

**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

Jeydson Lopes da Silva

**CONTROLE EFICIENTE COM FERRAMENTAS
DE INTELIGÊNCIA ARTIFICIAL EM UM
SISTEMA DE EXAUSTÃO**

Recife
2017

Jeydson Lopes da Silva

**CONTROLE EFICIENTE COM FERRAMENTAS
DE INTELIGÊNCIA ARTIFICIAL EM UM
SISTEMA DE EXAUSTÃO**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como parte dos requisitos para obtenção do grau de Mestre em Engenharia Elétrica. Área de Concentração: Processamento de Energia.

Orientador: Ronaldo Ribeiro Barbosa
de Aquino, *D.Sc.*

Coorientador: Otoni Nóbrega Neto,
D.Sc.

Recife
2017

Catálogo na fonte
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

S586c Silva, Jeydson Lopes da.
Controle eficiente com ferramentas de inteligência artificial em um sistema de
exaustão / Jeydson Lopes da Silva. - 2017.
104 folhas, il.

Orientador: Ronaldo Ribeiro Barbosa de Aquino, D.Sc.
Coorientador: Otoni Nóbrega Neto, D.Sc.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação em Engenharia Elétrica, 2017.
Inclui Referências.

1. Engenharia Elétrica. 2. Controlador PID. 3. Sintonia. 4. Inteligência artificial.
5. Otimização por enxame de partículas. 6. Eficiência energética. I. Aquino,
Ronaldo Ribeiro Barbosa de (Orientador). II. Nóbrega Neto, Otoni (Coorientador).
III. Título.

UFPE

621.3 CDD (22. ed.) BCTG/2017-132



Universidade Federal de Pernambuco

Pós-Graduação em Engenharia Elétrica

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

JEYDSON LOPES DA SILVA

TÍTULO

**“CONTROLE EFICIENTE COM FERRAMENTAS DE INTELIGÊNCIA
ARTIFICIAL EM UM SISTEMA DE EXAUSTÃO”**

A comissão examinadora composta pelos professores: RONALDO RIBEIRO BARBOSA DE AQUINO, DEE/UFPE; OTONI NÓBREGA NETO, DEE/UFPE, FRANCISCO DE ASSIS DOS SANTOS NEVES, DEE/UFPE e ALCIDES CODECEIRA NETO, DEE/UPE, sob a presidência do primeiro, consideram o candidato **JEYDSON LOPES DA SILVA APROVADO.**

Recife, 20 de fevereiro de 2017.

MARCELO CABRAL CAVALCANTI

Coordenador do PPGEE

**RONALDO RIBEIRO BARBOSA DE
AQUINO**

Orientador e Membro Titular Interno

ALCIDES CODECEIRA NETO

Membro Titular Externo

OTONI NÓBREGA NETO

Coorientador e Membro Titular Interno

FRANCISCO DE ASSIS DOS SANTOS NEVES

Membro Titular Interno

AGRADECIMENTOS

Em primeiro plano a Deus, por todas as oportunidades vivenciadas até agora nesta vida, Seu eterno amor e misericórdia para comigo e minha família, permitindo superar todos desafios de diários. À minha mãe Maria, pelo grande amor dedicado, cuidado e afeição, dando-me toda a educação e carinho que tanto precisava em minha vida. Ao meu pai Jaime e o meu irmão Jefferson por todos os ensinamentos, compreensão e incentivos necessários. À minha amada esposa Julyane, por ser uma companheira maravilhosa em todos os sentidos, seu grande amor e carinho me incentivam diariamente, seu exemplo de fidelidade e integridade é algo que me fortalece sempre. Em especial ao Prof. Dr. Ronaldo Aquino pela grande orientação, dedicação, atenção e real preocupação que foram elementos chaves, não só para a realização deste trabalho, mas sim para um amadurecimento pessoal e profissional. A todos professores do mestrado, ao Prof. Dr. Otoni, que sempre apoiou e contribuiu fortemente com a pesquisa. À FACEPE, por todo apoio financeiro ao longo do tempo do mestrado, tornado essa conquista possível. Aos companheiros do LEEQE: Davidson, Renato e Daniel, pelo apoio, incentivo e amizade. De uma forma geral, a todos que de alguma forma contribuíram para a realização deste trabalho.

RESUMO

A energia elétrica é considerada como um dos principais insumos do setor industrial; sua disponibilidade, qualidade e custo são diretamente ligados à capacidade competitiva deste setor. Com o aumento dos custos da eletricidade e da emissão de gases causadores do efeito estufa, ações voltadas para o uso eficiente deste insumo tornam-se cada vez mais atrativas. Uma parte muito importante da área de controle e automação dos processos industriais é a sintonia dos controladores PID, uma vez que os processos, dentre outras coisas, dependem dos seus controladores, e estes para serem produtivos precisam estar bem sintonizados. O presente trabalho descreve uma maneira de sintonizar desses tipos de controladores baseada em inteligência artificial utilizando uma técnica de otimização evolutiva, conhecida como Otimização por Enxame de Partícula (PSO), técnica eficiente na otimização de funções com vários mínimos locais, funcionando desta forma como uma alternativa às diversas formas de sintonizações clássicas existentes. O objetivo deste trabalho é o de demonstrar o ganho em desempenho no controlador, tanto na parte energética como na ação de controle, proporcionado pela sintonia do controlador através do PSO. Uma parte importante da metodologia deste trabalho é a possibilidade da implementação direta no sistema real dos parâmetros sintonizados do controlador, encontrados por meio da otimização por PSO via simulação computacional; para isso, foi necessária a modelagem do sistema de forma digital, a qual permitiu reproduzir os efeitos da dinâmica do processo real. A implementação real foi feita por meio do protótipo de um sistema de exaustão industrial, o qual é todo controlado por um controlador lógico programável (CLP), localizado no Laboratório de Sistemas Motrizes da Universidade Federal de Pernambuco, a partir do qual foi realizada a coleta de dados experimentais para a análise do desempenho do sistema quando do uso deste tipo de sintonia do controlador.

Palavras-chave: Controlador PID. Sintonia. Inteligência artificial. Otimização por enxame de partículas. Eficiência energética.

ABSTRACT

Electricity is considered as one of the main inputs of the industrial sector; its availability, quality and cost are directly related to the competitive capacity of this sector. With rising costs of electricity and the emission of greenhouse gases, actions aimed at the efficient use of this input become increasingly attractive. A very important part of the area of control and automation of industrial processes is the tuning of the parameters of the PID controllers, since the processes, among other things, depend on their controllers, and these to be productive must be well tuned. The present work describes a way of tuning these types of controllers based on artificial intelligence using an evolutionary optimization technique, known as Particle Swarm Optimization (PSO), an efficient technique for optimizing functions with several local minimums, working in this way as a different form of classical tuning. The objective of this work is to demonstrate the gain in performance in the controller, both in the energy part and in the control action, provided by the controller tuning through the PSO. An important part of the methodology of this work is the possibility of directly implementing in the real system the tuned parameters of the controller, found by means of PSO optimization through computational simulation; for this it was necessary to model the system in digital form, which allowed to reproduce the effects of the actual process dynamics. The actual implementation was done through the prototype of an industrial exhaust system, which is all controlled by means of a PLC, located in the Laboratory of Motor Systems of the Federal University of Pernambuco, from which the collection of experimental data for the analysis of the performance of the system when using this type of controller tuning.

Keywords: PID controller. Tuning. Artificial intelligence. Particle swarm optimization. Energy Efficiency.

LISTA DE ILUSTRAÇÕES

Figura 1 – Principais Políticas de Eficiência Energética no Brasil - 1984 a 2011	16
Figura 2 – Oportunidades MEE na ventilação industrial	20
Figura 3 – Estimativa de Penetração e Economia das MEE na ventilação industrial	20
Figura 4 – Bancada do Exaustor Presente no LAMOTRIZ	22
Figura 5 – Supervisório da Bancada do Exaustor no LAMOTRIZ em WinCC [®]	23
Figura 6 – Hierarquia do Sistema de Controle e Comunicação Presentes na Bancada	24
Figura 7 – Configuração da Rede de Comunicação da Bancada	25
Figura 8 – Malha Fechada de um Controle de Processo	26
Figura 9 – Execuções das Operações A/D e D/A em um Controlador Digital	31
Figura 10 – Sistema Anti-Windup para um Controlador PI	33
Figura 11 – Resposta do Processo de Primeira Ordem em Malha Aberta	34
Figura 12 – Resposta do Processo de Primeira Ordem em Malha Aberta	35
Figura 13 – Método do Relé em Malha Fechada	38
Figura 14 – Saída do Processo com o Método do Relé	38
Figura 15 – Áreas Relacionadas com a Inteligência Artificial.	42
Figura 16 – Regiões de Busca na Otimização.	43
Figura 17 – Busca de Soluções por Métodos Heurísticos.	47
Figura 18 – Fases Iterativas de uma Metaheurística.	48
Figura 19 – Caminhos das Metaheurísticas: (a) População ; (b) Trajetórias	49
Figura 20 – Classificação das Metaheurísticas	50
Figura 21 – Avaliação das Metaheurísticas para Diferentes Tipos de Problemas	51
Figura 22 – Capacidade da Inteligência de Enxame	52
Figura 23 – Estratégia de Movimentação das Partículas no PSO	53
Figura 24 – Voo coordenado de um bando de pássaros	54
Figura 25 – Fluxograma do Algoritmo PSO	56
Figura 26 – Metodologia Aplicada à Sintonização do Controlador por meio de IA	59
Figura 27 – Processo de Identificação de Sistemas	60
Figura 28 – Resposta do processo de primeira ordem em malha aberta	61
Figura 29 – Curva de Resposta da Vazão do Sistema em Malha Aberta devido à Aplicação de um Degrau de 41 Hz.	62
Figura 30 – Tangente no Ponto Máximo de Inflexão da Curva da Vazão	62
Figura 31 – Comparação entre Diferentes Métodos de Identificação de Sistemas para um Degrau de 41 Hz.	64
Figura 32 – Planta do Processo com Controle Contínuo.	65
Figura 33 – Planta do Processo com Controle Digital.	65
Figura 34 – Equivalência do Processo Contínuo-Digital em uma Malha de Controle.	66

