecimento, referido como ζ_{max} . Pode-se concluir que isso poderá afetar o processo de otimização pois tende a produzir resultados onde o sistema final apresente coeficiente de amortecimento correspondente a ζ_{max} . Da teoria clássica de controle, sabe-se que sistemas com $\zeta < 0.7$ apresentam oscilação no transitório, o que normalmente não é desejado. Portanto, nota-se que as métricas ISE e ITSE possuem $\zeta_{max} < 0.7$, enquanto IAE possui $\zeta_{max} \simeq 0.7$ e apenas COP possui $\zeta_{max} > 0.7$. Isso pode ser um fator decisivo quanto à métrica a ser escolhida para o processo de otimização.

No próximo Capítulo serão utilizadas as métricas avaliadoras de desempenho para verificar a qualidade das respostas encontradas pelos agentes otimizadores.

5 FERRAMENTAS DE OTIMIZAÇÃO

5.1 INTRODUÇÃO

Neste capítulo é apresentada uma revisão sobre as origens e características das metaheurísticas bio-inspiradas propostas neste trabalho, onde o algoritmo genético (AG) e a otimização por enxame de partículas (PSO) são utilizados para encontrar uma solução otimizada na obtenção dos parâmetros das funções Gaussianas dos ganhos de um controlador PID adaptativo.

5.2 ALGORITMO GENÉTICO

O algoritmo genético (AG) é o mais importante representante dos algoritmos evolutivos. Como características marcantes eles são adaptativos e inspirados na evolução natural descrita pela primeira vez por (DARWIN, 1859) em seus livros “*On the Origin of Species*” e “*The preservation of favored races in the struggle for life*”. Nestes foi descrita de forma pioneira a seleção natural – sobrevivência do indivíduo mais adaptado ao ambiente, a recombinação sexual e mutação.

Estes conceitos básicos foram os inspiradores para elaboração dos algoritmos genéticos (AGs) introduzidos por (HOLLAND, 1975) e mais tarde aperfeiçoados por (GOLDBERG, 1989) e (MICHALEWICZ, 1992). AGs são métodos de busca que visam a procura do ótimo global, sem impor restrições sobre a função a ser otimizada, como continuidade ou dimensionalidade. Ele é o adequado para solução de problemas com espaços de busca grandes e complexos, em que a enumeração de todas as soluções possíveis (busca aleatória) não é possível ou muito custosa. O AG é aplicado com sucesso em diferentes campos que variam desde a previsão de séries temporais ((SIQUEIRA, 2009), (WANG et al., 2016)), otimização de carga em contêineres (SUPENO; RUSMIN; HINDERSAH, 2015), teoria de jogos (BONOMO; LAUF; YAMPOLSKIY, 2015), controle de frota de veículos usando visão computacional (ROMERO; TRIGUEROS, 2006), projeto de circuito eletrônico (SARVI; SALIMIAN, 2010), a previsão do mercado de ações (BOONPENG; JEATRAKUL, 2014), para otimizar os indicadores técnicos do mercado financeiro (IBRAHIM; RAAHEMIFAR, 2016), telefonia celular (AZEVEDO; RIBEIRO, 2013), dentre outros.

Uma vez que a evolução natural ocorre nos cromossomos e não nas próprias entidades biológicas, uma solução possível é representada por uma versão codificada dos parâmetros (genótipo) num algoritmo genético. Esta representação é realizada como cadeia linear de genes e chamada indivíduo. O mapeamento do genótipo ao fenótipo correspondente depende inteiramente da estrutura do problema e tem de ser adaptado pelo usuário. De acordo com a natureza, não se usa um único indivíduo, mas um conjunto deles, a população ($p(t)$). Após a inicialização, um número é atribuído a cada indivíduo que determina a aptidão para a sobrevivência (chamada de *fitness*). Dois indivíduos são escolhidos com probabilidades proporcionais à posição relativa na população atual e se acasalam para produzir novos indivíduos (*crossover*). Este tem característica exploradora propiciando criar pequenos desvios aleatórios, ficando assim perto da sua linhagem. Esta etapa é repetida até que indivíduos suficientes sejam criados para formar a próxima população. Estes novos indivíduos podem

ser modificados novamente por mutação aleatória que ocorre com uma probabilidade fixa, mas pequena (MICHALEWICZ, 1992). Com isso, pode-se recuperar as boas características eventualmente perdidas nos processos de seleção e cruzamento, evitando ficar preso em determinadas regiões do espaço de busca ou em pontos de ótimos locais (NéIA et al., 2013). Posteriormente, esta nova população é avaliada e as subseqüentes são criadas até que uma condição de terminação seja atendida. Assim como na natureza, o processo evolutivo perpassa por toda população e não apenas em um único indivíduo.

A terminologia empregada originalmente no algoritmo genético é a mesma da teoria da evolução natural e da genética (Quadro 2).

Biologia	Algoritmo Genético (AG)
Gene	Parâmetros que caracterizam o indivíduo
Cromossomo	Indivíduo
Alelo	Valor dos parâmetros do gene
Locus	Posição de um gene no indivíduo
Genótipo	Indivíduo candidato a uma solução – x
Fenótipo	Valor da função para um dado indivíduo – $f(x)$

Quadro 2 – Relação da terminologia do AG com a Biologia

Fonte: (BARBOZA, 2005).

5.2.1 População Inicial

A população é inicializada inserindo as características desejadas em cada indivíduo de uma forma aleatória e uniforme, visando maximizar a distribuição dos mesmos no espaço amostral. Estas características são norteadas pelo objetivo da busca: por exemplo, deseja-se otimizar um controlador PID linear em que as características de cada indivíduo (genes) são as variáveis K_i , K_p , K_d . Entretanto, se é conhecida a dinâmica da função custo, pode-se utilizar este conhecimento para inserir na população indivíduos com potencial de boas soluções ((NéIA et al., 2013), (PINHO et al., 2013)). Em contrapartida, a proporção de indivíduos com conhecimento prévio deve ser dimensionada de tal forma que evite uma convergência prematura (PINHO et al., 2013).

O tamanho da população auxilia no aumento da eficiência, visto que a população inicial deve cobrir a maior parte do espaço de busca da solução. Uma população pequena pode resultar em uma convergência prematura enquanto uma muito grande requer elevado esforço computacional ((LEÓN-ALDAGO; CALLEJA; ALQUICIRA, 2015; ROEVA; FIDANOVA; PAPRZYCKI, 2013), (PINHO et al., 2013)).

Uma vez gerados, os indivíduos passam pelo processo de seleção e após isso estarão sujeitos aos operadores genéticos, a saber, *crossover* e mutação. É a aplicação de tais operadores de forma iterativa que permite que o processo de otimização ocorra e os ótimos das funções sejam procurados.

5.2.2 Crossover (Recombinação)

O operador de recombinação (*crossover*) permite a geração de filhos que herdam genes dos seus pais, tendo por finalidade combinar as informações genéticas de dois indivíduos. Apresenta como característica o poder exploratório, permitindo ao algoritmo realizar buscas locais e refinamento de soluções. Tradicionalmente esta recombinação pode ser por ponto ou aritmética quando a codificação do problema é real.

A recombinação por ponto está classicamente vinculada a um contexto de codificação binária. Neste método escolhe-se dois indivíduos (pais) da população e gera-se outros dois filhos. O processo é realizado selecionando aleatoriamente os pontos de recombinação, conforme ilustrado na Figura 11. Portanto, esta metodologia pode ser aplicada ao contexto de qualquer codificação.

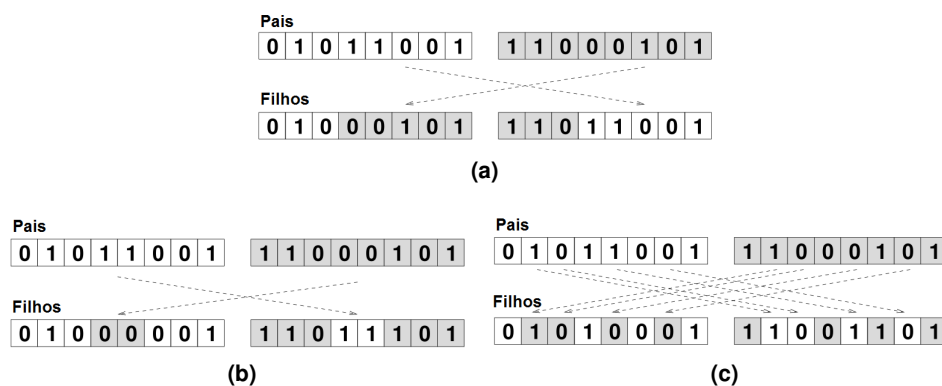


Figura 11 – (a) crossover 1 ponto, (b) crossover 2 pontos, (c) crossover uniforme

Fonte: (TUTORIALSPPOINT.COM, 2016).

Para codificação com números reais é possível utilizar o método desenvolvido por (MICHALEWICZ, 1992), no qual a combinação percentual dos pais (p_1 e p_2) geram novos filhos f_1 e f_2 , por meio de uma combinação linear entre seus genes (equações 5.1 e 5.2). O termo α será uma constante pré-determinada pelo usuário ($0 < \alpha < 1$).

$$f_1 = (1 - \alpha)p_1 + \alpha p_2 \quad (5.1)$$

$$f_2 = \alpha p_1 + (1 - \alpha)p_2. \quad (5.2)$$

5.2.3 Mutação

A finalidade da mutação em AGs é introduzir a diversidade. Deve permitir que o algoritmo evite os mínimos e máximos locais impedindo que a população de cromossomos se torne muito similar entre si, retardando ou mesmo interrompendo a evolução. Este raciocínio também explica o fato de que a maioria dos algoritmos evita levar apenas o mais apto da população à próxima geração, mas sim uma seleção aleatória com uma ponderação para aqueles que estão mais aptos (PINHO et al., 2013).

Dos diversos métodos para obter a mutação escolhe-se para discutir a uniforme e a Gaussiana. Na mutação uniforme, um gene é selecionado e substituído por outro gerado por meio de uma distribuição uniforme no intervalo permitido dos seus alelos (Figura 12).

Indivíduo	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	
Indivíduo mutado	0	1	0	0	1	0	1	1	0	0	0	1	0	1	1	0	0	1

Figura 12 – Mutação Uniforme

Fonte: (SIQUEIRA, 2009).

Na mutação Gaussiana, os genes de um cromossomo c são modificados aleatoriamente no conjunto de uma população obedecendo um vetor gaussiano de média zero e desvio padrão fixo $N(0, \sigma)$ (MICHALEWICZ, 1992), conforme ilustrado na Equação 5.3

$$c' = c + N(0, \sigma) \quad (5.3)$$

onde c' é o novo cromossomo.

5.2.4 Seleção

Este processo tem como função direcionar o processo evolutivo para regiões mais promissoras, nas quais podem ser encontrados os indivíduos mais adaptados (BARBOZA, 2005). Assim, quando a população aumenta devido ao operador de recombinação (*crossover*), o processo seletivo age como regulador populacional eliminando o excedente (indivíduo com baixo grau de adaptação) e mantendo-a com tamanho fixo. Entretanto, embora a probabilidade dos mais aptos serem selecionados seja mais elevada, é possível que indivíduos de menor *fitness* possam participar da nova geração. Alguns métodos de seleção são apresentados a seguir.

- **Roleta:** A seleção dos indivíduos é feita de forma aleatória, atribuindo para cada um uma parcela, que é correspondente ao seu grau de adaptação (*fitness*). Assim, a probabilidade do indivíduo ser selecionado é proporcional à parcela ocupada na mesma. Entretanto, esse método tem a desvantagem de possuir uma alta variância, privilegiando indivíduos que possuem alto valor de aptidão, podendo o mesmo ser sorteado várias vezes ou não ser sorteado. Esta falha pode direcionar para uma solução local prematuramente. Em contrapartida, quando a evolução está avançada, observa-se uma estagnação do algoritmo (BARBOZA, 2005). Este problema pode ser contornado quando se utiliza um processo de seleção elitista ou a realização de um novo sorteio (PINHO et al., 2013) (Figura 13).
- **Torneio:** Ao utilizar o método de seleção por torneio, uma competição é iniciada com um subconjunto da população e não com todos os indivíduos. A ideia consiste em escolher-se k indivíduos, extrair o melhor deste grupo para uma população intermediária. Este procedimento é repetido com reposição até que a população intermediária tenha o mesmo número de indivíduos da população da geração anterior (BARBOZA, 2005) (Figura 14).

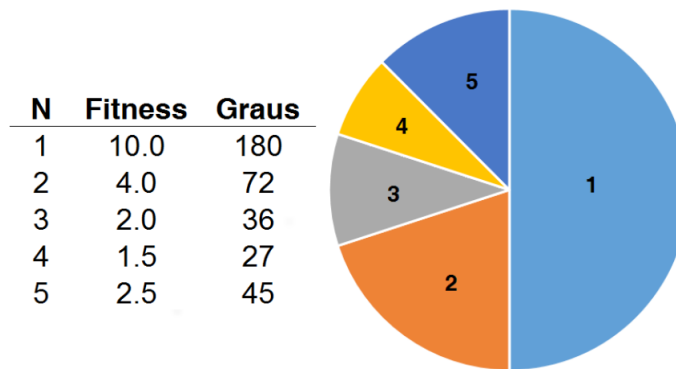


Figura 13 – Seleção por Roleta
Fonte: (TUTORIALSPPOINT.COM, 2016).