Figura 35 – Processo Zero-Order-Hold.	67
Figura 36 – Equivalência entre $H(s)$ e $H_{zoh}(z)$	67
Figura 37 – Diagrama de Blocos do Controlador Standard PID Control Siemens [®]	69
Figura 38 – Bloco PID Discreto da Biblioteca SIMULINK MATLAB [®]	70
Figura 39 – Malha de Controle em SIMULINK [®] Representando o Protótipo do Exaustor no LEEQE	71
Figura 40 – Parâmetros da resposta padrão a um degrau unitário de um sistema em malha fechada	73
Figura 41 – Espaço das soluções da Função Objetivo J da Sintonia PI	78
Figura 42 – Sintonia PI Ziegler Nichols Simulação x Real.	80
Figura 43 – Sintonia PI CHR Servo Simulação x Real.	81
Figura 44 – Sintonia PI CHR Regulatório Simulação x Real.	82
Figura 45 – Sintonia PI CHR 20% de Sobressinal Servo Simulação x Real.	83
Figura 46 – Sintonia PI Cohen e Coon Simulação x Real.	84
Figura 47 – Deslocamento das Partículas Durante as Iterações.	86
Figura 48 – Evolução dos Valores das Partículas Durante as Iterações.	87
Figura 49 – Minimização da Função Objetivo por PSO.	87
Figura 50 – Deslocamento das Partículas Durante as Iterações.	88
Figura 51 – Evolução dos Valores das Partículas Durante as Iterações.	89
Figura 52 – Minimização da Função Objetivo por PSO.	89
Figura 53 – Deslocamento das Partículas Durante as Iterações.	90
Figura 54 – Evolução dos Valores das Partículas Durante as Iterações.	91
Figura 55 – Minimização da Função Objetivo por PSO.	91
Figura 56 – Sintonia do Controlador PI por PSO Simulação x Real.	92
Figura 57 – Minimização da Função Objetivo pela Metaheurística. PSO.	93
Figura 58 – Comportamento da Potência Ativa pelas diferentes Sintonias do Controlador PI	94

LISTA DE TABELAS

Tabela 1 – Controladores PID Comerciais	30
Tabela 2 – Parâmetros para Sintonia PID Ziegler-Nichols	35
Tabela 3 – Parâmetros para Sintonia PID Ziegler-Nichols (Oscilação Crítica)	36
Tabela 4 – Parâmetros para Sintonia PID por CHR sem Sobrevalor (Servo)	36
Tabela 5 – Parâmetros para Sintonia PID por CHR sem Sobrevalor (Regulatório)	37
Tabela 6 – Parâmetros para Sintonia PID por CHR com 20% de Sobrevalor (Servo)	37
Tabela 7 – Parâmetros para Sintonia PID por Cohen e Coon	37
Tabela 8 – Índices de Desempenho Baseados na Integral do Erro no Modelo Discreto.	74
Tabela 9 – Índices de Qualidade do Controlador PI Ziegler-Nichols (Simulação).	79
Tabela 10 – Índices de Qualidade do Controlador PI CHR Servo (Simulação).	80
Tabela 11 – Índices de Qualidade do Controlador PI CHR Regulatório (Simulação).	81
Tabela 12 – Índices de Qualidade do Controlador PI CHR 20% de Sobressinal Servo (Simulação).	82
Tabela 13 – Índices de Qualidade do Controlador PI Cohen e Coon (Simulação).	83
Tabela 14 – Resultado da Otimização por PSO com 20 Partículas.	86
Tabela 15 – Resultado da Otimização por PSO com 30 Partículas.	88
Tabela 16 – Resultado da Otimização por PSO com 50 Partículas.	90
Tabela 17 – Índices de Qualidade do Controlador PI Otimizado por PSO (Simulação).	92
Tabela 18 – Quadro Comparativo das Diversas Sintonias do Controlador PI.	94
Tabela 19 – Consumo Acumulado de Energia (W.h) das Sintonias (8 min)	95

LISTA DE ABREVIATURAS E SIGLAS

AS	<i>Automation Station</i>
AVAs	Acionadores de Velocidade Ajustáveis
BP	Banda Proporcional
CHR	Chien, Hrones e Reswick
CLP	Controlador Lógico Programável
CSV	<i>Comma Separated Value</i>
EE	Eficiência Energética
EPE	Empresa de Pesquisa Energética
FRM	<i>Foward Rectangular Method</i>
Gbest	<i>Global Best</i>
IA	Inteligência Artificial
IHM	Interface-Homem-Máquina
LAMOTRIZ	Laboratório de Sistemas Motrizes da UFPE
Lbest	<i>Local Best</i>
LEEQE	Laboratório de Eficiência Energética e Qualidade de Energia
MEE	Medidas de Eficiência Energética
MME	Ministério de Minas e Energia
Pbest	<i>Position Best</i>
PID	Proporcional-Integral-Derivativo
PI	Proporcional-Integral
PNE	Plano Nacional de Energia
PROCEL	Programa Nacional de Conservação de Energia Elétrica
OS	<i>Operation Station</i>
PSO	<i>Particle Swarm Optimization</i>
ZOH	<i>Zero-Order-Hold</i>

LISTA DE SÍMBOLOS

α	Constante do filtro derivativo
θ	Atraso de transporte da função de transferência
τ	Constante de tempo na função de transferência
$c_{1,2}$	Constantes de buscas local e global do PSO
c2d	Comando <i>continuous to digital</i> em MATLAB
$e(t)$	Valor do erro na malha de controle
FB41	Função <i>Standard PID Control</i> no CLP
$G_c(s)$	Função de transferência do controlador em frequência
$G_p(s)$	Função de transferência do processo em frequência
$H(s)$	Função de transferência em frequência
$H_{zoh}(z)$	Função de transferência em tempo discreto por <i>Zero-Order-Hold</i>
IAE	<i>Integrated Absolute Error</i>
ITAE	<i>Integrated Time Absolute Error</i>
ISE	<i>Integrated Squared Error</i>
ITSE	<i>Integrated Time Squared Error</i>
J	Função objetivo (<i>fitness</i>)
K	Ganho em malha aberta
K_d	Ganho derivativo
K_i	Ganho integral
K_p	Ganho proporcional
K_u	Ganho crítico em malha fechada
M_p	<i>Overshoot</i>
$r_{1,2}$	Constantes randômicas da partícula no PSO
$r(t)$	Valor de referência (<i>setpoint</i>)

T_a	Variável de otimização do PSO utilizada na simulação
T_d	Tempo derivativo
T_i	Tempo proporcional
T_s	Tempo de amostragem
T_u	Tempo crítico
t_s	<i>Settling Time</i>
t_r	<i>Rise Time</i>
$u(t)$	Sinal de controle
v	Velocidade da partícula no PSO
x	Posição da partícula no PSO
$y(t)$	Variável de saída do processo
ω_u	Frequência angular crítica
w	Peso inercial do PSO

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Eficiência Energética no Setor Industrial	15
1.2	O Problema da Sintonia	16
1.3	Objetivos da Pesquisa	18
1.4	Organização Textual	19
2	CONTROLADORES PID EM SISTEMAS MOTRIZES	20
2.1	Apresentação da Bancada do Exaustor	21
2.1.1	<i>Operação da Bancada</i>	21
2.1.2	<i>Descrição da Bancada do Exaustor</i>	22
2.1.3	<i>Sistema Supervisório da Bancada</i>	23
2.1.4	<i>Esquema de Comunicação Presente na Bancada</i>	24
2.1.5	<i>Possíveis Experimentos na Bancada</i>	25
2.2	O Controlador PID	26
2.2.1	<i>Controlador Proporcional (P)</i>	27
2.2.2	<i>Controlador Proporcional e Integral (PI)</i>	27
2.2.3	<i>Controlador Proporcional e Derivativo (PD)</i>	28
2.2.4	<i>Controlador Proporcional, Integral e Derivativo (PID)</i>	28
2.2.5	<i>Controladores PID Comerciais</i>	29
2.2.6	<i>Controlador PID Digital</i>	30
2.2.7	<i>Sistema Anti-Windup</i>	32
2.3	Métodos para Sintonizar os Controladores PID	32
2.3.1	<i>Métodos de Ziegler-Nichols</i>	33
2.3.2	<i>Métodos de CHR</i>	36
2.3.3	<i>Método de Cohen e Coon</i>	37
2.3.4	<i>Método de Auto-Sintonia com Relé Realimentado</i>	38
2.3.5	<i>Limitações dos Métodos Tradicionais de Sintonia</i>	39
3	IA COMO FERRAMENTA PARA A OTIMIZAÇÃO	41
3.1	Inteligência Artificial e Sistemas Especialistas	41
3.2	A Otimização	42
3.2.1	<i>Forma Geral do Problema de Otimização</i>	43
3.2.2	<i>Otimização Global e Local</i>	45
3.2.3	<i>Métodos Exatos e Heurísticos</i>	45
3.3	Heurísticas e Metaheurísticas	46
3.3.1	<i>Classificação e Propriedades</i>	47

3.4	Otimização por Enxame de Partículas - PSO	51
3.4.1	<i>A Inteligência de Enxame</i>	51
3.4.2	<i>O PSO</i>	53
3.4.3	<i>Origem e Etimologia do PSO</i>	54
3.4.4	<i>O Algoritmo PSO</i>	55
3.4.5	<i>Controle dos Parâmetros no PSO</i>	57
3.4.6	<i>Aplicações PSO</i>	57
4	SINTONIZAÇÃO APLICADA	59
4.1	Modelo do Processo	60
4.1.1	<i>Identificação do Modelo do Processo</i>	60
4.1.2	<i>Modelo Digital</i>	64
4.2	Sistema de Controle	68
4.2.1	<i>Estrutura do Controlador</i>	68
4.2.2	<i>Malha de Controle</i>	70
4.3	Avaliação do Desempenho da Malha de Controle	71
4.3.1	<i>Requisitos de Desempenho Baseados na Resposta ao Degrau</i>	72
4.3.2	<i>Requisitos Baseados na Integral do Erro</i>	73
4.4	Aplicação da Técnica de Otimização a Sintonia PI	75
4.4.1	<i>PSO Adaptado ao Problema de Sintonia PI</i>	75
5	RESULTADOS E DISCUSSÕES	78
5.1	Região do Espaço de Busca da Solução	78
5.2	Análise das Sintonias Clássicas do Controlador PI	79
5.3	Análise da Metaheurística PSO na Sintonia PI	85
5.4	Análise Energética das Sintonias do Controlador PI	94
6	CONCLUSÃO E TRABALHOS FUTUROS	96
	REFERÊNCIAS	98

1 Introdução

1.1 Eficiência Energética no Setor Industrial

A grande relevância da energia elétrica como um insumo para os processos produtivos é amplamente conhecida. No entanto, sabe-se que parte relevante da energia entregue às unidades produtivas é desperdiçada ou usada com baixa eficiência. E portanto, reconhecida a necessidade de se melhorar o rendimento dos processos energéticos, principalmente no âmbito industrial, como têm indicado os estudos empreendidos nesse sentido, com vantagens econômicas e ambientais (PROCEL, 2006).

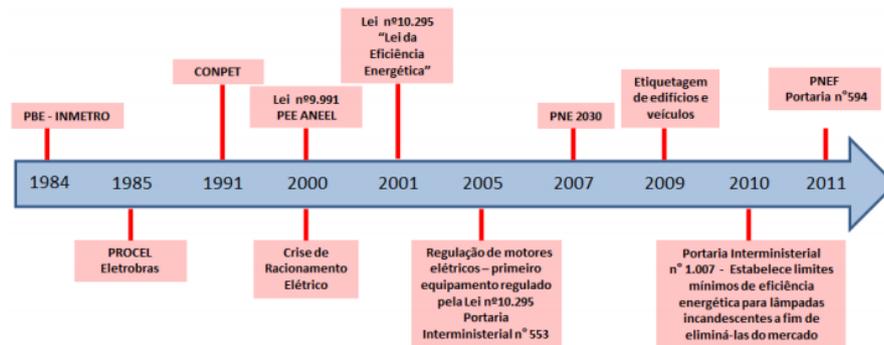
O setor industrial corresponde a uma boa parcela de toda a energia elétrica consumida no país. Mesmo com a constatação da queda no consumo por parte deste setor nos últimos anos; este ainda representa uma parte significativa com cerca de 36,3% do total consumido no Brasil em 2015 de acordo com a Empresa de Pesquisa Energética (EPE, 2016). Certamente, este setor também se mostra como o de maior potencial na conservação de energia elétrica.

A respeito da Eficiência Energética (EE), uma maior preocupação nesse sentido surgiu com os chamados choques do petróleo (1973-1974 e 1979-1981), no qual o preço do barril de petróleo foi aumentado excessivamente pelo cartel formado pelos países exportadores. Além disso, a expansão acentuada do consumo de energia experimentada pela população, embora tenha refletido o aquecimento econômico e a melhoria da qualidade de vida, trouxe aspectos negativos; um desses aspectos é a possibilidade do esgotamento dos recursos utilizados para a produção de energia. Estes fatos trouxeram uma grande percepção a respeito da escassez dos recursos energéticos, abrindo espaço para uma série de ações voltadas à conservação energética e maior eficiência no uso dos seus derivados. Nesta mesma época, começou uma corrida para a diversificação da matriz energética visando uma maior segurança no atendimento à demanda de energia (MME, 2011).

No Brasil, no que concerne à energia elétrica, o estímulo ao uso eficiente tem sido aplicado de forma sistemática desde a década de 80, destacando-se o ano de 1985, quando o Ministério de Minas e Energia (MME) criou o Programa Nacional de Conservação De Energia Elétrica (Procel), de âmbito nacional e coordenado pela Eletrobrás.

Economizar energia elétrica traz inúmeras vantagens, como o adiamento da necessidade de construção de novas usinas geradoras e sistemas associados, liberando recursos para outras áreas e contribuindo para a preservação do meio ambiente. A Figura 1 apresenta um resumo das ações criadas no Brasil para o incentivo a conservação de energia.

Figura 1 – Principais Políticas de Eficiência Energética no Brasil - 1984 a 2011



Fonte: adaptado de EPE (2016).

A abordagem desta dissertação a respeito da EE se concentrará na melhoria obtida nos processos industriais a partir de uma melhor regulação nos controladores PID, amplamente utilizados na maioria dos processos industriais; a este processo de regulação é dado o nome de sintonia.

1.2 O Problema da Sintonia

A sintonia de controladores é um problema persistente na área de controle e automação. Desde a abordagem inicial deste tema até os dias atuais; não chegou-se ainda a uma solução definitiva, sendo um tema constantemente abordado em diversos trabalhos na área de Engenharia de Controle.

A questão acerca do problema de sintonia de controladores engloba a grande maioria dessas estruturas. Mesmo assim, apesar de comportar as diversas estruturas de controladores, os estudos a cerca da sintonia se concentram, em sua quase absoluta maioria, nos controladores PID. No entanto, não há metodologia mais amplamente defendida como solução, ou até mesmo uma formulação canônica e genérica a esse respeito (GODOY, 2012).

De acordo com *Rubaai* (RUBAAI, 2008), aproximadamente 90% das malhas de controle encontradas em processos industriais operavam com controladores PI/PID atingindo uma larga faixa de aplicações. A maioria das malhas são do tipo PI, pois a ação derivativa não é usada com frequência. Segundo Ogata (OGATA, 2003), a utilidade dos controladores PID está na sua aplicabilidade geral à maioria dos sistemas de controle. Além disso, como causas majoritárias que dificultam a aplicação de outras estruturas de controle, mesmo podendo ser mais adequadas a certos tipos de problemas, destacam-se as dificuldades inerentes à sua implementação e

principalmente à sintonização destes.

Em relação aos controladores PID, é de prática comum a sintonia por meio de cálculos diretos, os quais são baseados nas características dinâmicas do processo. Essas técnicas de sintonia, ainda que raramente sejam ótimas ao processo, são consideradas melhores que as chamadas sintonias pré-fixadas, as quais geralmente procuram pré-estabelecer alguma propriedade e são de maior facilidade de implementação; no entanto, não garantem robustez satisfatória ou bom desempenho ao sistema. Além disso, uma grande parte dos fabricantes de controladores comerciais disponibilizam, juntamente com o equipamento, softwares de *Auto-Tuning*, conhecidos como sintonizadores automáticos. A partir da realização da identificação do processo por meio destes softwares, estes se utilizam dos parâmetros identificados para aplicação da sintonia que envolve a técnica do cálculo direto. Este método acaba por aumentar a facilidade da sintonia de controladores, porém dificilmente este procedimento irá gerar um sistema com desempenho ótimo (GODOY, 2012).

Por fim, e não menos comum, é a técnica da sintonia manual de controladores, comumente conhecida no meio técnico por sintonia através de tentativa e erro. Esta técnica, de forma geral, realiza um procedimento iterativo, variando-se os parâmetros do controlador em busca do ponto ótimo de controle. Em geral, isso ocorre a partir de uma sintonia inicial obtida por meio da pré-sintonia ou mesmo o cálculo direto, obtendo-se uma resposta do processo considerada boa, e a partir deste ponto utiliza-se a tentativa e erro com o intuito de melhorar (refinar) a ação de controle.

São diversos os trabalhos a respeito da sintonia de controladores PID, contudo, o mais conhecido é o artigo de Ziegler e Nichols (ZIEGLER; NICHOLS, 1942), onde os autores propuseram, a partir de uma modelagem simples do processo, uma metodologia para a obtenção dos parâmetros utilizados na sintonia dos controladores PID. Além de ser o primeiro a propor um método de sintonia pela técnica do cálculo direto, o artigo de Ziegler e Nichols iniciou uma abordagem que separa a escolha da estrutura do controlador da sintonia de seus parâmetros, permitindo desta forma que fosse possível utilizar estruturas padrão em diferentes processos, ajustando-as ao processo controlado, fato esse que contribuiu para o controlador PID ser amplamente utilizado na maioria dos processos de controle (FIRMINO, 2014).