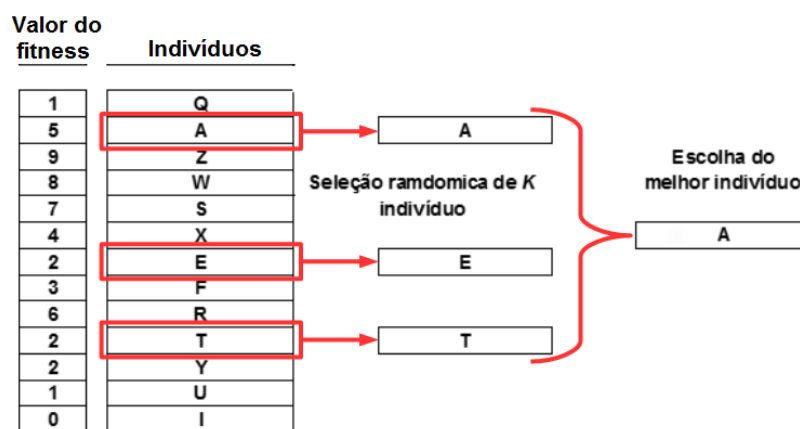


Figura 14 – Seleção por Torneio
Fonte: (TUTORIALSPPOINT.COM, 2016).

5.2.5 Avaliação do Grau de Adaptação do Indivíduo

Para cada indivíduo da população é atribuída uma nota, graduando assim a adaptação de cada solução ao problema. Em outras palavras, indivíduos mais adaptados – ou cromossomos que resultem em melhores resultados – possuem maior *fitness*. Quanto maior, mais adaptado ao meio e, assim, maior sua a probabilidade de sobrevivência. Esta conversão depende da função custo J_w desejada e normalmente busca-se reduzir a função custo para aumentar o grau de adaptação do indivíduo J_{fit} (BOCCATO et al., 2009).

$$J_{fit} = \frac{1}{1 + J_w} \quad (5.4)$$

Quanto maior for o valor de aptidão, maiores as chances de o indivíduo sobreviver no ambiente e reproduzir-se, passando seu material genético para as gerações futuras. Desta forma, o processo avaliativo é efetuado a cada aplicação dos operadores recombinação, mutação e seleção durante a iteração (geração) vigente.

5.2.6 Busca Local e Elitismo

A seleção elitista consiste em reinserir o cromossomo (indivíduo) melhor adaptado de uma geração para a seguinte, evitando assim a perda de indivíduos importantes e de alta aptidão durante o processo de seleção. Desta forma, armazena-se temporariamente o indivíduo melhor adaptado da geração, para que no final este seja reintroduzido na população, mesmo que não esteja na última geração do processo (BARBOZA, 2005). Quando o critério de parada for aceito, o melhor indivíduo desta geração provavelmente será a solução desejada (BARBOZA, 2005).

A busca local, por outro lado pode ser realizada em um conjunto de indivíduos com os melhores valores de *fitness*. Neste caso, pequenas perturbações pseudo-Gaussianas podem ser somadas ao valor de um de seus genes por vez, a fim de avaliar na vizinhança se alguma solução neste espaço melhora a adaptação dos mesmos. Em geral, esta operação é realizada após determinado número de iterações (GLOVER, 2002).

5.2.7 Etapas do Algoritmo Genético Clássico

As etapas básicas de um clássico algoritmo genético proposto por (HOLLAND, 1975), bem como o pseudocódigo são apresentados a seguir:

Pseudocódigo:

1. Gerar uma população inicial com N_{pop} ;
2. Determinar o número máximo de iterações;
3. Calcular a aptidão dos indivíduos da população inicial;
4. Em cada iteração, fazer:
 - a) Selecionar pares de pais da população para *Crossover*;
 - b) Realizar o *Crossover*, criando uma população intermediária;
 - c) Realizar Mutação na população;
 - d) Calcular a aptidão da prole;
 - e) Realizar a seleção;
 - f) A cada n_{gen} gerações realiza-se uma busca local.
5. A busca prossegue até atingir o número máximo de iterações ou algum outro critério previamente estabelecido.

5.2.8 Evolução Temporal do Fitness no AG

A evolução temporal do *fitness* do melhor indivíduo classicamente sempre é ascendente se adotada a estratégia de elitismo. Já o *fitness* médio pode variar pois a mutação pode levar indivíduos

para regiões menos promissoras. A probabilidade de que a média do *fitness* aumente com o passar das gerações varia devido à aleatoriedade envolvida na criação de cada população genética, ficando assim, oscilando abaixo do melhor indivíduo. A Figura 15 apresenta um exemplo de como o *fitness* médio e o máximo podem se comportar durante o processo evolutivo.

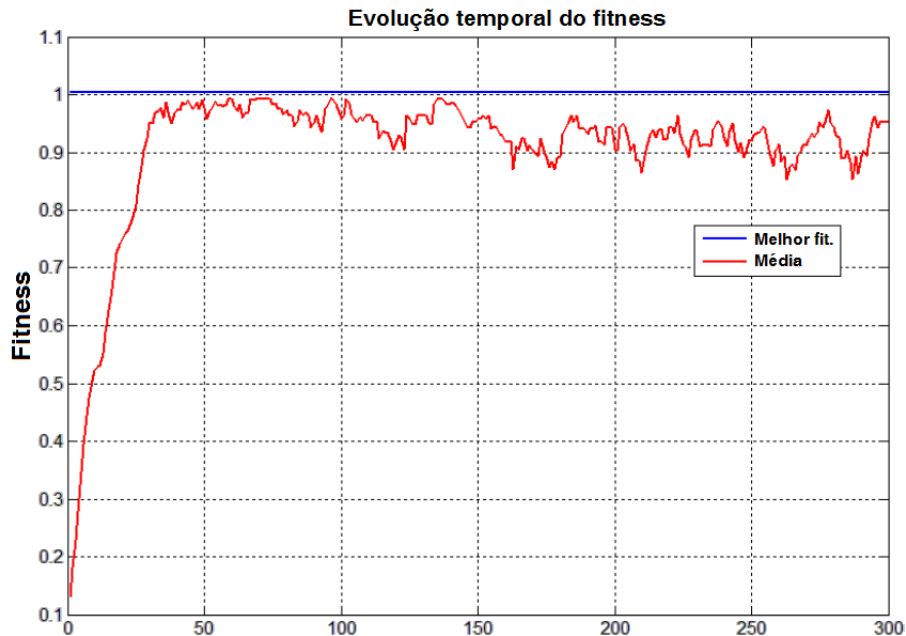


Figura 15 – Evolução temporal do *fitness*
Fonte: (BHATTACHARJYA, 2013).

5.3 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO)

Inspirado no comportamento social e na dinâmica de movimentos e comunicação de pássaros e peixes, a estrutura de otimização proposta por (KENNEDY; EBERHART, 1995), o algoritmo de otimização por enxame de partículas (PSO), combina a experiência particular e social do grupo para solucionar um problema de forma coletiva. A distribuição dos membros deste enxame no espaço de busca para solução de um problema é delimitada por dois componentes básicos: a posição em que se encontra (x_p) e a velocidade (v_p). A convergência para a melhor solução do problema é atraída por duas forças aleatórias – com vistas a melhorar sua localização ($pbest$) e outra pela melhor localização encontrada pelo enxame ($gbest$). No algoritmo proposto por (KENNEDY; EBERHART, 1995), a cada iteração estes dois componentes (x_p , v_p) são atualizados (Equações 5.5 e 5.6) tendo como limitante a velocidade máxima que essa partícula pode atingir (V_{max}). Já que esta é utilizada para limitar as velocidades das partículas evitando que ocorram grandes saltos, ou que o movimento seja lento. Sendo assim, as Equações 5.5 e 5.6 replicam o comportamento do enxame

$$v_p^{(it+1)} = v_p^{(it)} + c_1 \cdot rand_1^{(it)} [pbest_p - x_p^{(it)}] + c_2 \cdot rand_2^{(it)} [gbest_p - x_p^{(it)}] \quad (5.5)$$

$$x_p^{(it+1)} = x_p^{(it)} + v_p^{(it+1)}. \quad (5.6)$$

onde:

v_p : velocidade da partícula;

c_1, c_2 : coeficientes cognitivos e social;

$pbest_p$: melhor posição que a partícula p já obteve durante a busca;

$gbest_p$: melhor posição encontrada na vizinhança da partícula p ;

$rand()$: função aleatória de distribuição uniforme entre 0 e 1;

$x_p^{(it+1)}$: posição da partícula p ;

it : iteração atual.

Em 1998, (SHI; EBERHART, 1998) propôs alterar o funcionamento original do PSO inserindo um coeficiente de inércia (w) na equação da velocidade (Equação 5.7), limitando o tamanho da área a ser explorada pela partícula. Neste contexto, (EBERHART; SHI, 2000) notou que por meio de diferentes pesos inerciais é possível ampliar ($w = 0,9$) ou restringir ($w = 0,4$) o espaço de busca. Se o valor do peso inercial for pequeno, a partícula irá realizar uma busca local mais refinada, porém, se tiver um valor maior, a busca será mais ampla, rastreando uma maior área dentro de uma região delimitada. Portanto, a escolha de um valor de equilíbrio para o parâmetro pode influenciar as habilidades das partículas na exploração global e local. Por outro lado, o decremento linear do momento de inércia durante o processo de busca conduzirá a bons resultados, visto que inicialmente ocorre uma exploração de espaços maiores e no decorrer das iterações o raio da busca será reduzido, permitindo encontrar um ótimo local (EBERHART; SHI, 2000). Desta forma, obtém-se um melhor controle sobre o processo de busca eliminando a importância da velocidade máxima da partícula (V_{max}).

$$v_p^{(it+1)} = wv_p^{(it)} + c_1 \cdot rand_1^{(it)} \left[pbest_p - x_p^{(it)} \right] + c_2 \cdot rand_2^{(it)} \left[gbest_p - x_p^{(it)} \right] \quad (5.7)$$

Outro comportamento relatado por (EBERHART; SHI, 2000) é a influência que as componentes cognitiva (c_1) e social (c_2) tem sobre o resultado final. Visto que influenciam na qualidade da solução através da experiência da própria partícula ($pbest$) e do grupo ($gbest$), acelerando e desacelerando o processo de busca. Como mencionado por (EBERHART; SHI, 2000), a escolha recomendada para as constantes c_1 e c_2 é 2 (dois). Sob esta condição, a partícula tem seu espaço de busca estatisticamente contraído levando o enxame à melhor posição atual ($gbest$).

O funcionamento básico do algoritmo PSO é apresentado pelo fluxograma da Figura 16.

Ao iniciar um enxame de partículas, limita-se a posição das mesmas dentro do espaço de busca do problema, ou seja, distribui-se de forma aleatória os integrantes do enxame variando suas posições para evitar aglomeração. Cada partícula será avaliada através de uma função de aptidão ($fitness$) que representará uma solução pontual dentro do espaço de busca e, se sua posição for a melhor já encontrada, ela será armazenada na variável $pbest$. O valor da componente cognitiva

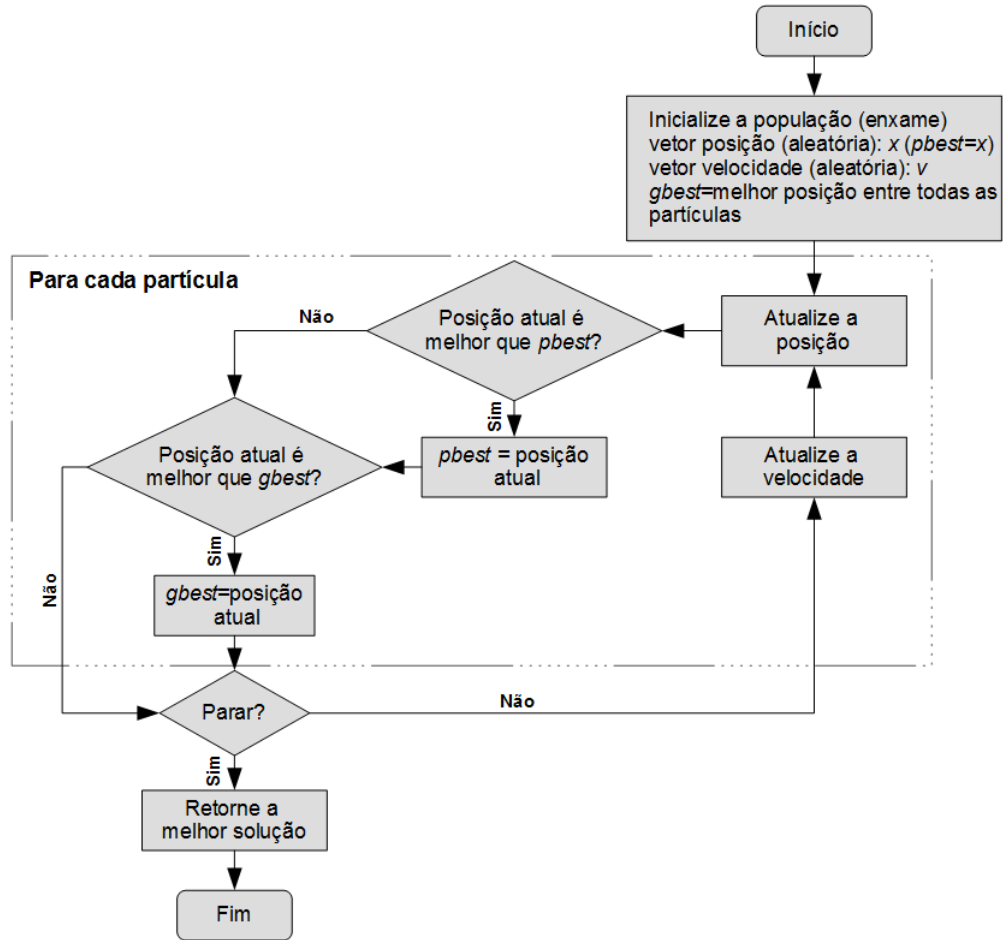


Figura 16 – Fluxograma básico do algoritmo PSO

Fonte: (NASCIMENTO et al., 2013).