Após a metodologia proposta por Ziegler e Nichols, vários outros trabalhos surgiram como novos métodos de sintonia para os controladores PID, dentre os quais destacam-se os mais clássicos: CHR (CHIEN; HRONES; RESWICK, 1952), Cohen Coon (COHEN; COON, 1953), Aström e Hägglund (ASTROM; HAGGLUND, 1984); e Skogestad (SKOGESTAD, 2004).

Nas últimas décadas, surgiram novas técnicas baseadas em otimização para a sintonização ótima de controladores, as quais na maioria foram fundamentadas em critérios clássicos de desempenho. Autores como Liu e Daley (LIU; DALEY, 2001), Sung, Lee e Park (SUNG; LEE; PARK, 2002) e Oi *et al.* (OI *et al.*, 2008) são alguns dos quais abordaram a otimização como um meio para a melhoria na qualidade da sintonização em relação aos métodos de sintonia

existentes.

1.3 Objetivos da Pesquisa

A correta inserção de um controlador devidamente sintonizado em uma malha de um processo industrial garante vantagens competitivas como o aumento de estabilidade no processo, aumento da margem de ganho, diminuição dos custos energéticos necessários ao controle do processo, aumento da velocidade da resposta do sistema, maximização das taxas de produção e minimização dos impactos ambientais, entre outros.

Os métodos convencionais de sintonia dos controladores PID podem ser muito úteis para a determinação dos parâmetros de sintonização iniciais; contudo, na esmagadora maioria das situações, um ajuste fino por meio de tentativa e erro é requerido para a obtenção de uma condição mais próxima do ideal de funcionamento, acarretando em diversos contratempos operacionais, além da perda expressiva de tempo e produtividade.

Uma forma alternativa de abordar a questão da sintonia de controladores é por meio da utilização das técnicas de otimização. Neste preâmbulo, as tradicionais técnicas de busca, baseadas no gradiente, são utilizadas como ferramentas de otimização, todavia, em muitas situações, o cálculo do gradiente não é obtido facilmente, tornando desta maneira mais difícil a implementação da otimização. Por essa razão, os métodos de busca probabilística têm sido desenvolvidos na tentativa de promover soluções que não dependam de conhecimento prévio sobre o espaço de busca (MEDEIROS, 2005).

A capacidade computacional disponível hoje em dia, permite cada vez mais que as técnicas de otimização desenvolvidas na área de inteligência artificial ganhem espaço na resolução de diversos problemas da engenharia. A otimização por sistemas neurofuzzy (PASSINO; YURKOVICH, 1997) e algoritmos de otimização evolucionários como algoritmos genéticos (GOLDBERG, 1989) são exemplos dessas aplicações.

O presente trabalho explora a capacidade da inteligência artificial, como ferramenta de otimização para a sintonia de controladores PID, especificamente o uso do algoritmo de otimização por enxame de partículas, *Particle Swarm Optimization* (PSO) (SHI; EBERHART, 1998), demonstrando a viabilidade da utilização desse algoritmo na busca de soluções em espaços de busca complexos com vários mínimos locais, como os problemas encontrados nos processos de sintonia de controladores.

A otimização por enxame de partículas é baseada no paradigma da interação entre as partículas de uma população (enxame) as quais buscam um ótimo global da solução do problema. Tal algoritmo não exige necessariamente um conhecimento prévio sobre o espaço de busca nem sobre a existência de limites ou derivadas da função objetivo e ou funções de restrição, bastando para sua aplicação a existência de uma função de avaliação dos indivíduos da população

(FIRMINO, 2014).

Neste trabalho pretende-se demonstrar um controle eficiente de um processo industrial, especificamente um sistema de exaustão, no qual a partir da utilização de ferramentas da inteligência artificial busca-se melhorar a qualidade de sintonia do controlador PID, apresentando a melhora no controle do processo em relação às sintonias comumente praticadas, bem como a demonstração do aumento da eficiência energética obtida por meio dessa aplicação no âmbito da indústria.

1.4 Organização Textual

- **Capítulo 2** - Realiza inicialmente uma abordagem a respeito da eficiência energética em sistemas de ventilação industrial; após isso, apresenta uma visão geral dos equipamentos e sistemas utilizados na bancada de experimentos realizados neste trabalho, além da comunicação presente no LAMOTRIZ e as principais características do sistema supervisorio. Realiza um estudo sobre o controlador PID, abordando suas principais características, sua formulação em modelo digital e por último trata de alguns métodos clássicos de sua sintonia.
- **Capítulo 3** - Apresenta o conceito de inteligência artificial como uma ferramenta útil na otimização de problemas. Realiza um estudo acerca das heurísticas e metaheurísticas, expondo as principais classificações e propriedades, além de suas vantagens e desvantagens. Logo depois, aborda o conceito da otimização por enxame de partículas (PSO), definindo os principais pontos deste algoritmo, a sua origem e algumas aplicações.
- **Capítulo 4** - Propõe a metodologia utilizada neste trabalho, abordando todo o processo de identificação e modelagem do sistema, o esquema de controle aplicado e a maneira de avaliação utilizada para qualificar o desempenho da sintonia proposta. Por fim, apresenta o PSO adaptado ao problema de sintonia, inclusive o passo-a-passo de funcionamento do algoritmo em questão.
- **Capítulo 5** - Apresenta os resultados para a sintonia do controlador PI obtidos pela aplicação da metodologia proposta nesta dissertação. Inicialmente é feita uma apresentação da região do espaço de busca da função objetivo do problema. Logo após, analisa-se o desempenho de algumas sintonias clássicas, apresentando resultados gráficos comparativos do sistema real e simulado, além de tabelas com valores de desempenho dessas sintonias. Por último, assim como apresentado nas sintonias clássicas, apresenta-se os resultados dos ganhos adquiridos a partir da aplicação do PSO na sintonização do controlador PI.
- **Capítulo 6** - Apresenta as conclusões dos resultados obtidos na dissertação, realiza comentários sobre a utilização do PSO na sintonia do controlador PI, e por último propõe trabalhos futuros correlacionados à área.

2 Controladores PID em Sistemas Motrizes

De acordo com o Plano Nacional de Energia (PNE) (EPE, 2007), a ventilação é uma das operações mais realizadas no setor industrial, tendo como objetivo efetuar o controle de determinados parâmetros, tais como a temperatura, a distribuição do ar, a umidade, e eliminar agentes contaminantes ou poluentes (gases, vapores, poeiras, névoas, microorganismos e odores).

Uma pesquisa de campo realizada pela empresa XEnergy (XENERGY, 1998) na indústria americana no final da década de 90, acerca de oportunidade de melhorias no mercado interno, recolheu informações de 30 mil sistemas motrizes; dentre outras coisas, essa pesquisa evidenciou diversas oportunidades referentes às chamadas Medidas de Eficiência Energética (MEE) nos ventiladores industriais. A Figuras 2 e 3 apresentam alguns resultados obtidos pela XEnergy acerca da conservação de energia; especificamente em sistemas de exaustão industrial.

Figura 2 – Oportunidades MEE na ventilação industrial

MEE	Comentários
Reduzir a energia requerida	
Reduzir os efeitos de sistema através de melhores projeto de entrada e saída	Economias de até 25%
Reduzir o sobredimensionamento	Reduções de 1 a 5%. Em geral, é melhor reduzir ou controlar a velocidade do que trocar o ventilador.
Reduzir ou controlar a velocidade	
Trocar dampers ou palhetas por AVAs	Estimativas de 14 a 49% de economia em dampers na entrada. Na saída, as economias são maiores, porém há menos aplicações.
Melhorar os componentes	
Substituir correias em V padrão por correias dentadas	Metade das aplicações possuem correias, 2/3 das quais são padrão, com eficiência de 90 a 97% contra 94 a 98% das dentadas.
Usar modelos mais eficientes	Embora os rendimentos variem muito com os modelos de rotor, há oportunidades reduzidas de melhora.
Operação e manutenção	
Melhores práticas de manutenção: ajustar correias, limpar ventiladores e trocar filtros regularmente	Economias de 2 a 5%, aplicáveis a todos os casos.

Fonte: adaptado de Xenergy (1998).

Figura 3 – Estimativa de Penetração e Economia das MEE na ventilação industrial

MEE	Penetração			Economia	Economia líquida
	Baixa	Média	Alta		
Reduzir a energia requerida	5%	15%	25%	10%	1,5%
Reduzir ou controlar a velocidade	5%	10%	15%	20%	2,0%
Melhorar os componentes	15%	20%	25%	5%	1%
Operação e manutenção	25%	50%	60%	2%	1%
Economia total					5,5%

Fonte: adaptado de Xenergy (1998).

Este trabalho aborda a análise do controle eficiente realizado em um sistema motriz de ventilação industrial. Como parte da metodologia, será utilizado um protótipo deste equipamento instalado no LAMOTRIZ, a partir do qual serão realizados experimentos com o intuito de observar os resultados provenientes das técnicas utilizadas para o controle deste sistema, visando à eficiência do controle empregado.

2.1 Apresentação da Bancada do Exaustor

A bancada do exaustor presente no LAMOTRIZ é um protótipo simples de um sistema de exaustão industrial, tendo como principal objetivo o estudo da eficiência energética nestes sistemas motrizes.

A operação e supervisão de todo o sistema se dá por meio de uma estação de operação, *Operation Station* (OS), a qual serve de *Interface-Homem-Máquina* (IHM) entre o operador e o sistema de controle da bancada. Também existe a opção de operação local, através de dispositivos de acionamento na porta do painel.

A bancada é formada por um painel de automação juntamente com um protótipo de carga, nesse caso, um exaustor industrial. No painel de automação, está instalado o CLP, bem como dispositivos de medição e proteção do sistema. A comunicação entre o CLP e os respectivos dispositivos de proteção e medição é feita através da rede PROFIBUS-DP. No caso da conexão entre a estação de operação (OS) da bancada. A comunicação do sistema de controle, *Automation Station* (AS), é realizada via rede INDUSTRIAL-ETHERNET. Por meio de dispositivos de manobra, a carga da bancada pode ser conectada aos três principais tipos de acionamentos que estão disponíveis, a saber: partida direta, softstarter e inversor de frequência.

2.1.1 Operação da Bancada

a) Operação Local

O modo de operação local é destinado à realização de demonstrações, o qual permite que a bancada seja parcialmente operada sem a estação de operação, através de chaves e botões localizados na porta do painel de automação.

Para que a bancada opere em modo local é necessário que o operador selecione a opção local na chave local/remoto fixada na porta do painel. Neste caso, semelhantemente ao que ocorre em ambiente industrial, a opção local restringe algumas funcionalidades de operação. As operações como mudanças de *setpoints* e ajustes na malha de controle não estão disponíveis neste modo de operação. No caso das opções disponíveis nesse modo de operação encontram-se as opções de ligar e desligar o motor, reconhecer falhas e ajustes de velocidade no inversor.

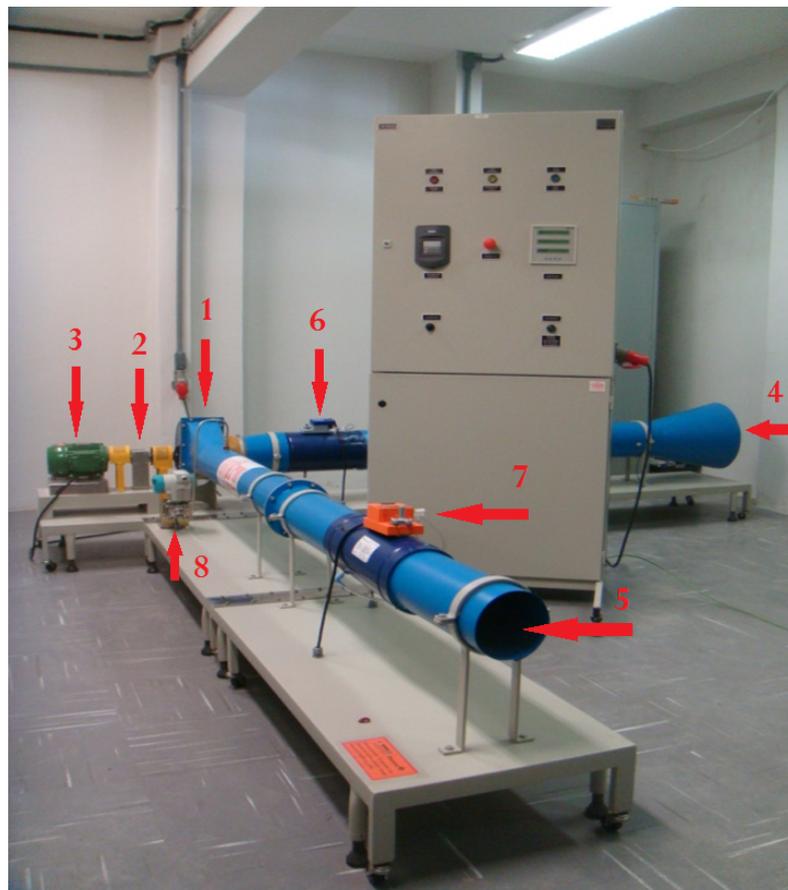
b) Operação Remota

O modo de funcionamento remoto é ativado com o propósito de operação, supervisão e aquisição de dados através da estação de operação (computador). Ativa-se a operação remota ao selecionar a opção remoto na chave local/remoto fixada na porta do painel. Quando selecionado este modo de operação, a bancada será operada exclusivamente via computador, tornando possível os ajustes na malha de controle bem como mudanças nos valores de *setpoints*.

2.1.2 Descrição da Bancada do Exaustor

A bancada do exaustor utilizada no desenvolvimento desta dissertação pode ser visualizada conforme a Figura 4.

Figura 4 – Bancada do Exaustor Presente no LAMOTRIZ



Fonte: próprio autor (2016).

De acordo com a Figura 4, são apresentados os principais equipamentos da bancada do exaustor, com a seguinte legenda:

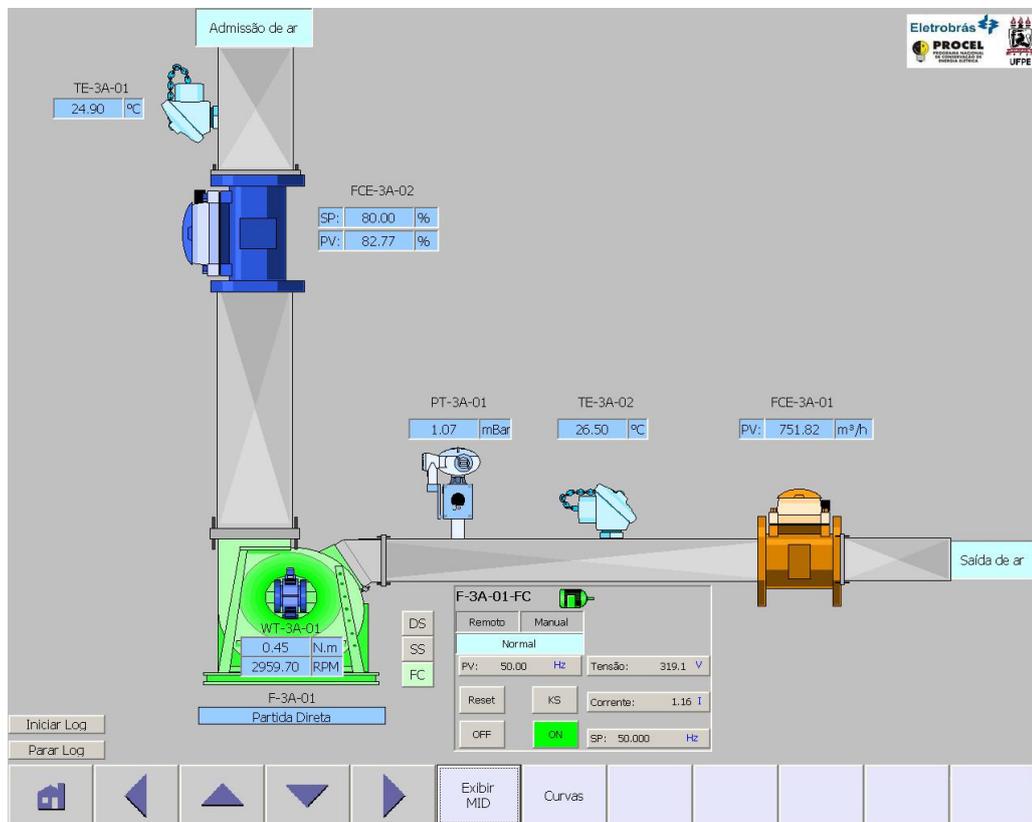
1. Ventilador de rotor axial;

2. Transdutor de torque e velocidade;
3. Motor de indução trifásico de alto rendimento (1.5 hp);
4. Admissão de ar;
5. Saída de ar;
6. Regulador de vazão (Damper);
7. Transdutor de vazão;
8. Transdutor de pressão.

2.1.3 Sistema Supervisório da Bancada

A representação da bancada do exaustor em ambiente computacional é feita por meio do software WinCC[®] da Siemens[®], na qual são modelados os componentes do sistema de controle como sensores e atuadores, bem como toda a característica operacional e suas variáveis. A Figura 5 ilustra o supervisor da bancada do sistema de exaustor industrial presente no LEEQE.

Figura 5 – Supervisor da Bancada do Exaustor no LAMOTRIZ em WinCC[®]



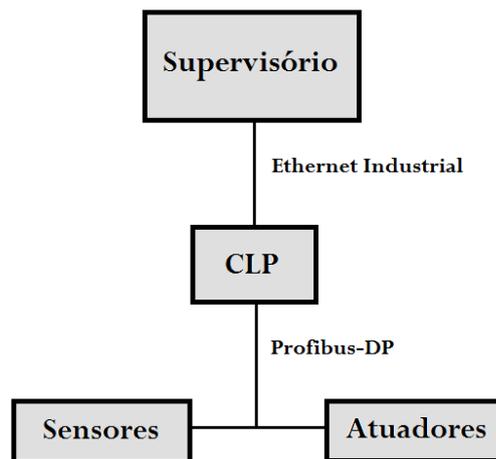
Fonte: próprio autor (2016).

De acordo com a Figura 5, tem-se representado no supervísório o ventilador (F-3A-01); um transdutor do tipo PT - 100 (TE-3A-01) que tem a função de exibir a temperatura no duto de admissão de ar; um regulador de vazão (FCE-3A-02) o qual fornece a possibilidade de controlar remotamente a abertura de uma válvula com uma variação de zero a cem por cento (0-100%); um transdutor de velocidade do ar (F-3A-01); um transdutor de torque e rotação (WT-3A-01) que indica a rotação em *rpm* e o torque em *N.m.*; um transdutor de pressão (PT-3A-01) que fornece a pressão em *mBar*, uma outra resistência do tipo PT-100 (TE-3A-02) na qual indica a temperatura no duto de saída do ar; e um transdutor de vazão que mostrará a vazão (FCE-3A-01) na saída em *m³/h.*

2.1.4 Esquema de Comunicação Presente na Bancada

O sistema hierárquico de supervisão e controle entre os diferentes componentes do sistema de exaustão industrial presente no LAMOTRIZ é descrito na Figura 5.