(*pbest*) será determinada pela constante de aceleração c_1 (termo cognitivo), que atualiza a velocidade de uma partícula em direção ao melhor resultado local, levando em consideração as experiências passadas. Da mesma forma, quando o enxame encontrar uma melhor posição geral, esta será armazenada pela variável *gbest*. A velocidade para disseminar a melhor posição encontrada para o enxame será determinada pela constante c_2 , que é um termo de aceleração desta troca de informação. O tamanho da área na qual esta solução pontual (partícula) irá “sobrevoar” é determinada pelo coeficiente de inércia (w).

Sendo assim, até que o critério de parada seja satisfeito, a cada iteração a velocidade será atualizada pelo *pbest* e *gbest*. Após isso, cada partícula terá sua posição atualizada em função do acréscimo da velocidade.

Neste contexto, o PSO é semelhante a um algoritmo genético (AG), pois ambas inicializam e distribuem suas populações de forma aleatória. Porém, ao contrário do AG, cada potencial solução tem sua velocidade inicializada aleatoriamente, as potenciais soluções, chamadas de partículas, “sobrevoam” o espaço de busca n -dimensional ajustando seu “vôo” baseado na própria experiência e na experiência coletiva (EBERHART; SHI, 2000). Outras similaridades são que ambas são baseadas em população e tanto partícula quando indivíduos representam uma solução para um problema.

As divergências estão em que o PSO não possui o processo multiplicação e de seleção e todos os integrantes da população inicial (enxame) continuam vivos até encontrar a solução para o problema.

No Capítulo 6 serão apresentados os testes de parametrização efetuados com o propósito de encontrar o melhor conjunto de parâmetros para o PSO para o controlador PID Gaussiano e os resultados experimentais de sua aplicação ao conversor Buck.

6 RESULTADOS EXPERIMENTAIS

6.1 INTRODUÇÃO

Neste capítulo é feita uma descrição detalhada do protótipo, da modelagem utilizada para realizar o experimento e das técnicas de otimização selecionadas para a estimação dos parâmetros. Por uma questão metodológica, todos os estudos realizados tiveram como base as simulações do modelo. Em seguida, tais resultados foram validados num protótipo em laboratório.

6.2 PROTÓTIPO

O protótipo apresentado na Figura 17, foi desenvolvido por (LUCAS, 2015) para confrontar os dados de sua pesquisa com a parte prática. Foi utilizado o kit de desenvolvimento DE0-nano da empresa Terasic, dotado de um FPGA da marca Altera®, modelo Cyclone IV EP4CE22F17C6N, para embarcar o projeto de controle discutido em sua pesquisa.

Este kit possui 22230 elementos lógicos, um conversor A/D de 12 bits de resolução com 8 canais multiplexados, com configuração de velocidade de 50 a 200 mil amostragens por segundo. O cristal responsável pelo clock possui uma frequência de 50 MHz, sendo possível manipular diferentes frequências de clock internamente com as quatro PLLs existentes no FPGA.




Figura 17 – Conversor Buck
Fonte: (LUCAS, 2015).

O FPGA é um HCPLD (*High Capacity Programmable Logic Device*) que suporta a implementação de circuitos lógicos relativamente grandes. Consiste em um grande arranjo de células lógicas ou blocos lógicos configuráveis contidos em um único circuito integrado. Cada célula contém capacidade computacional para implementar funções lógicas e realizar roteamento para comunicação entre elas. Existem vários meios de embarcar um projeto em um FPGA, porém a programação utilizando interfaces gráficas através de blocos digitais, como o DSP Builder, vem se destacando pela

facilidade no desenvolvimento e interação com o programador. Esta ferramenta trabalha juntamente com o software Matlab®, permitindo gerar algoritmos capazes de interagir com simulações usando os elementos da biblioteca padrão.

Tanto o protótipo quanto a modelagem utilizada por (LUCAS, 2015) serão reutilizadas como ferramenta experimental para esse trabalho. A modelagem desenvolvida pelo autor será utilizada para embarcar os parâmetros otimizados, visto que nesta modelagem a estrutura dos controles PID e GAPID já está desenvolvida.

Para o processo de otimização, uma nova modelagem foi desenvolvida (Figura 18) tomando como base a pesquisa realizada por (LUCAS, 2015). Desta forma, foram necessários ajustes no modelo para que fosse mantida a similaridade entre os modelos e o protótipo .

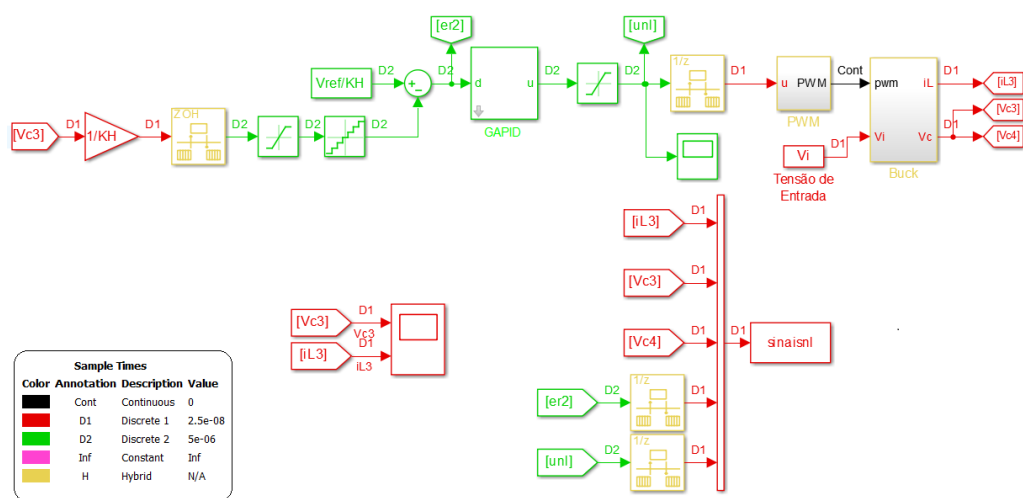


Figura 18 – Modelo do Buck no Simulink®

Fonte: Autoria própria.

Na Figura 19 é apresentada a estrutura esquemática básica do protótipo da Figura 17, onde observa-se o sensoriamento utilizado e o tratamento destes sinais por um diagrama em blocos.

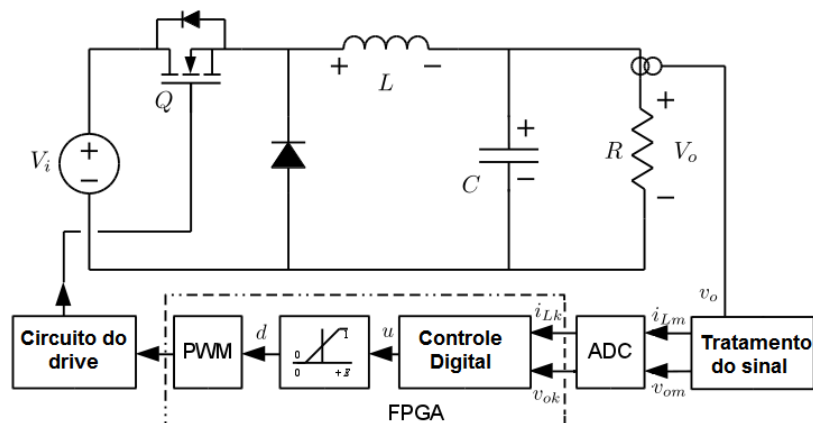


Figura 19 – Esquemático do conversor e sistema de controle.

Fonte: Autoria própria.

As especificações deste conversor (Quadro 3) correspondem fielmente ao protótipo e modelos.

Grandeza	Símbolo	Valor
Capacitor	C	100 μF
Varição tensão no capacitor	$\Delta V_c\%$	10%
Resistência do capacitor	r_C	0,2 Ω
Indutor	L	2,54 mH
Varição corrente no indutor	$\Delta I_L\%$	10%
Resistência do indutor	R_L	0,81 Ω
Resistência série da chave	R_{on}	0,55 Ω
Queda de tensão diodo	V_d	1 V
Frequência de comutação	f	50 KHz
Tensão de alimentação	V_i	50 V
Tensão de saída	V_O	20 V
Carga	Ω	10 Ω

Quadro 3 – Parâmetros usados no projeto do conversor Buck

Fonte: Autoria própria.

6.3 ESTUDO PARAMÉTRICO PARA O PSO

Conforme descrito no capítulo anterior, o PSO é da classe da inteligência de enxame que tem como característica a presença de estruturas (seres) que realizam tarefas individuais, mas o trabalho coletivo mostra-se inteligente. Este enxame é composto por partículas nas quais a posição (x_p) e a velocidade (v_p) são as componentes que conduzem a partícula para uma possível solução. Entretanto, a experiência própria ($pbest$) e do grupo ($gbest$) direcionam o enxame para uma solução coletiva (convergência). Desta forma, coeficientes como: inércia (w), termos cognitivo (c_1) e social (c_2), influenciam diretamente na qualidade da solução alcançada. Com base nesta afirmativa, houve a necessidade de avaliar as respostas obtidas pelo PSO para diferentes configurações destes coeficientes. Para isso foram efetuadas em média 30 execuções independentes para cada configuração.

O primeiro desafio é como apresentar um conjunto de parâmetros para avaliação (codificação), visto que o problema em questão é composto por seis parâmetros.

A estruturação de uma população de possíveis partículas candidatas deve ser organizada de tal forma que a partícula tenha um espaço de memória, onde serão armazenadas as informações provenientes de outras partículas e suas condições (posição e velocidade). A estrutura mais simples para essa aplicação é uma matriz de três dimensões, como mostrado na Figura 20.

A solução para o problema proposto neste trabalho será composta por uma partícula hexadimensional $p_n = (x, y, z, \delta_p, \delta_i, \delta_d)$, onde as dimensões são cada um dos parâmetros do GAPID, e a função de aptidão (*fitness*) de cada partícula é uma função que envolve todos os parâmetros e

poderia ser escrita como $fit = f(x, y, z, \delta_p, \delta_i, \delta_d)$. Dentro do conceito do PSO, cada partícula p_n é um valor hexadimensional, bem como sua velocidade $v_n = (v_x, v_y, v_z, v_p, v_i, v_d)$ e sua melhor posição individual $pbest_n = (p_x, p_y, p_z, p_p, p_i, p_d)$.

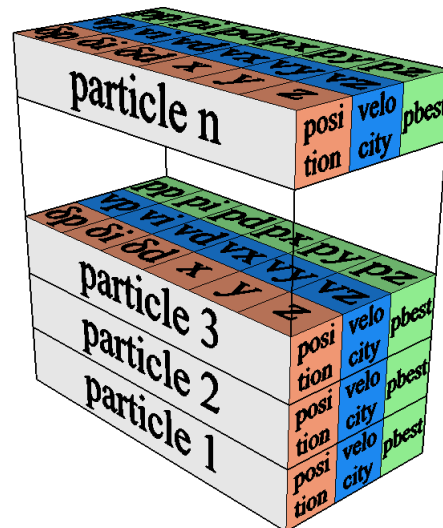


Figura 20 – Organização do enxame de partículas
Fonte: Autoria própria.

De posse de um enxame de partículas já estruturado e devidamente distribuído sobre o espaço de busca, utilizou-se a equação proposta por (SHI; EBERHART, 1998) (Equação 5.7) para verificar a melhor forma de parametrizar o PSO. Deve-se salientar que, para que a experiência fosse realizada de forma justa, os enxames partiram do mesmo ponto para convergir para uma solução. A Tabela 1 é composta por oito itens, correlacionados com os gráficos das Figuras 21 e 22. Desta forma, os valores contidos no item 1 da Tabela 1 estão representados no gráfico 1 das Figuras 21 e 22.

A análise dos dados contidos na Tabela 1 levará em consideração quatro variáveis: o tempo de subida (T_r), o máximo sobressinal (M_p), o tempo de acomodação (T_s) e o *fitness* ($fit = 1/IAE$). No item 1, o pior resultado, utilizou-se o momento de inércia e um valor aleatório fixo para as variáveis c_1 e c_2 . No item 2, optou-se por variar o momento de inércia de forma decrescente para inicialmente explorar grandes áreas e à medida que o tempo fosse passando iria contraindo esse espaço de busca induzindo o melhor resultado. Da mesma forma, variou-se o termo cognitivo de forma decrescente para que as partículas tivessem inicialmente maior interação com seus vizinhos e que isso fosse sendo reduzido ao passar do tempo. O termo social, que determina o grau de influência do enxame nas partículas, variou de forma crescente visando aumentar a influência do enxame nas partículas a medida que o tempo fosse passando, o que culminou em um resultado melhor que o item 1. O item 3 está relacionado com o PSO original proposto por (KENNEDY; EBERHART, 1995), onde obtivemos o terceiro melhor resultado. Quando o momento de inércia foi inserido (0, 9) no item 4, obteve-se um resultado melhor que o experimento anterior. Nos itens subsequentes, manteve-se os coeficientes de aceleração em 2 (dois) (EBERHART; SHI, 2000) e variou-se o momento de inércia de forma decrescente com o objetivo de encontrar a melhor configuração para esses parâmetros. Portanto,

pode-se comprovar através dos estudos apontados por (EBERHART; SHI, 2000) e (NASCIMENTO et al., 2013) que o melhor resultado fora obtido com a configuração apontada pelo item 8.

Tabela 1 – Resultados obtidos do estudo paramétrico utilizando PSO

Item	w_{in}	w_{fim}	$c1_{ini}$	$c1_{fim}$	$c2_{ini}$	$c2_{fim}$	T_r (ms)	M_p (%)	T_s (ms)	Fitness
1	0,9	0,9	1,5	1,5	1,5	1,5	1,80000	0,74	1,2000	4165,86
2	0,9	0,2	2,0	0,2	0,2	2,0	1,20000	2,54	0,9510	4553,34
3	1	1	2,0	2,0	2,0	2,0	0,70255	2,81	0,62440	4994,01
4	0,9	0,9	2,0	0,2	0,2	2,0	0,90613	3,68	0,79330	5995,73
5	0,6	0,4	2,0	2,0	2,0	2,0	0,69093	3,41	0,61910	5972,36
6	1,2	0,8	2,0	2,0	2,0	2,0	0,71668	1,95	0,62968	6039,64
7	1,2	0,4	2,0	2,0	2,0	2,0	0,70848	2,26	0,62648	6027,70
8	0,9	0,4	2,0	2,0	2,0	2,0	0,71268	1,62	0,62753	6072,62

Fonte: Autoria própria.

Analisando a evolução da função de aptidão (Figura 21), fica evidente a influência que a parametrização do PSO tem sobre o resultado encontrado. Observe que o valor do *fitness* pode ser normalizado no intervalo [0;1] dividindo-se pelo valor máximo possível de ser encontrado. Entretanto, neste trabalho optou-se por manter a escala original.

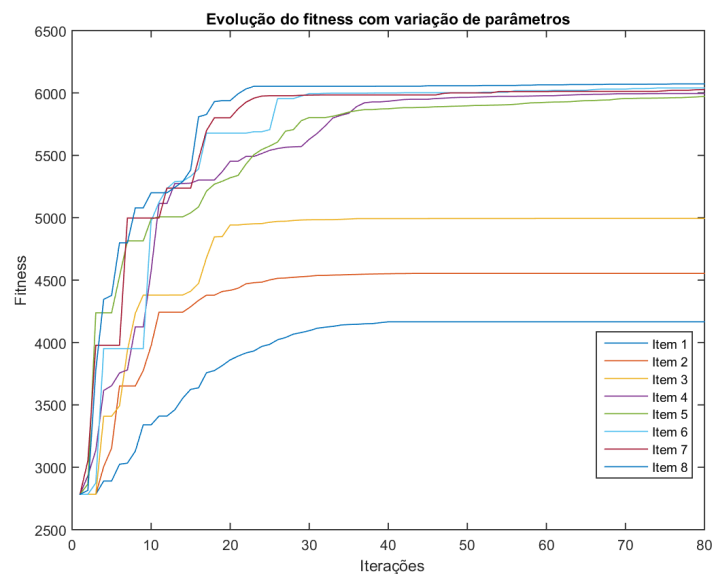


Figura 21 – Evolução do *fitness* no estudo paramétrico (PSO)

Fonte: Autoria própria.

Ao analisar-se o gráfico de resposta (Figura 22), nota-se que há uma distância considerável entre os resultados dos primeiros três itens com as demais configurações. Isso ocorreu devido aos testes realizados com o PSO original e variações de parâmetros.

Além da parametrização do PSO, outro ponto crítico é a escolha da função de aptidão. Esta função, conhecida como *fitness*, penaliza as soluções fora do padrão e privilegia os melhores resultados. O sucesso da otimização dependerá desta escolha.

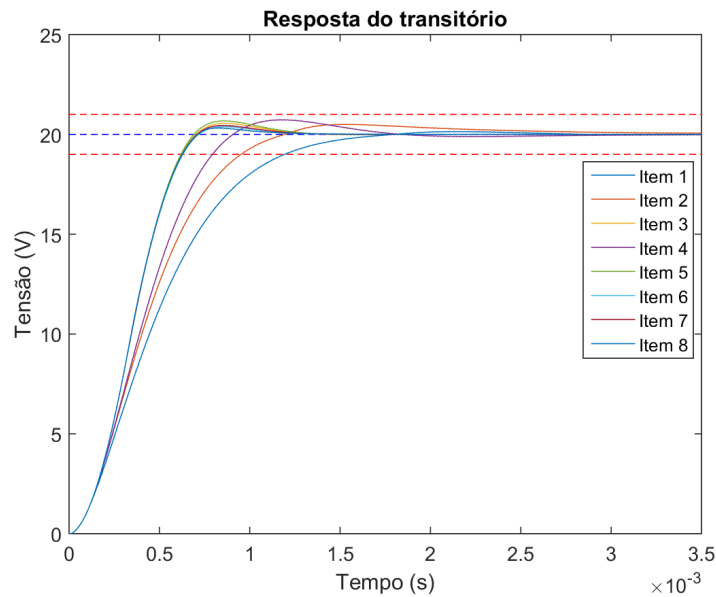


Figura 22 – Transitório de resposta após a otimização (PSO)
Fonte: Autoria própria.

Neste sentido, procede-se um estudo sobre como analisar e ponderar essa “performance” desejada. Inicialmente, escolheu-se quatro técnicas de análise de desempenho, uma utilizando uma função quadrática que pondera o tempo de acomodação (T_s) e o máximo sobressinal (M_p) em uma escala percentual quadrática (COP), e três técnicas baseadas na integração dos erros ($ITSE$, ISE e IAE), explicadas no capítulo 4. Neste experimento será utilizado o PSO com a configuração que apresentou o melhor resultado (Tabela 1, item 8). Entretanto, apenas o número de iterações e a quantidade de elementos do enxame foi alterado (Quadro 4).

Partindo do pressuposto que a população inicial de cada teste será distribuída de forma aleatória sobre o espaço de busca, garante-se que os candidatos ($ITSE$, ISE , IAE , COP) não saiam do mesmo ponto. Desta forma serão evidenciadas a velocidade de convergência, a qualidade e a robustez das respostas encontradas pelos candidatos.

Descrição	Valor
População do enxame	20
Número máximo de iterações	30
Coefficiente de inércia inicial (w)	0,9
Coefficiente de inércia final (w)	0,4
Termo Cognitivo (c_1)	2
Termo Social (c_2)	2

Quadro 4 – Parâmetros do PSO

Fonte: Autoria própria.

Ao término das simulações pode-se observar que o melhor resultado (Tabela 2) foi obtido pelo

ITSE, que obteve o menor tempo de acomodação (T_s), embora apresentasse o maior sobressinal (M_p). Isso evidencia um comportamento especialista (que funciona bem apenas no ponto de operação usado no projeto), tendo alguns ganhos elevados, Gaussiana com concavidade extremamente fechada¹ (particularmente no termo derivativo) e, conseqüentemente, a ocorrência *chattering* (trepidação) desse ganho quando próximo ao regime permanente. O *ISE* resultou no segundo melhor resultado. A performance alcançada pelo *IAE* demonstrou maior estabilidade a perturbações, devido à sua característica de produzir respostas mais lentas e com baixas oscilações. Já no caso do *COP*, verifica-se que produziu uma resposta muito parecida com o *IAE*, mas devido à sua característica de ponderação de tempo de acomodação em função do sobressinal resultou em um sobressinal bem pequeno, porém apresentando um *undershoot* considerável (como um sobressinal negativo) e também com uma maior incidência de *chattering*.

Tabela 2 – Comparativo entre técnicas de *fitness* (PSO)

DESCRIÇÃO	<i>ITSE</i>	<i>ISE</i>	<i>IAE</i>	<i>COP</i>
$M_p(\%)$	4,205	3,977	1,85096	1,67569
$T_s (ms)$	0,6038	0,81525	0,98285	0,999025
$T_r (ms)$	0,6644	0,92545	1,18178	1,22503
x	46,0387	8,8565	7,3650	6,9375
y	3,0370	2,4615	2,1562	2,0338
z	8,4961	2,8323	2,8967	2,6613
δ_i	43,9453	71,1466	55,2456	76,4675
δ_d	2,0616e-5	4,4357e-5	6,1169e-4	0,0155
δ_p	11,5679	23,1356	13,3929	13,2621

Fonte: Autoria própria.

Ao analisar as respostas obtidas, apresentadas na Figura 24, verifica-se que todas as técnicas de *fitness* apresentaram resultados satisfatórios quanto às premissas do projeto (saída = 20 V, sobressinal $\leq 5\%$). Entretanto, o candidato escolhido foi o resultado obtido pelo *IAE* devido à sua robustez quanto à variação do ponto de operação, muito comum nas aplicações do conversor Buck. Deve-se salientar que, para esse caso em particular, foi a técnica que apresentou os melhores resultados quando inseriu-se perturbações no sistema.

Na Figura 23 está exposta a evolução temporal do resultado obtido pelo *IAE*.

Portanto, após determinar o melhor conjunto de parâmetros e a melhor forma de avaliar (*fitness*), parte-se para o experimento prático.

6.4 OTIMIZAÇÃO UTILIZANDO PSO

Os resultados obtidos no tópico anterior serão utilizados para o experimento prático no protótipo e na simulação. A parametrização utilizada para o PSO está apresentada no Quadro 4, a evolução

¹ A abertura da curva Gaussiana está relacionada com o parâmetro p onde, quanto mais alto o seu valor, mais fechada se torna a curva.

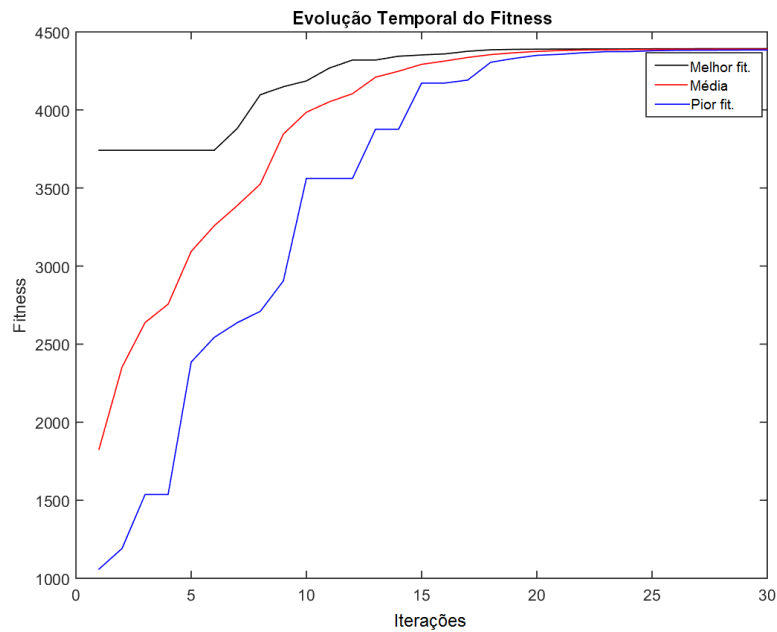


Figura 23 – Evolução temporal do *fitness* (PSO)

Fonte: Autoria própria.




Figura 24 – Comparativo entre as respostas do sistema para diferentes técnicas de *fitness*

Fonte: Autoria própria.

temporal da avaliação do enxame está apresentada na Figura 23, sendo que a trajetória do enxame está apresentada na Figura 25. Ao analisar-se esta trajetória, fica evidente que a convergência de mais de 80% das partículas que compõem o enxame ocorre após 15 iterações.

Ao finalizar o processo de otimização, utilizou-se os parâmetros do Quadro 5 na parametrização do GAPID e do PID linear para o protótipo.

Na Figura 26 é apresentada uma comparação entre o PID linear e o GAPID. Nota-se que na

simulação houve uma melhora significativa ao utilizar o GAPID de 46% sobre o PID linear no quesito tempo de acomodação (T_s) e 31,7% com relação ao sobressinal (M_p). Estes dados estão apresentados na Tabela 3. O ponto mais importante a ser notado aqui é que esta performance é alcançada pelo GAPID com parâmetros vinculados ao PID linear.

Para alcançar essa melhoria, os ganhos adaptativos entram em ação durante a inicialização do transitório, como representado na Figura 27. Esses ganhos induzem a ação de controle (u) que corresponde à saída do controlador GAPID.

Param. PID	Valor	Param. GAPID	Valor
k_p	6,5E-3	x	7,37
k_i	21,9	y	2,16
k_d	6,5E-6	z	2,89
		δ_p	13,4
		δ_i	55,2
		δ_d	6,12E-4

Quadro 5 – Parâmetros de controle otimizados (PSO)

Fonte: Autoria própria.

Tabela 3 – Comparativo de performance do GAPID otimizado com PSO

Parâmetro	PID	GAPID	Desempenho
T_s	1,82 ms	0,983 ms	46%
$M_p(\%)$	2,71%	1,85%	31,7%

Fonte: Autoria própria.

Ao parametrizar o controlador com os valores da Tabela 5 no modelo do DSP Builder mostrado na Figura 18, onde o mesmo foi compilado e embarcado em um FPGA, os resultados tanto para o PID linear quanto para o GAPID replicaram as respostas obtidas na simulação. Isso confirma a ótima fidelidade entre o modelo usado em simulação e o protótipo.

A corrente do indutor e tensão de saída para o PID linear são apresentadas na Figura 28 (a). O valor do tempo de acomodação, tanto para o resultado prático quanto para o experimental, são muito próximos o que valida a modelagem.

O transitório de saída para o GAPID é apresentado na Figura 28 (b). Novamente, o tempo de acomodação, tanto para o resultado prático quanto para o experimental, são semelhantes.

6.5 OTIMIZAÇÃO UTILIZANDO ALGORITMO GENÉTICO

Conforme estudo realizado no Capítulo 5, para que um indivíduo seja apresentado a um processo de evolução seus genes devem ser estruturados combinando suas características. Estas características definirão qual indivíduo de uma população carregará seus genes para a próxima geração.