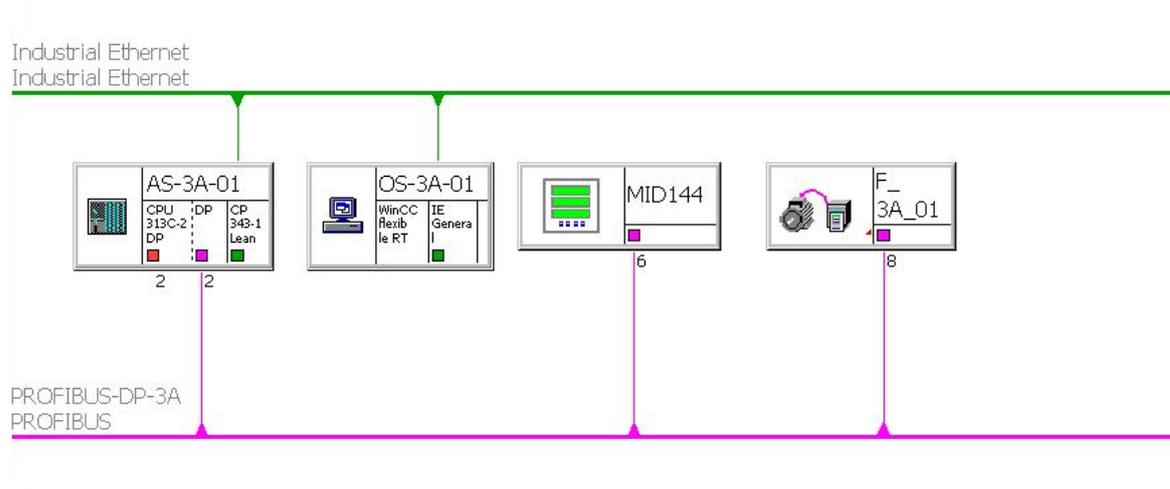
Figura 6 – Hierarquia do Sistema de Controle e Comunicação Presentes na Bancada



Fonte: próprio autor (2016).

O supervísório fornece ao usuário a possibilidade de realizar ajustes das condições de controle ao longo da operação, bem como o comando do CLP que está em um nível hierárquico inferior. O CLP é o equipamento responsável pelo controle direto do sistema, no qual interage com os diversos sensores e atuadores presentes na planta. Os dados da operação de controle da bancada são coletados através do supervísório, os quais são armazenados no computador em arquivos do tipo CSV (*Comma Separated Value*), com objetivo de futuras análises. A Figura 7 representa a rede de comunicação presente na bancada do exaustor no LEEQE.

Figura 7 – Configuração da Rede de Comunicação da Bancada



Fonte: adaptado de Equitron Sistemas (2007).

2.1.5 Possíveis Experimentos na Bancada

A bancada do exaustor possibilita a realização de diferentes tipos de experimentos que permitem a análise da eficiência energética em determinadas situações. Cada tipo de análise enfoca uma variável de controle para ajustar a saída da vazão de ar do exaustor. São três os tipos de experimentos:

a) Ajuste de vazão com o *damper* em manual

Através da variação do regulador de vazão, realiza-se o estrangulamento da entrada de ar, sendo possível obter através deste experimento o levantamento das seguintes curvas:

- i. Pressão x Potência Consumida;
- ii. Vazão x Potência Consumida.

b) Controle da vazão com *damper* em automático

Realiza-se o ajuste de vazão ou pressão através do duto, o CLP atua abrindo e fechando o *damper*. As grandezas são disponibilizadas no sistema supervisório para posterior análise.

c) Controle de vazão ou pressão através do inversor de frequência

O CLP controlará a velocidade do ventilador através do inversor de frequência, alterando assim a vazão do ar, permitindo avaliar as relações entre energia consumida, vazão e/ou pressão na tubulação.

O experimento abordado nesta dissertação é o do controle da vazão através do inversor de frequência, no qual mantém-se o *damper* totalmente aberto, permitindo o fluxo total de ar por este; sendo assim, a única variável de controle será então a frequência do inversor. Desta maneira

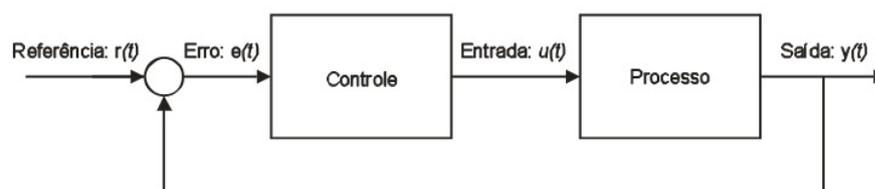
será possível avaliar a eficiência energética da bancada, unicamente pelo prisma do controlador, ou seja, a busca pelos parâmetros deste controlador que permitem um controle rápido, estável e com menor perda de potência elétrica.

2.2 O Controlador PID

O *Proportional–Integral–Derivative* (PID) é um dos controladores mais amplamente utilizados em todo o mundo para sistemas de controle industrial; sua popularidade se deve principalmente ao fato de seu desempenho robusto em muitas condições de funcionamento e também no que concerne à sua simplicidade funcional, permitindo assim aos engenheiros operá-los de uma forma simples e direta. Mesmo com o surgimento de novas técnicas de controle, os controladores PID ainda serão os protagonistas por bastante tempo nos parques industriais (CARDOSO, 2002).

De acordo com Murray (MURRAY et al., 2003), basicamente um sistema de controle é um dispositivo no qual uma certa grandeza medida é utilizada para alterar o comportamento de um sistema através de computação e atuação. De maneira simples, um controlador calcula um valor de erro $e(t)$ a partir da diferença entre a variável de saída do processo em questão $y(t)$ e o valor de referência, valor desejado ou set point $r(t)$, tendo como o objetivo minimizar esse valor de erro, ajustando a variável do processo, conhecida como variável de controle $u(t)$. A Figura 8 ilustra um processo em uma malha de controle fechada.

Figura 8 – Malha Fechada de um Controle de Processo



Fonte: próprio autor (2016).

De maneira geral, os principais tipos de controladores da família PID são:

- Controlador Proporcional (P)
- Controlador Proporcional e Integral (PI)
- Controlador Proporcional e Derivativo (PD)
- Controlador Proporcional, Integral e Derivativo (PID)

2.2.1 Controlador Proporcional (P)

Como o próprio nome já diz, o controle proporcional gera uma ação de controle de modo diretamente proporcional à entrada, ou seja, ao sinal do erro em função do tempo. A ação proporcional aplica um fator de escalonamento, reduzindo ou ampliando o valor do sinal de entrada do controlador (erro), modificando desta maneira o comportamento dinâmico da planta; esse fator é dado por K_p , ou constante proporcional. O sinal de saída do controlador então é dado pela seguinte equação, representada tanto no domínio do tempo quanto no domínio da frequência, após a aplicação da transformada de Laplace:

$$u(t) = K_p * e(t), \quad (1)$$

$$U(s) = K_p * E(s). \quad (2)$$

2.2.2 Controlador Proporcional e Integral (PI)

Nessa estrutura de controle, a ação integral consiste em fornecer na saída do controlador uma resposta proporcional ao erro e à sua duração, caso a referência seja constante, esta ação corrigirá o erro de *offset* gerado pela ação proporcional, acelerando a resposta do sistema, o que permite atingir o valor de referência mais rapidamente; a seguinte equação mostra o sinal de controle na saída PI:

$$u(t) = K_p * e(t) + K_p * \frac{1}{T_i} \int e(t). \quad (3)$$

Aplicando a transformada de Laplace à equação 3, considerando suas condições iniciais como sendo nulas, é possível obter a função de transferência $G_c(s)$ do controlador PI:

$$G_c(s) = \frac{U(s)}{E(s)} = K_p \left(1 + \frac{1}{sT_i}\right). \quad (4)$$

O termo T_i é conhecido como o *tempo integral*, que basicamente são intervalos regulares de tempo para a correção da variável manipulada. Alguns controladores têm o ajuste desse tempo em segundos, porém, dependendo da planta o mais conveniente seja usar milissegundos. O inverso do tempo integral multiplicado por K_p é definido como o *ganho integral* (K_i), dado por $K_i = \frac{K_p}{T_i}$. Se o valor do ganho integral é pequeno, a resposta do sistema pode levar muito tempo para atingir o valor desejado. Em contrapartida, se o ganho integral for bastante elevado, o sistema pode vir a tornar-se instável, contudo, uma das grandes vantagens do uso do termo integrativo é a eliminação do erro em regime permanente (ASTROM; HAGGLUND, 1995).