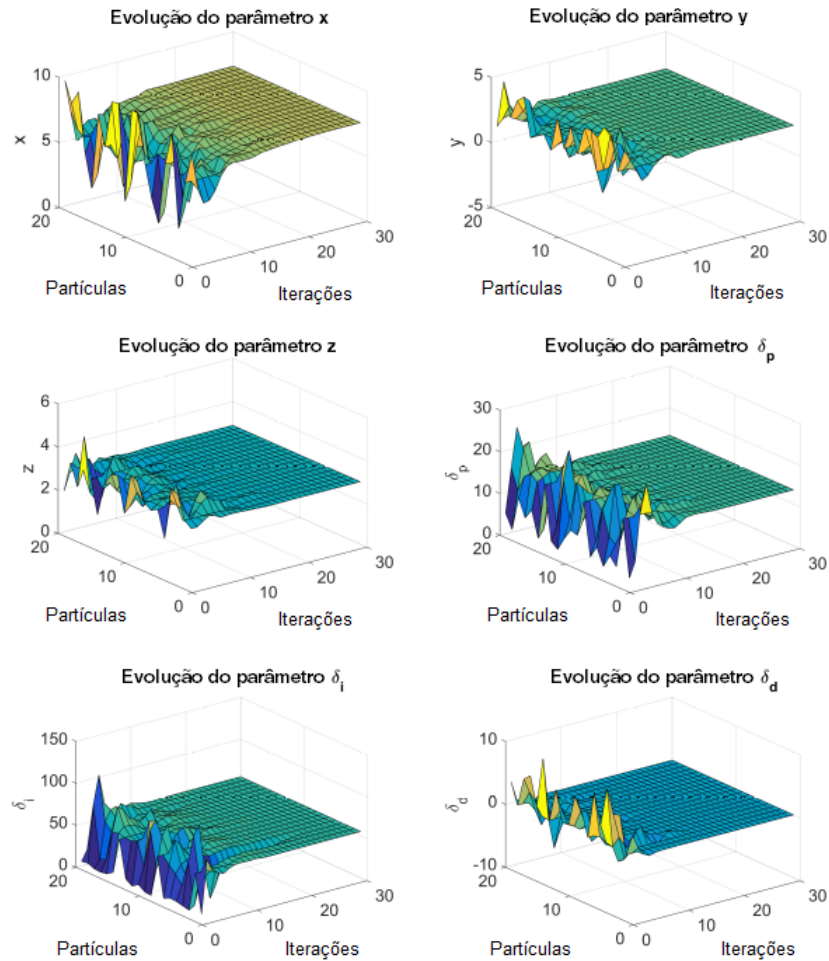


Figura 25 – Evolução dos parâmetros otimizados do PSO.

Fonte: Autoria própria.

Desta forma, a combinação dos seis parâmetros vinculados (x , y , z , δ_i , δ_d , δ_p) do GAPID ao PID linear formam um indivíduo, ou seja, uma possível solução. Na Figura 29 é apresentada a forma dos genes que irá compor a população de possíveis candidatos para a solução do problema.

Após a codificação da população, dimensiona-se o tamanho da população, o número de iterações (gerações), a taxa de acasalamento (*crossover*), a influência do meio no indivíduo (mutação) e expõe a população ao processo de seleção (roleta). No Quadro 6 está apresentada a parametrização do algoritmo genético.

Descrição	Valor
Tamanho da população (N_{ind})	20
Número de iterações	80
Filhos gerados por crossover	10
Regulador de amplitude de mutação (β)	10
Taxa percentual de mutação (%)	10
Delta da busca local	0,01

Quadro 6 – Parâmetros AG




Figura 26 – Resposta ao transitório para o PID linear e o GAPID (PSO)

Fonte: Autoria própria.

Fonte: Autoria própria.

A evolução do processo de avaliação (*COP*) desta população é apresentada na Figura 30.

Após o processo de otimização, o indivíduo que apresentou melhor desempenho está apresentado no Quadro 7 (GAPID).

PID param.	Valor	GAPID Param.	Valor
k_p	6,5E-3	x	6,95
k_i	21,9	y	1,99
k_d	6,5E-6	z	2,58
		δ_p	13,24
		δ_i	76,25
		δ_d	0,01

Quadro 7 – Parâmetros de controle otimizados (AG).

Fonte: Autoria própria.

O resultado da simulação utilizando os parâmetros do Quadro 7 para o GAPID e PID linear é apresentado na Figura 31.

Ao analisarmos o transitório de partida tanto para GAPID quanto para o PID linear, nota-se que houve uma melhora significativa tanto para o tempo de acomodação (T_s) quanto para o máximo sobressinal (M_p). A técnica utilizada para obtenção do tempo de acomodação foi o envelopamento do

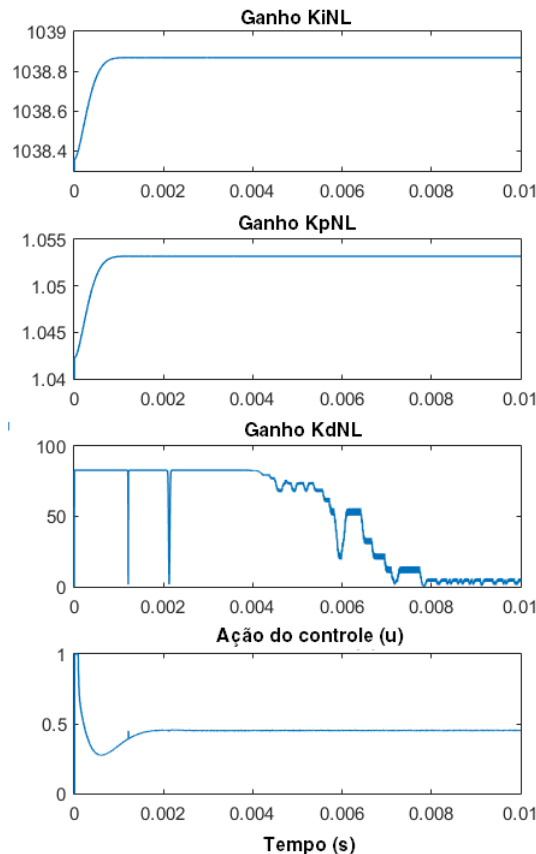


Figura 27 – Variação dos ganhos adaptativos $k_p(\delta)$, $k_i(\delta)$ e $k_d(\delta)$ e o resultado do sinal de controle durante o transitório de partida (PSO)

Fonte: Autoria própria.

transitório descrito no Capítulo 4. Sendo assim, observa-se uma melhora de 52,8% no quesito tempo de acomodação (T_s), e 66,8% com relação ao sobressinal (M_p). Estes dados são apresentados na Tabela 4.

Tabela 4 – Comparativo de performance do GAPID otimizado com AG.

Parâmetros	PID	GAPID	Desempenho
T_s	2,29 ms	1,08 ms	52,8%
$M_p(\%)$	2,71%	0,9%	66,8%

Fonte: Autoria própria.

O transitório dos ganhos adaptativos gerado pelo GAPID e sua respectiva ação de controle é apresentada na Figura 32.

Testes de perturbação por variação de carga foram realizados para testar a robustez do controlador. Como esperado, obteve-se um desempenho similar ao transitório inicial para a variação de carga, como mostrado na Figura 33.

A corrente do indutor e a tensão de saída para o PID linear são apresentadas na Figura 34 (a). Como esperado, o valor do tempo de acomodação, tanto para o resultado prático quanto para a simulação (Figura 31), são muito próximos.

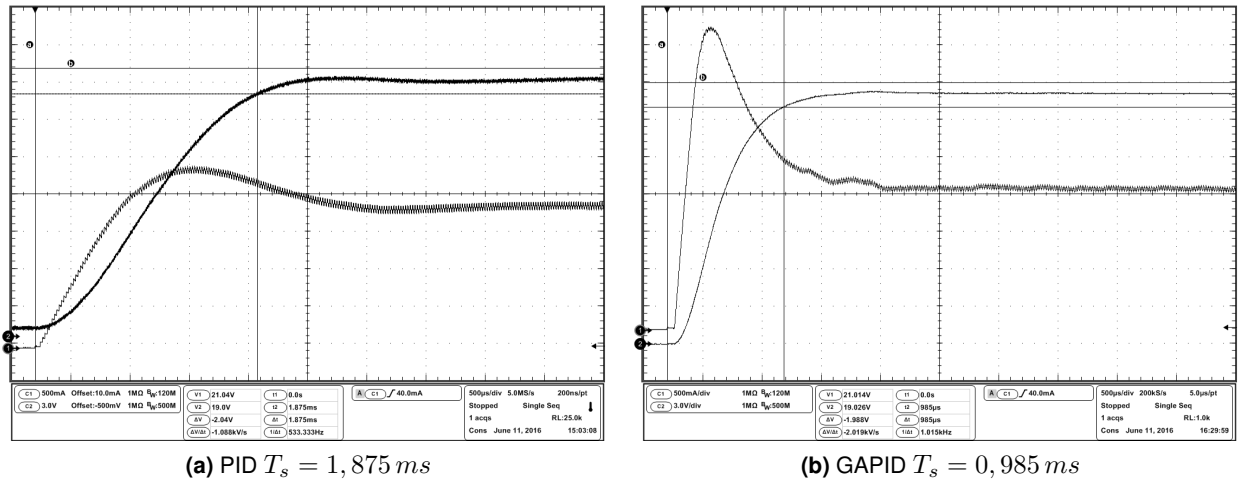


Figura 28 – Resposta do transitório de partida para PID e GAPID no protótipo (PSO)(Ch.1: 500mA/div; Ch.2: 3V/div, Time: 500 μ s/div)

Fonte: Autoria própria.




Figura 29 – Estrutura dos genes para AG

Fonte: Autoria própria.

O transitório de saída para o GAPID é apresentado na Figura 34 (b). A prática e a simulação (Figura 31) também são semelhantes.

6.6 COMPARATIVO ENTRE PSO E AG

Ao iniciar um processo de otimização, o tamanho do espaço de busca e o número de indivíduos distribuídos neste espaço são fatores que ajudam a aumentar a eficiência de um agente otimizador. O tamanho da população pode definir a precisão da otimização, porém populações grandes requerem grande esforço computacional quando utiliza-se algoritmo genético (ou seja, ocorrem vários testes a cada iteração para determinar o grau de adaptação de um indivíduo desta população) ((LEÓN-ALDACO; CALLEJA; ALQUICIRA, 2015; ROEVA; FIDANOVA; PAPRZYCKI, 2013), (PINHO et al., 2013)).

Para realizar um experimento comparativo, utilizou-se o melhor resultado encontrado na Tabela 2, no qual o *ITSE* obteve o melhor resultado como agente avaliador de desempenho. Na Figura 35 é apresentado o transitório de partida para os dois modelos otimizadores e na Tabela 5 é apresentado um comparativo do desempenho que ambos tiveram.

Fica evidente que ambos obtiveram bons resultados. Entretanto, o esforço computacional re-

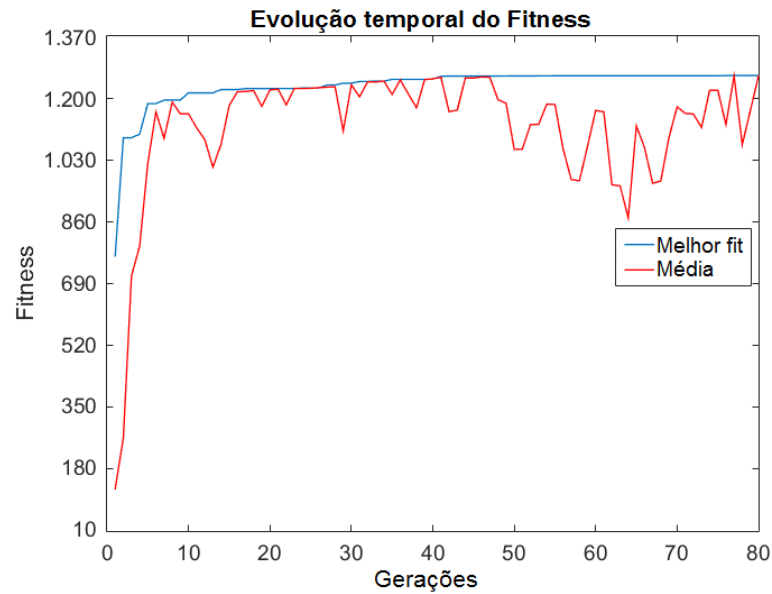


Figura 30 – Evolução temporal do *fitness* (AG): média (em vermelho), o melhor resultado (em azul).

Fonte: Autoria própria.

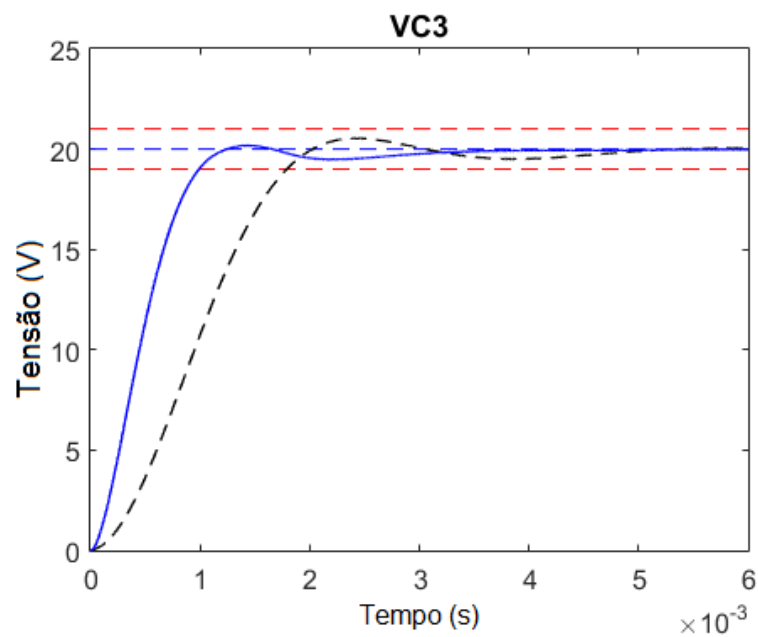


Figura 31 – Resposta do transitório para o PID linear (linha pontilhada cor preto) e GAPID (linha sólida cor azul) (AG).

Fonte: Autoria própria.

querido pelo algoritmo genético é 133% maior que pelo PSO. É importante mencionar que os valores dos parâmetros obtidos pelas técnicas de otimização não são idênticos, que é um indicativo de que a função de custo é multimodal. Este comportamento tende a dificultar o processo de busca.

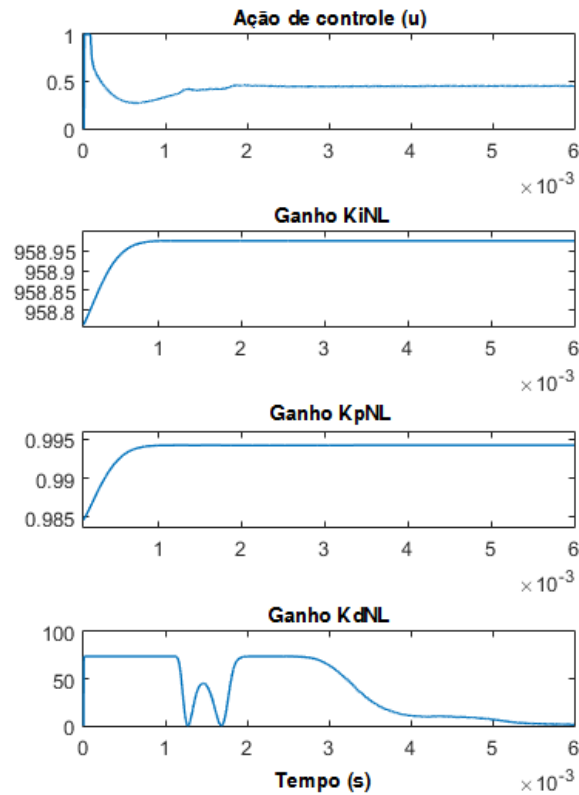


Figura 32 – Variação dos ganhos adaptativos $k_p(\delta)$, $k_i(\delta)$ e $k_d(\delta)$ e o resultado do sinal de controle durante o transitório de partida (AG).

Fonte: Autoria própria.

6.7 ESTUDO DE TENDÊNCIA

Um dos objetivos deste trabalho é desenvolver uma metodologia algébrica para obtenção dos ganhos adaptativos do GAPID, encontrar a proporção apropriada que determine os limites superiores, inferiores e a concavidade da gaussiana representadas por equações matemáticas. É esta proporção que fará com que os ganhos sejam dinâmicos e modulem em função de uma curva gaussiana, aumentando ou diminuindo os ganhos adaptativos em função da amplitude do erro. Esta metodologia algébrica eliminaria o processo de otimização para encontrar essa proporcionalidade dos parâmetros adaptativos.

Portanto, um estudo de variação paramétrica foi efetuado para tentar determinar uma tendência da variação destes parâmetros. Para isso, um vetor de carga distribuído em uma escala logarítmica foi criado para efetuar o processo de otimização. O processo de otimização foi conduzido por duas linhas: parâmetros vinculados e parâmetros livres.

6.7.1 Varredura de Carga com Parâmetros Vinculados

Conforme descrito no Capítulo 3, vincula-se os parâmetros com o intuito de aproveitar os mesmos requisitos de projeto do PID. Desta forma, busca-se correlacionar as duas técnicas para reduzir o impacto que acarretaria na migração do PID para o GAPID.

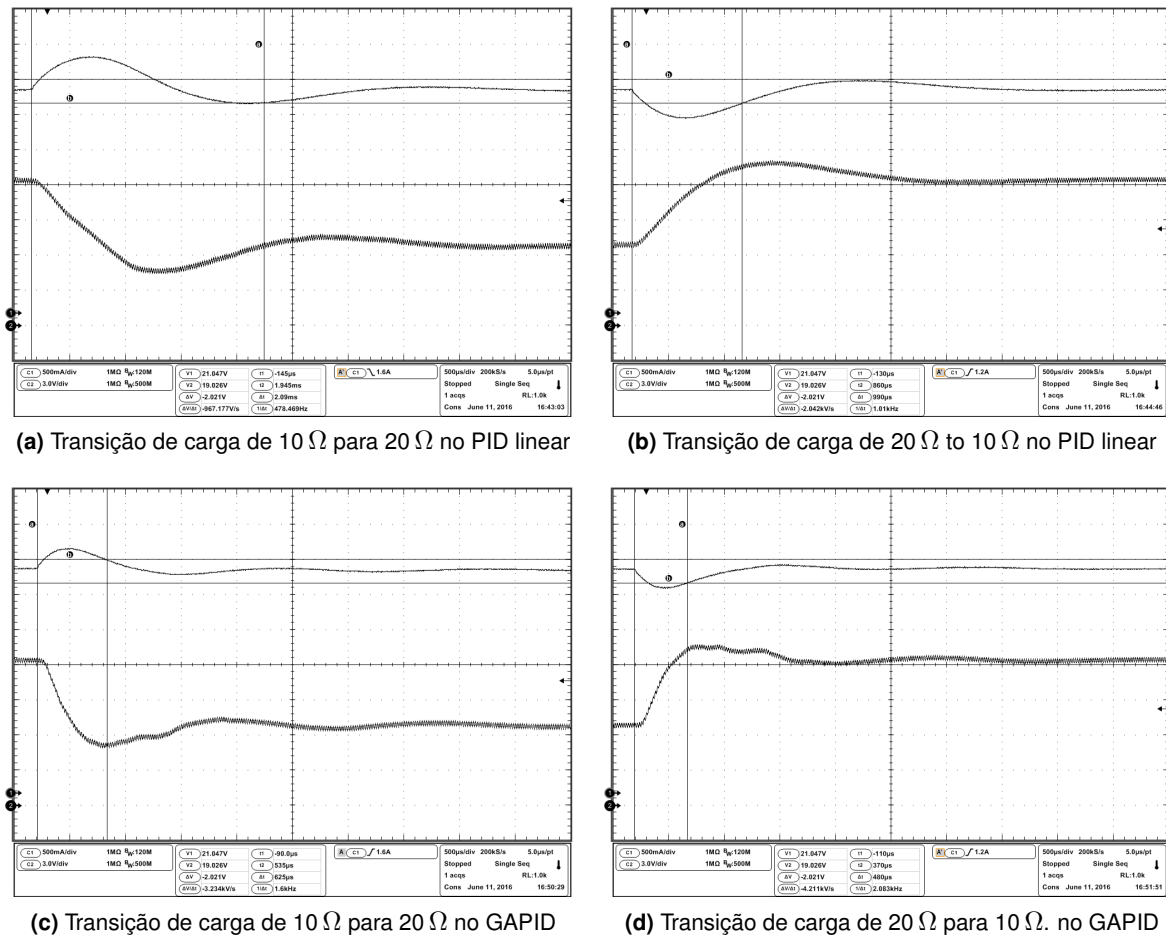


Figura 33 – Comparação entre PID e GAPID quando ocorre uma variação de carga (Ch.1: 500 mA/div; Ch.2: 3 V/div, Time: 500 μ s/div).

Fonte: Autoria própria.

Na Figura 36 é apresentado um estudo de otimização para cada carga variando de 10 a 100 Ω . O transitório de resposta é apresentado na Figura 37.

6.7.2 Varredura de Carga com Parâmetros Livres

Embora os parâmetros vinculados tenham como ponto de partida os ganhos do PID linear, desvincular esses ganhos deixa o processo de otimização livre para encontrar uma solução ótima sem impor qualquer restrição. Entretanto, como já mencionado anteriormente, aplica-se a um sistema que costuma funcionar bem apenas quando trabalha nas condições de operação usadas na otimização, sem incidência de perturbações.

Na Figura 38 é apresentado um estudo de otimização para cada carga variando de 10 a 100 Ω .

Na Figura 39 é apresentada a resposta a variação de carga. Nota-se que, conforme descrito anteriormente, os resultados são próximos e com característica especialista, não sendo possível identificar um padrão de tendência que possa conduzir a uma expressão matemática.

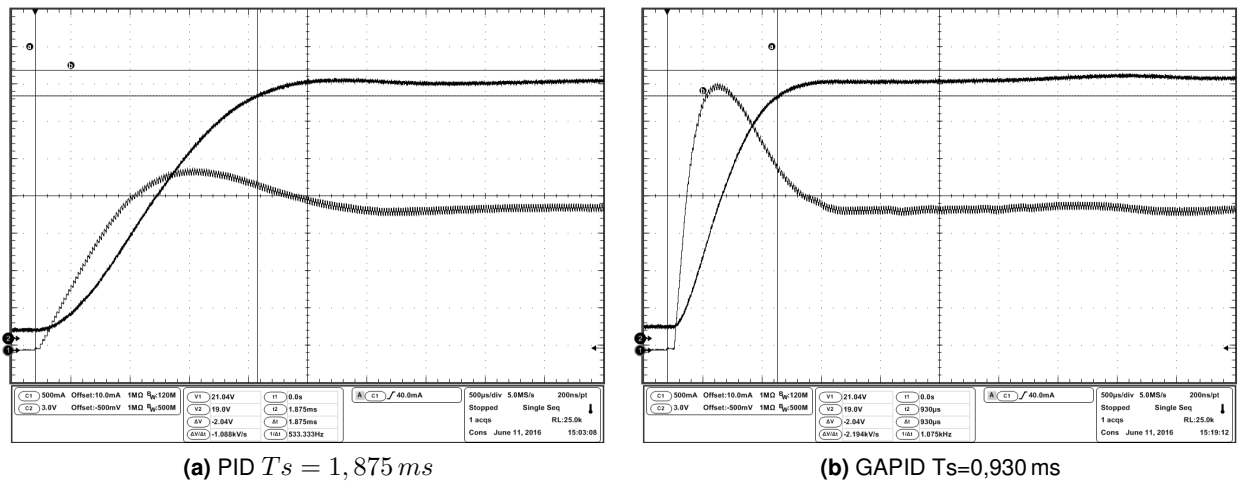


Figura 34 – Resposta do transitório de partida para PID e GAPID no protótipo (AG) (Ch.1: 500 mA/div; Ch.2: 3 V/div, Time: 500 $\mu\text{s}/\text{div}$).




Figura 35 – Comparativo entre PSO e AG utilizando ITSE

Fonte: Autoria própria.

6.7.3 Análise Geral

Analisando os resultados obtidos, tanto para parâmetros vinculados como livres, conclui-se que, perto da solução ótima, existe uma “nuvem” de resultados sub-ótimos, porém com parâmetros bem diferentes. Mesmo que os parâmetros sejam diferentes, podem acabar gerando respostas próximas do “ótimo”. É possível que exista um conjunto de soluções sub-ótimas que permita identificar uma curva de tendência passível de equacionamento matemático. Essa análise acabou ficando fora do escopo deste trabalho, ficando entre os estudos futuros na continuidade da pesquisa.

Tabela 5 – Comparativo entre PSO e AG utilizando ITSE

DESCRIÇÃO	PSO	AG
Tempo de execução(s)	542	1265
Workers (Cluster)	36	36
Gerações/Iteração	30	200
Convergência total	20	65
Avaliação por Geração/Iteração	1	5
M_p (%)	4,205	3,951
T_s (ms)	0,6038	0,6180
T_r (ms)	0,6644	0,688
x	46,0387	25,3232
y	3,0370	3,0390
z	8,4961	5,0311
δ_i	43,9453	65,3527
δ_d	2,0616e-5	6,0958e-5
δ_p	11,5679	13,6890

Fonte: Autoria própria.




Figura 36 – Varredura de carga utilizando PSO com *fitness* IAE para parâmetros vinculados

Fonte: Autoria própria.

6.8 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram realizadas análises da aplicação das propostas de otimização bio-inspiradas: algoritmo genético (AG) e a otimização por enxame de partículas (PSO). Para isso foi necessário realizar um estudo de variação paramétrica. Uma análise detalhada determinou qual a melhor forma

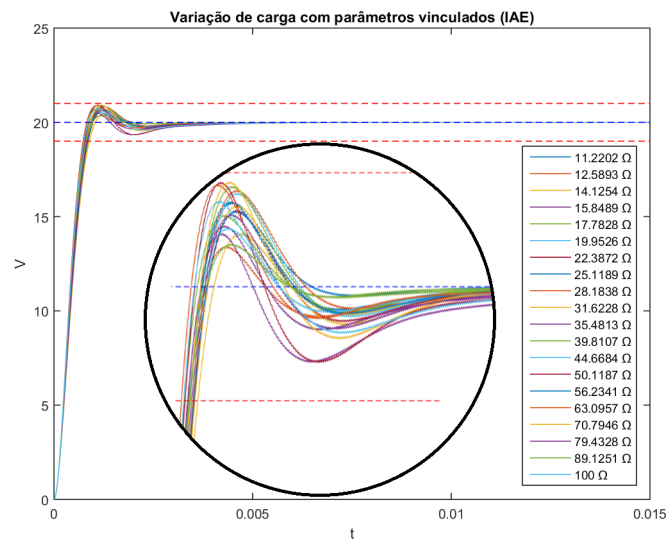


Figura 37 – Resposta do sistema para variação de carga com parâmetros vinculados

Fonte: Autoria própria.