2.2.3 Controlador Proporcional e Derivativo (PD)

A ação de controle derivativa apresenta uma ação de controle proporcional à taxa da variação do erro. Essa ação quando combinada com a ação proporcional, tem o objetivo de antecipar a correção do erro, diminuindo o tempo de resposta e melhorando a estabilidade do sistema. A equação que descreve o sinal de controle do controlador PD é dada por:

$$u(t) = K_p * e(t) + K_p * T_d \frac{de(t)}{dt}. \quad (5)$$

A função de transferência desse controlador é obtida a partir da aplicação da transformada de Laplace na equação 5, obtendo a seguinte equação:

$$G_c(s) = \frac{U(s)}{E(s)} = K_p(1 + sT_d). \quad (6)$$

A ação derivativa atua em intervalos de tempo regulares conhecidos como *tempo derivativo* (T_d), similarmente ao tempo integrativo; o T_d pode ser definido em milissegundos, segundos ou minutos. O *ganho derivativo* é diretamente proporcional ao tempo derivativo, dado por $K_d = K_p T_d$, sendo assim, a ação derivativa não deve ser usada em processos nos quais o sistema responda rapidamente a uma perturbação, tampouco em situações que apresentem muito ruído no sinal, o que poderia levar à instabilidade ao sistema de controle.

2.2.4 Controlador Proporcional, Integral e Derivativo (PID)

O controlador PID é resultante da união dos controles proporcional, integral e derivativo. Seu sinal de controle é dado pela seguinte equação no domínio do tempo:

$$u(t) = K_p * e(t) + K_p * \frac{1}{T_i} \int e(t) + K_p * T_d \frac{de(t)}{dt}. \quad (7)$$

Aplicando a transformada de Laplace à equação 7, considerando suas condições iniciais nulas, é obtida a função de transferência do controlador PID, dada pela equação:

$$G_c(s) = \frac{U(s)}{E(s)} = K_p \left(1 + \frac{1}{sT_i} + sT_d \right). \quad (8)$$

Uma importante observação a respeito da equação do controlador PID é concernente ao termo derivativo; esse termo não é aplicado nesta forma pura, como apresentado na equação 8, principalmente pelo fato deste ampliar ruídos, bem como também não é implementado fisicamente. Uma maneira de solucionar este inconveniente do termo derivativo no PID é a aplicação de um filtro na ação derivativa, de acordo com a seguinte equação:

$$D(s) = \frac{sT_d}{1 + \alpha sT_d} \quad (9)$$

A função de transferência do controlador PID com filtro derivativo torna-se então:

$$G_c(s) = \frac{U(s)}{E(s)} = K_p \left(1 + \frac{1}{sT_i} + \frac{sT_d}{1 + \alpha sT_d} \right). \quad (10)$$

De acordo com Johnson e Moradi (JOHNSON; MORADI, 2005), a família dos controladores PID é desenvolvida a partir da combinação das ações proporcional, integral e derivativa, conforme a necessidade de cumprir requisitos de desempenho específicos. De acordo com Campos e Teixeira (CAMPOS; TEIXEIRA, 2006), os tipos de algoritmos PID mais implementados em controladores digitais são os do tipo ideal, paralelo, paralelo alternativo e o série, este último é também conhecido como iterativo e clássico. No controlador tipo série os ganhos são dependentes do termo proporcional, no caso do paralelo são independentes.

Em relação a projetos de controladores que incluam o PID, faz-se necessário ter o conhecimento de qual o tipo de algoritmo PID está sendo implementado, visto que este influencia consideravelmente na sintonia do controlador (CORRIPIO, 1996).

2.2.5 Controladores PID Comerciais

Em ambientes industriais, é necessária uma atenção em especial aos diferentes tipos de fabricantes dos controladores, isso porque alguns fabricantes têm estruturas diferentes de outros; sendo assim, se um determinado controle, implementado em um certo tipo de controlador em uma malha de controle, precisar ser realocado para um outro tipo de controlador, de outro fabricante por exemplo, os parâmetros deste controlador muito provavelmente precisarão sofrer alterações (ASTROM; HAGGLUND, 2006).

Para a realização dos ajustes nos parâmetros dos controladores PID comerciais, faz-se necessário o conhecimento de como o mesmo encontra-se estruturado; infelizmente, essa estrutura nem sempre está disponível ao usuário. Em muitas situações, alguns fabricantes aprimoram os métodos de controle com o intuito de facilitar o ajuste e melhorar o desempenho do controlador, como a implementação de alguns filtros por exemplo, utilizando-os como ofertas diferenciais de produto no mercado. Assim sendo, essas novas tecnologias de aprimoramento não são abertas aos usuários do produto, o que os tornam sempre dependentes dos desenvolvedores de tal tecnologia, limitando assim, a exploração de toda a capacidade disponível nestes controladores (SHIRAHIGE, 2007).

A Tabela 1 apresenta como está implementada a estrutura do algoritmo PID nos principais controladores comerciais; apesar de ser atual, é necessário realizar uma revisão do que se encontra no manual do CLP (Controlador Lógico Programável), pois o fabricante pode ter feito mudanças, ou até mesmo acrescentado algo à estratégia de controle PID do seu

equipamento. Os principais algoritmos em PID comerciais são:

Tabela 1 – Controladores PID Comerciais

Fabricantes	Modelos	Algoritmo PID	Parâmetros do Controlador
Allen Bradley	Contrologix PID - independente	$K_p e(t) + K_i \int e(t) dt + K_d \frac{dPV}{dt}$	K_p : Ganho proporcional K_i : Ganho integral K_d : Ganho derivativo
Allen Bradley	Contrologix PID - dependente	$K_p(e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{dPV}{dt})$	K_p : Ganho proporcional T_i : Reset time(min) T_d : Rate time(min)
Altus	Series : DUO, AL e FBs	$K_p(e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{de(t)}{dt})$	K_p : Ganho proporcional T_i : Tempo integral(seg) T_d : Tempo derivativo(seg)
Siemens [®]	S7	$K_p(e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{de(t)}{dt})$	K_p : Ganho proporcional T_i : Reset time(seg) T_d : Tempo derivativo(seg)
Yogogawa	Field Control Station PID	$\frac{100}{BP}(e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{de(t)}{dt})$	BP: Banda Proporcional T_i : Tempo integral(seg) T_d : Tempo derivativo(seg)
Smar	MultiLoop CD-600	$K_p(e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{de(t)}{dt})$	K_p : Ganho proporcional T_i : Tempo integral(min) T_d : Tempo derivativo(min)
HI-Tecnologia	ZAP-900, 500 e Flex 950	$K_p(e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{de(t)}{dt})$	K_p : Ganho proporcional T_i : Tempo integral(min) T_d : Tempo derivativo(min)
Schneider	Família Modicon	$K_p(e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{de(t)}{dt})$	K_p : Ganho proporcional T_i : Tempo integral(min) T_d : Tempo derivativo(min)

Fonte: adaptado de Pinto (2014).

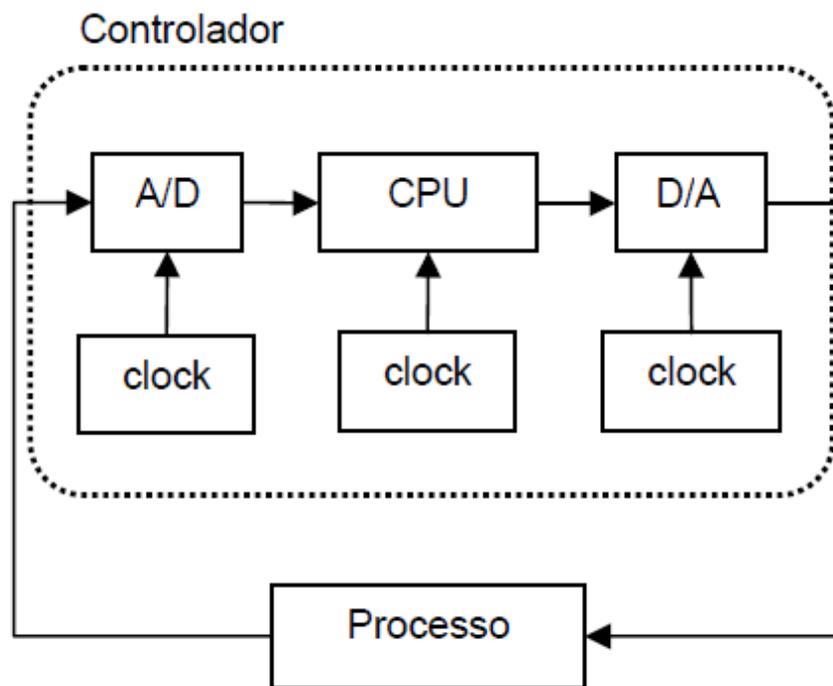
2.2.6 Controlador PID Digital

Em um ambiente industrial, é comum o uso de CLPs em processos de controle. Nessa situação o controlador PID é implementado de maneira digital nos CLPs; no entanto, para que isso ocorra é necessário que o algoritmo PID seja convertido para sua forma discreta, em que uma nova ação de controle é executada após um intervalo de tempo regular, o qual denomina-se de *tempo de amostragem* (T_s). A escolha do tempo de amostragem é de fundamental importância no controle digital; essa escolha deverá ser adequada à capacidade de processamento do controlador e ao nível de ruído da planta (POPESCU; TAMBOZI; PETRESCU, 2000). O tempo de amostragem também precisa ser escolhido de tal forma que consiga ser compatível com a dinâmica do sistema controlado e às propriedades do atuador (BOBÁL et al., 2005).

Além do tempo de amostragem que está relacionado à informação que chega ao controlador pelo conversor A/D, também existem outros períodos importantes na dinâmica

do processo, tais como o período de execução dos cálculos por parte do controlador e o período de atualização das informações, referentes à saída do controle pelo conversor D/A. A Figura 9 apresenta o esquema das operações de conversões das informações por parte do controlador digital.