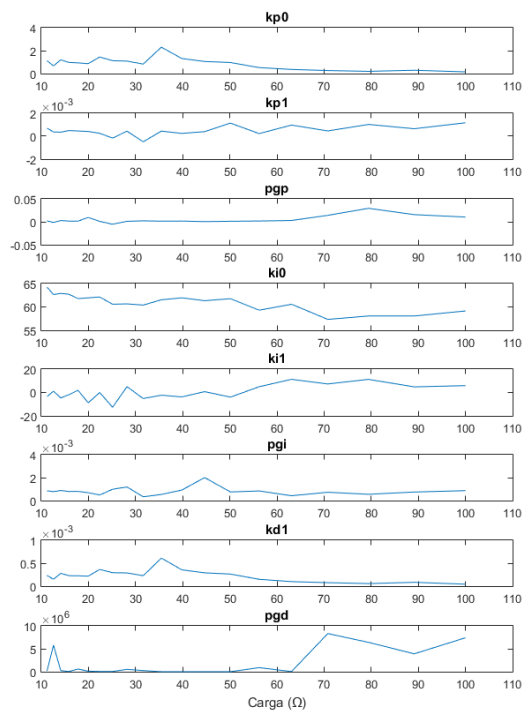


Figura 38 – Varredura de carga utilizando PSO com *fitness* IAE para parâmetros livres

Fonte: Autoria própria.

de avaliar o desempenho (*fitness*) dos resultados, de maneira que o *IAE* foi eleito por apresentar resultados mais estáveis e robustos para as variações de carga. Foi necessário um número elevado de simulações para poder levantar as curvas de desempenho para cada sistema, sendo assim, houve a necessidade de utilizar uma *cluster* composta por 36 *workers*, onde um *script* de programação paralela otimizou o processo de coleta de dados das simulações.

Utilizou-se o PSO como agente principal nas simulações devido sua facilidade de implantação

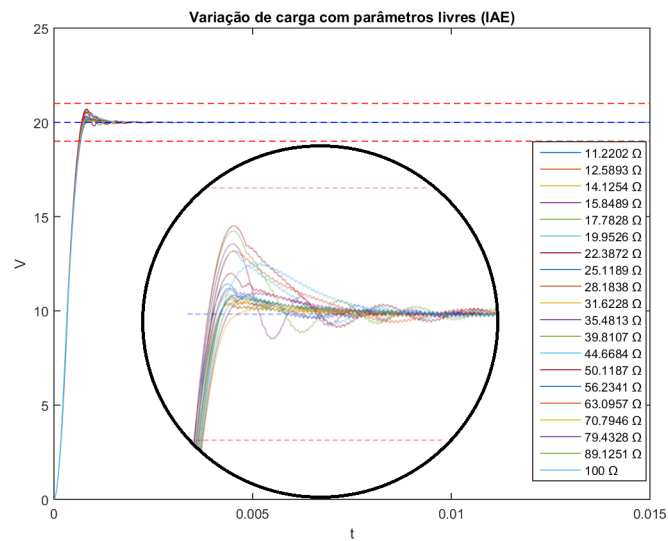


Figura 39 – Resposta do sistema para variação de carga com parâmetros livres

Fonte: Autoria própria.

e velocidade no processo de convergência. Essa característica propiciou um estudo de variação de carga para determinar uma forma algébrica para obtenção dos ganhos do perfil gaussiano, porém devido aos efeitos da combinação paramétrica não foi possível determinar uma tendência, já que se obtêm o mesmo resultado para proporções diferentes dos parâmetros. Foram apresentadas formas de onda dos transitórios do sinal de saída do PID e do GAPID que demonstram a eficácia do controle proposto.

No capítulo seguinte serão apresentadas as considerações finais, a conclusão sobre o trabalho e sugestões de trabalhos futuros.

7 CONCLUSÃO

Neste trabalho foi apresentado um estudo sobre o controlador adaptativo baseado em funções Gaussianas, o GAPID, que tem como alicerce a estrutura de um PID convencional. Porém, ao contrário do que ocorre no último caso, no qual após o projeto finalizado seus ganhos são fixos, o GAPID atua na variação dos ganhos sobre uma curva Gaussiana como função da amplitude do erro. Desta forma, pode-se variar os ganhos adaptativos em um transitório de partida mantendo uma transição suave entre estes.

Para que um estudo comparativo fosse realizado, uma planta de teste foi escolhida para que o controlador fosse embarcado em um FPGA e os testes de controle fossem executados. Sendo assim, o conversor abaixador CC-CC Buck foi eleito devido à sua baixa complexidade e conceitos bem difundidos em várias bibliografias. Desta forma, a dinâmica da planta tornou-se um problema secundário frente às necessidades da implantação do controle.

A principal dificuldade na utilização do GAPID é achar a proporção exata das Gaussianas que regerão a variação desses ganhos, visto que esta curva possui limites superiores e inferiores bem definidos. Ao longo do tempo, muitos autores utilizaram métodos pouco convencionais para encontrar essas proporções e mesmo assim obtiveram êxito em seus estudos. Alguns utilizaram métodos empíricos e outros varredura paramétrica para encontrar essa proporcionalidade. Neste trabalho, utilizou-se duas metaheurísticas de otimização bio-inspiradas bem consolidadas no meio científico e acadêmico: o Algoritmo genético (AG) e a otimização por enxame de partículas (PSO).

Além de eleger duas ferramentas de otimização, outro ponto extremamente importante é a forma de avaliar o desempenho. É este agente avaliador que informará ao AG e o PSO se o resultado dever ser considerado como uma solução adequada ou não. Sendo assim, após intensa pesquisa bibliográfica definiu-se os possíveis candidatos para esta tarefa: *IAE* (Integral Absoluta dos Erros), *ISE* (Integral Quadrática dos Erros), *ITSE* (Integração do tempo com erro quadrático) e uma função quadrática que pondera o tempo de acomodação em função do percentual quadrático do máximo sobressinal (*COP*). Entre todos os candidatos, o *ITSE* obteve os melhores resultados gerais em termos do tempo de acomodação e máximo sobressinal.

Entretanto, por razões avaliativas de desempenho optou-se por utilizar na pesquisa o *IAE*, pois embora ele tende a produzir uma resposta mais lenta do que os sistemas ideais (*ISE* e *ITSE*), favorece a obtenção de resultados com menores oscilações. Para testar o *COP* como métrica de avaliação, houve a necessidade de estender as análises, pois para avaliar o desempenho do transitório de partida duas informações devem ser consideradas: o tempo de acomodação e o máximo sobressinal. Entretanto, por se tratar de uma função descontínua, a aquisição do tempo de acomodação deu-se através do envelopamento do transitório, discutido no Capítulo 4. Assim, quando a envoltória tocar no limite estipulado em projeto obtém-se o tempo de acomodação.

Após um estudo paramétrico do PSO, visando definir parâmetros de configuração para aumentar o grau de aproveitamento da ferramenta de otimização, optou-se por manter o termo cognitivo fixo em 2 (dois) e variar o coeficiente de inércia de forma decrescente (0,9 a 0,4) a cada iteração.

Para dinamizar a coleta de dados proveniente das simulações, um *script* de programação paralela foi desenvolvido e executado em uma *cluster* com 36 *workers*. Após vários testes o PSO foi eleito como ferramenta base para toda a pesquisa devido a facilidade de implantação e a baixa exigência de recursos computacionais.

Todos os resultados encontrados pelo PSO foram confrontados com o AG. Ambos tiveram resultados muito próximos, embora o PSO tenha sido 133% mais eficaz em termos computacionais.

Outro estudo efetuado foi a variação paramétrica da carga usando na otimização Gaussianas com parâmetros livres e vinculados. Este teve como principal objetivo evidenciar uma tendência das soluções como função da variação de carga. Porém devido aos efeitos da combinação paramétrica não foi possível determinar uma tendência, visto que outros resultados sub-ótimos mas com proporções diferentes dos parâmetros.

Os resultados obtidos, tanto na simulação quanto no protótipo, foram semelhantes. Isso se deve ao cuidado com a modelagem e o rigor nos procedimentos de projeto, implementados da mesma forma no modelo e no protótipo.

CONTRIBUIÇÕES DO TRABALHO

Este trabalho traz como principais contribuições:

- Apresentar proposta de controle adaptativo tendo como base a estrutura do PID tradicional, dinamizando a variação dos ganhos baseados na curva Gaussiana;
- Expor a dificuldade para encontrar uma solução algébrica que determine os ganhos adaptativos vinculados ao PID tradicional;
- Propor uma metodologia de projeto através de metaheurísticas de otimização bio-inspiradas;
- Demonstrar a eficácia do GAPID comparado ao PID tradicional;
- Apresentar a eficácia do PSO para obtenção dos ganhos adaptativos;
- Demonstrar que os resultados coletados da simulação correspondem com os resultados coletados no protótipo.

CONTINUIDADE DO TRABALHO

Como continuidade desses estudos, pretende-se:

- Realizar uma variação paramétrica mais completa, envolvendo a carga, o indutor e o capacitor, buscando encontrar uma forma algébrica para determinação dos ganhos adaptativos;
- Estudar o uso das ferramentas de otimização para outros conversores e aplicações;

ARTIGOS ACEITOS PARA PUBLICAÇÃO EM CONGRESSOS

Os resultados desse trabalho geraram artigos submetidos e aceitos para os seguintes congressos:

- PUCHTA, E. D. P.; LUCAS, R.; KASTER, M. S.; SIQUEIRA, H. V. **Application of a Nonlinear Gaussian Adaptive PID with PSO Optimization to a Buck Converter**. XXI Congresso Brasileiro de Automática (CBA 2016). Vitória, ES, Brazil, 2016.
- PUCHTA, E. D. P.; LUCAS, R.; KASTER, M. S.; SIQUEIRA, H. V. **Gaussian Adaptive PID Control Optimized via Genetic Algorithm Applied to a Step-down DC-DC Converter**. Industry Applications (INDUSCON), 2016 12th IEEE/IAS International Conference on, Curitiba, 2016.

ARTIGO SUBMETIDO PARA PUBLICAÇÃO EM REVISTA

- PUCHTA, E. D. P.; KASTER, M. S.; SIQUEIRA, H. V. Optimization tools based on meta-heuristics for performance enhancement in nonlinear control. IEEE Transactions on Cybernetics, 2016.

REFERÊNCIAS

- ABDULAZIZ, M. et al. A linearization technique for differential otas. **IEEE Transactions on Circuits and Systems II: Express Briefs**, PP, n. 99, p. 1–1, 2016. ISSN 1549-7747.
- ABENSUR, E. O. Meta-heurísticas aplicadas ao desenvolvimento de novos fundos de investimentos. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 29, p. 459–472. ISBN 978-85-64619-10-4.
- ALEXANDROV, A. G. Frequencial adaptive pid-controller. In: **Control Conference (ECC), 1999 European**. [S.l.: s.n.], 1999. p. 2638–2643.
- ALISSON, E. **Sistema aumenta a produtividade de processos industriais**. 2013. Disponível em: <<http://exame.abril.com.br/tecnologia/sistema-aumenta-a-produtividade-de-processos-industriais/>>.
- ANSARI, A. Q.; IBRAHEEM; KATIYAR, S. Application of ant colony algorithm for calculation and analysis of performance indices for adaptive control system. In: **Computational Intelligence on Power, Energy and Controls with their impact on Humanity (CIPECH), 2014 Innovative Applications of**. [S.l.: s.n.], 2014. p. 466–471.
- ARMENTANO, V. A.; BRANCHINI, R. M. Uma introdução à busca tabu. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 3, p. 33–52. ISBN 978-85-64619-10-4.
- ARMENTANO, V. A. et al. Busca tabu: Implementação de estratégias de memórias de curto e longo prazo. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 23, p. 367–384. ISBN 978-85-64619-10-4.
- ASTROM K. J.; HAGGLUND, T. **PID Controllers: Theory, Design, and Tuning, 2nd Edition**. [S.l.]: Research Triangle Park, 1995. ISBN 1-55617-516-7.
- AZEVEDO, A. T.; RIBEIRO, C. M. Um estudo comparativo de algoritmos genéticos e *Beam Search* para o problema de alocação de células de telefonia celular. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 24, p. 385–400. ISBN 978-85-64619-10-4.
- BARBOZA, A. O. **Simulação e Técnicas da Computação Evolucionária Aplicadas a Problemas de Programação Linear Inteira Mista**. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná (UTFPR), CPGEI, Curitiba, PR, 2005.
- BHATTACHARJYA, R. K. **Introduction To Genetic Algorithms**. 2013. Disponível em: <<http://www.iitg.ernet.in/rkbc/CE602/CE602/Genetic%20Algorithms.pdf>>.
- BOCCATO, L. et al. Um estudo da aplicação de algoritmos bio-inspirados ao problema de estimação de direção de chegada. **Revista Controle Automação**, v. 20, p. p. 609–624, 2009.
- BONOMO, D.; LAUF, A. P.; YAMPOLSKIY, R. A crossword puzzle generator using genetic algorithms with wisdom of artificial crowds. In: **Computer Games: AI, Animation, Mobile, Multimedia, Educational and Serious Games (CGAMES), 2015**. [S.l.: s.n.], 2015. p. 44–49.

BOONPENG, S.; JEATRAKUL, P. Enhance the performance of neural networks for stock market prediction: An analytical study. In: **Digital Information Management (ICDIM), 2014 Ninth International Conference on**. [S.l.: s.n.], 2014. p. 1–6.

DARWIN, C. **The Origin of Species by Means of Natural Selection**. [S.l.]: John Murray, Albemarle Street, 1859.

DO, T. D. et al. Suboptimal control scheme design for interior permanent-magnet synchronous motors: An sdr-based approach. **IEEE Transactions on Power Electronics**, v. 29, n. 6, p. 3020–3031, June 2014. ISSN 0885-8993.

EBERHART, R. C.; SHI, Y. Comparing inertia weights and constriction factors in particle swarm optimization. In: **Evolutionary Computation, 2000. Proceedings of the 2000 Congress on**. [S.l.: s.n.], 2000. v. 1, p. 84–88 vol.1.

FUJIMOTO, T.; TABUCHI, F.; YOKOYAMA, T. A design of fpga based hardware controller for dc-dc converter using sdr approach. In: **Power Electronics Conference (IPEC), 2010 International**. [S.l.: s.n.], 2010. p. 1001–1005.

GLOVER, F. W. . K. O. **Handbook of Metaheuristics**. [S.l.]: Kluwer Academic Publishers, 2002.

GOLDBERG, D. **Genetic Algorithms in Search, Optimization and Machine Learning**. [S.l.]: ADDISON-WESLEY PUBLISHING COMPANY, INC., 1989.

HOLLAND, J. **Adaptation in Natural and Artificial Systems**. [S.l.]: The University of Michigan Press, Ann Arbor, 1975.

IBRAHIM, M. A. A.; RAAHEMIFAR, K. Beating the zero-sum game using ga to optimize technical financial market indicators. In: **2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)**. [S.l.: s.n.], 2016. p. 1–6.

ÇIMEN, T. Systematic and effective design of nonlinear feedback controllers via the state-dependent riccati equation (SDRE) method. **Annual Reviews in Control**, v. 34, n. 1, p. 32–51, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.arcontrol.2010.03.001>>.

ISAYED M. B.; HAWWA, M. A. A nonlinear pid control scheme for hard disk drive servosystems. In: **Proceedings of the Mediterranean Conference on Control and Automation**. Athens, Greece: [s.n.], 2007.

JAGATHEESAN, K.; ANAND, B. Dynamic performance of multi-area hydro thermal power systems with integral controller considering various performance indices methods. In: **Emerging Trends in Science, Engineering and Technology (INCOSSET), 2012 International Conference on**. [S.l.: s.n.], 2012. p. 474–478.

JIMENEZ-URIBE, . et al. Comparative study of a pid and pd control bounded by hyperbolic tangent function in robot 3 dof. In: **Mechatronics, Electronics and Automotive Engineering (ICMEAE), 2015 International Conference on**. [S.l.: s.n.], 2015. p. 199–204.

KASTER, M. S. et al. Análise do uso de controle pid não linear aplicado a conversor buck. In: **Proceedings of the X Conferência Brasileira de Dinâmica, Controle e Aplicações**. [S.l.: s.n.], 2011.

- KASTER, M. S. et al. Performance analysis of an adaptive gaussian nonlinear pid control applied to a step-down cc-cc converter. In: **Proceedings of the 24th International Symposium on Industrial Electronics (ISIE 2015)**. [S.l.: s.n.], 2015. p. 1022.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Neural Networks, 1995. Proceedings., IEEE International Conference on**. [S.l.: s.n.], 1995. v. 4, p. 1942–1948 vol.4.
- KHAMIS, A. Wind energy conversion systems nonlinear tracking using finite-horizon sdre. In: **2015 IEEE Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)**. [S.l.: s.n.], 2015. p. 681–685.
- KHEIRMAND, M. et al. Intelligent modern controller on dc-dc converter. In: **TENCON 2008 - 2008 IEEE Region 10 Conference**. [S.l.: s.n.], 2008. p. 1–5. ISSN 2159-3442.
- KISHNANI, M.; PAREEK, S.; GUPTA, R. Optimal tuning of pid controller by cuckoo search via. In: **Advances in Engineering and Technology Research (ICAETR), 2014 International Conference on**. [S.l.: s.n.], 2014. p. 1–5. ISSN 2347-9337.
- KRAUSE, J.; CORDEIRO, J. A.; LOPES, H. S. Comparação de métodos de computação evolucionária para o problema da mochila multidimensional. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 6, p. 87–98. ISBN 978-85-64619-10-4.
- KRIPKA, R. M. L.; KRIPKA, M. *Simulated Annealing* aplicado ao problema de alocação de salas com deslocamentos mínimos. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 20, p. 325–338. ISBN 978-85-64619-10-4.
- KUMAR, P.; NEMA, S.; PADHY, P. K. Pid controller for nonlinear system using cuckoo optimization. In: **Control, Instrumentation, Communication and Computational Technologies (ICICCT), 2014 International Conference on**. [S.l.: s.n.], 2014. p. 711–716.
- LEE, H.; LEE, J.; LEE, J. Hill climbing algorithm of an inverted pendulum. In: **Computational Intelligence in Robotics and Automation (CIRA), 2009 IEEE International Symposium on**. [S.l.: s.n.], 2009. p. 574–579.
- LEÓN-ALDACO, S. E. D.; CALLEJA, H.; ALQUICIRA, J. A. Metaheuristic optimization methods applied to power converters: A review. **IEEE Transactions on Power Electronics**, v. 30, n. 12, p. 6791–6803, Dec 2015. ISSN 0885-8993.
- LEUNG, F. H. F.; TAM, P. K. S.; LI, C. K. An improved lqr-based controller for switching dc-dc converters. **IEEE Transactions on Industrial Electronics**, v. 40, n. 5, p. 521–528, Oct 1993. ISSN 0278-0046.
- LUCAS, R. **Análise e Implementação de Estruturas de Controle em Dispositivo FPGA Aplicadas a um Conversor Buck**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná (UTFPR), PPGEE, Ponta Grossa, PR, 2015.
- MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. [S.l.]: Springer, 1992.
- MISTRY, K. et al. A micro-ga embedded pso feature selection approach to intelligent facial emotion recognition. **IEEE Transactions on Cybernetics**, PP, n. 99, p. 1–14, 2016. ISSN 2168-2267.

- MOGHADAM, M. F.; GHAREHPETIAN, G. B.; ABYANEH, H. A. Optimized regulation of dc voltage in interline power flow controller (ipfc) using genetic algorithm. In: **Power Engineering and Optimization Conference (PEOCO), 2010 4th International**. [S.l.: s.n.], 2010. p. 117–121.
- NALLUSAMY, S.; VELAYUTHAM, D.; GOVINDARAJAN, U. Design and implementation of a linear quadratic regulator controlled active power conditioner for effective source utilisation and voltage regulation in low-power wind energy conversion systems. **IET Power Electronics**, v. 8, n. 11, p. 2145–2155, 2015. ISSN 1755-4535.
- NASCIMENTO, F. A. F. do et al. Meta-heurística otimização por enxame de partículas aplicada ao planejamento florestal. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 22, p. 355–366. ISBN 978-85-64619-10-4.
- NÉIA, S. S. et al. Roteamento de veículos utilizando otimização por colônia de formigas e algoritmo genético. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 14, p. 219–236. ISBN 978-85-64619-10-4.
- NUCHKRUA, T.; LEEPHAKPREEDA, T. Control of dc-link by adaptive pid control for dc/dc boost converter. In: **Automatic Control Conference (CACS), 2013 CACS International**. [S.l.: s.n.], 2013. p. 423–426.
- OGATA, K. **Modern Control Engineering**. 5th. ed. [S.l.]: Pearson, 2009. 912 p.
- PEDROSO, M. D. et al. Performance comparison between nonlinear and linear controllers with weighted adaptive control applied to a buck converter using poles placement design. In: **Industrial Electronics (ISIE), 2013 IEEE International Symposium on**. [S.l.: s.n.], 2013. p. 1–6. ISSN 2163-5137.
- PINHO, A. F. de et al. Algoritmos genéticos: Fundamentos e aplicações. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 2, p. 21–32. ISBN 978-85-64619-10-4.
- PUSPITASARI, N. F.; FATTA, H. A.; WIBOWO, F. W. Implementation of greedy and simulated annealing algorithms for wireless access point placement. In: **2015 3rd International Conference on Artificial Intelligence, Modelling and Simulation (AIMS)**. [S.l.: s.n.], 2015. p. 165–170.
- RAFAEL, S.; SANTOS, P. J.; PIRES, J. An adaptive pid speed controller for an 8/6 switched reluctance machine. In: **Power Engineering, Energy and Electrical Drives (POWERENG), 2013 Fourth International Conference on**. [S.l.: s.n.], 2013. p. 1147–1150. ISSN 2155-5516.
- RAMPAZZO, P. C. B.; YAMAKAMI, A.; FRANÇA, F. O. de. Algoritmo genético e evolução diferencial para a resolução do problema de planejamento hidrelétrico. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 19, p. 307–324. ISBN 978-85-64619-10-4.
- ROEVA, O.; FIDANOVA, S.; PAPRZYCKI, M. Influence of the population size on the genetic algorithm performance in case of cultivation process modelling. In: **Computer Science and Information Systems (FedCSIS), 2013 Federated Conference on**. [S.l.: s.n.], 2013. p. 371–376.

ROMERO, N. G.; TRIGUEROS, J. A. Control of a fleet of vehicles using computer vision, cellular automaton and genetic trained behaviour. In: **2006 IEEE International Conference on Mechatronics**. [S.l.: s.n.], 2006. p. 483–487.

SAHU, P. K.; SHAW, P.; MAITY, S. Fixed-frequency sliding mode control for power quality improvement of a grid-connected inverter. In: **2015 Annual IEEE India Conference (INDICON)**. [S.l.: s.n.], 2015. p. 1–6.

SANTOS, L. A.; KASTER, M. S. Adaptive proportional-integrator controller applied in a single-phase parallel active power filter. In: **2015 IEEE 24th International Symposium on Industrial Electronics (ISIE)**. [S.l.: s.n.], 2015. p. 355–360. ISSN 2163-5137.

SANTOS, L. A. dos; KASTER, M. dos S.; SILVA, S. A. O. d. Applying a nonlinear pid in a singlephase pll control. In: **2012 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)**. [S.l.: s.n.], 2012. p. 1–4.

SARINANA, A.; BACHA, S.; BORNARD, G. On nonlinear observers applied to three-phase voltage source converters. In: **Power Electronics Specialists Conference, 2000. PESC 00. 2000 IEEE 31st Annual**. [S.l.: s.n.], 2000. v. 3, p. 1419–1424 vol.3. ISSN 0275-9306.

SARVI, M.; SALIMIAN, M. R. Optimization of specific harmonics in multilevel converters by ga amp; pso. In: **Universities Power Engineering Conference (UPEC), 2010 45th International**. [S.l.: s.n.], 2010. p. 1–4.

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

SILVA, G. F. da et al. Solução de problemas de planejamento florestal com variáveis inteiras com o emprego de meta-heurísticas. In: LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. 1. ed. Curitiba, PR: Omnipax, 2013. cap. 21, p. 339–354. ISBN 978-85-64619-10-4.

SINGH, B.; KUMAR, V. A real time application of model reference adaptive pid controller for magnetic levitation system. In: **2015 IEEE Power, Communication and Information Technology Conference (PCITC)**. [S.l.: s.n.], 2015. p. 583–588.

SIQUEIRA, H. **Previsão de Séries de Vazões com Redes Neurais Artificiais e Modelos Lineares Ajustados por Algoritmos Bio-Inspirados**. Dissertação (Mestrado) — Universidade Estadual de Campinas (UNICAMP-SP) Faculdade de Engenharia Elétrica e Computação Departamento de Engenharia de Sistemas, 2009.

SOUZA, V. C. **A ORIGEM DO CÁLCULO DIFERENCIAL E INTEGRAL**. Dissertação (Mestrado) — Universidade Candido Mendes (UCAM-RJ) PRÓ-REITORIA DE PLANEJAMENTO E DESENVOLVIMENTO, 2001.

SUPENO, H.; RUSMIN, P. H.; HINDERSAH, H. Optimum scheduling system for container truck based on genetic algorithm on spin(simulator pelabuhan indonesia). In: **2015 4th International Conference on Interactive Digital Media (ICIDM)**. [S.l.: s.n.], 2015. p. 1–6.

TUTORIALSPPOINT.COM. **Genetic Algorithms - Parent Selection**. 2016. Disponível em: <https://www.tutorialspoint.com/genetic_algorithms/genetic_algorithms_parent_selection.htm>.

UDDIN, S.; KRAUSE, O.; MARTIN, D. A linearization technique to estimate operational constraints states by pseudo inverse matrix. In: **2016 Australasian Universities Power Engineering Conference (AUPEC)**. [S.l.: s.n.], 2016. p. 1–6.

WANG, J. et al. Hybrid forecasting model-based data mining and genetic algorithm-adaptive particle swarm optimisation: a case study of wind speed time series. **IET Renewable Power Generation**, v. 10, n. 3, p. 287–298, 2016. ISSN 1752-1416.

WANG, R.; ZHANG, Z. Fuzzy adaptive pid hybrid control for airborne platform mounted on muav. In: **2016 IEEE Information Technology, Networking, Electronic and Automation Control Conference**. [S.l.: s.n.], 2016. p. 737–741.

WEI, L. et al. Algorithm research and real-time simulation of neural network sliding mode position control. In: **2013 25th Chinese Control and Decision Conference (CCDC)**. [S.l.: s.n.], 2013. p. 1904–1907. ISSN 1948-9439.

WENGE, L. et al. Research on pid control parameters tuning based on election-survey optimization algorithm. In: **Computing, Control and Industrial Engineering (CCIE), 2010 International Conference on**. [S.l.: s.n.], 2010. v. 2, p. 323–326.

XIAO, J. Z. et al. Robot force position control without impact: Method and application. In: **2010 International Conference on Machine Learning and Cybernetics**. [S.l.: s.n.], 2010. v. 2, p. 965–968. ISSN 2160-133X.

YANG, X. S.; DEB, S. Cuckoo search via lévy flights. In: **Nature Biologically Inspired Computing, 2009. NaBIC 2009. World Congress on**. [S.l.: s.n.], 2009. p. 210–214.