Figura 9 – Execuções das Operações A/D e D/A em um Controlador Digital



Fonte: adaptado de Shirahige (2007).

No processo de conversão do PID para sua forma discreta, os operadores integral e derivativo necessitam ser aproximados por operações discretas equivalentes; no caso desta dissertação, para a adequação do padrão existente nos modelos de CLPs da Siemens[®], o método discretização utilizado foi o *Forward Rectangular Method* (FRM), onde por sua vez, a integral e a derivada são aproximadas, respectivamente, pelas seguintes equações em tempo discreto:

$$\int_0^t e(t)dt \approx T_s \sum_{i=0}^{k-1} e(i) \quad (11)$$

$$\frac{de(t)}{dt} \approx \frac{e(k) - e(k-1)}{T_s} \quad (12)$$

No domínio discreto, a estrutura do algoritmo PID é dada por:

$$u(k) = K_c(e(k) + \frac{T_s}{T_i} \sum_{i=1}^k e(i) + \frac{T_d}{T_s}(e(k) - e(k-1))). \quad (13)$$

A respeito da equação 13, caso a relação T_d/T_s seja muito grande, haverá uma maior reação por parte do controlador a ruídos, causando alguns degraus na saída do controlador, em que k representa o intervalo da amostragem do sinal. Em relação à T_s/T_i , caso seja muito pequena, resultará em um erro permanente no controlador, ocasionando perdas de precisão nas operações de arredondamento, conversões e computação por parte da CPU, esse efeito é devido à precisão dos conversores A/D (BOBÁL et al., 2005). Se o tempo da amostragem for demasiadamente grande ou mesmo pequeno quando comparado com a dinâmica do sistema, medições futuras podem apresentar alguma diferença do valor real da grandeza naquele instante de tempo. Tal erro influencia de forma significativa os resultados finais do controle (MALIK; CHENG, 1991).

2.2.7 Sistema Anti-Windup

Na prática, todos os controladores possuem limites operacionais. Quando um variável de controle alcança um limite, ou seja, uma restrição operacional, de máximo ou mínimo, ocorre a saturação do sinal de controle. Este fato resulta de certa maneira na quebra na malha de realimentação, perdendo-se desta forma um grau de liberdade no sistema de controle, pois nessa situação o atuador permanecerá no seu limite máximo (ou mínimo) independentemente da saída do processo. Caso esta situação de saturação ocorra em um controlador que possua a ação integrativa, o sinal do erro continuará a ser integrado, acumulando assim a parcela da integral na saída do controlador, este fenômeno é denominado de *windup*.

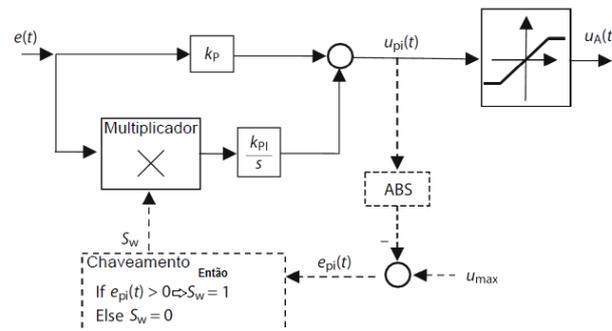
Para que o controlador volte a atuar na região linear, ou seja, saia da saturação, é necessário que o todo o erro integrado excessivamente seja cancelado; isto é feito aplicando um sinal de erro oposto por um certo período de tempo, o qual é responsável por deixar a resposta transitória do sistema lenta e oscilatória, situação não desejável em sistemas industriais (PINTO, 2014). As soluções para este inconveniente consistem, geralmente em retirar ou paralisar a ação integral assim que o sinal de controle atingir a região de saturação, retornando-a novamente quando o sinal voltar à região linear. Este procedimento é denominado de *anti-windup* (JOHNSON; MORADI, 2005). A Figura a seguir representa uma das formas de implementação do sistema *anti-windup*.

Ainda que em muitos dos PID Comerciais o sistema Anti-Windup esteja implementado, os fornecedores, todavia, não apresentam maiores detalhes sobre a sua implementação ao usuário (PINTO, 2014).

2.3 Métodos para Sintonizar os Controladores PID

A chave da sintonia dos controladores PID em malhas de controle é a identificação de como a dinâmica de um processo reage aos esforços do controle, e de acordo com requisitos de desempenho, determinar os parâmetros do algoritmo PID necessários para a dinâmica de eliminação de erros (VANDORE, 2006).

Figura 10 – Sistema Anti-Windup para um Controlador PI



Fonte: adaptado de Pinto (2014).

Um dos primeiros e mais clássicos métodos de sintonia aplicada a controladores PID foi introduzido em 1942 pelo engenheiro químico John G. Ziegler e o matemático Nathaniel B. Nichols. Esse método é baseado na caracterização da dinâmica do processo por meio de simples equações matemáticas, a partir de algumas informações da planta. Em contrapartida, o método fornece poucas informações a respeito do sistema e tende a produzir sistemas em malha fechada com baixo amortecimento e robustez. Mesmo assim, até os dias atuais, este trabalho tem um impacto significativo nas práticas de controle de sistemas, sendo bastante aplicado na sintonia de controladores PID comerciais, seja em sua forma original ou em suas variantes (ASTROM; HAGGLUND, 2001).

Uma outra maneira de sintonização que foi muito utilizada, consistia em ligar o sistema em modo manual e ir ajustando os parâmetros do controlador à medida em que a saída aproximava-se do valor esperado; no entanto, esta técnica era muito onerosa, pelo fato de que era necessária muita experiência por parte do operador e também requeria uma alta demanda de tempo para os ajustes dos ganhos (THIMOTIO, 2005).

As diferentes estruturas do controlador PID têm uma influência direta na sintonia e no desempenho do processo de controle resultante. De acordo com Tan (TAN; LEE; JIANG, 2001), para que um processo de sintonia seja eficaz é necessário o conhecimento exato de sua estrutura. Segundo Cheng (CHENG, 2002). A sintonia de um controlador não é apenas influenciada por sua estrutura utilizada, mas também pelo tipo de processo controlado.

2.3.1 Métodos de Ziegler-Nichols

Os métodos desenvolvidos por J. G. Ziegler e N. B. Nichols, foram apresentados em 1942 e são conhecidos como os primeiros métodos sistemáticos de ajustes dos parâmetros do controlador PID (ZIEGLER; NICHOLS, 1942). A partir de testes práticos em determinados processos utilizando o controlador comercial *Fulscope da Taylor*, os autores desenvolveram regras empíricas para o ajuste dos parâmetros do controlador (ASTROM; HAGGLUND, 2006).

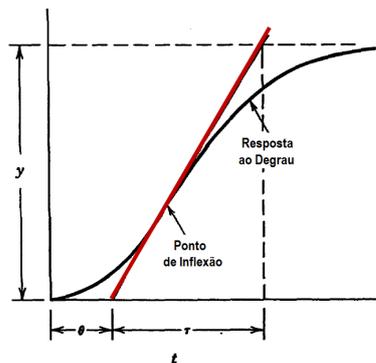
Os dois métodos clássicos de Ziegler e Nichols são apresentados a seguir:

O método é baseado nas informações obtidas da resposta dinâmica do processo a um degrau em malha aberta. Neste método, admite-se que a resposta em malha aberta do sistema a um degrau de entrada seja monotônica, ou seja, neste caso a função preserva uma relação de ordem crescente, após um tempo inicial. Essa função pode ser aproximada por uma função de transferência de um sistema de primeira ordem com atraso de transporte. Este modelo de parametrização da dinâmica de um processo é comumente encontrado na indústria (COELHO; COELHO, 2004). A função é dada de acordo com a seguinte equação:

$$G_p(s) = \frac{K}{\tau s + 1} e^{\theta s} \quad (14)$$

O valor de K é conhecido como ganho estático, ou ganho em malha aberta, sendo obtido pela relação da variação do sinal de saída do processo (Δy) com a variação do sinal de controle (Δu) na entrada do processo, representando assim um parâmetro de relação de ganho ($K = \Delta y / \Delta u$). A curva da resposta a uma entrada degrau terá por característica duas constantes, o atraso de transporte (θ) e a constante de tempo (τ). A determinação dessas constantes é feita traçando-se uma linha tangente no ponto de inflexão da curva; então determina-se a interseção da linha com o eixo das abcissas (tempo), e a linha quando a saída estiver em regime permanente constante ($y \rightarrow \infty$). A Figura 11 ilustra a forma para a obtenção dos parâmetros da função de transferência através da resposta do sistema.

Figura 11 – Resposta do Processo de Primeira Ordem em Malha Aberta



Fonte: adaptado de Pinto (2014).

O trabalho de Ziegler e Nichols propôs uma tabela que demonstra a sintonia do controlador PID a partir dos parâmetros K , τ e θ , obtidos com o auxílio da curva do modelo de primeira ordem com atraso de transporte ou tempo morto, mostrada na Figura 11. A tabela a seguir é utilizada na sintonia PID Ziegler-Nichols.

A Tabela 2 foi apresentada com base nos controladores que existiam na época, todavia, ainda não se tem um consenso na literatura a respeito de qual tipo de controlador PID essa

Tabela 2 – Parâmetros para Sintonia PID Ziegler-Nichols

Controlador	K_p	T_i	T_d
P	$\tau/K\theta$	-	-
PI	$0.9(\tau/K\theta)$	3.33θ	-
PID	$1.2(\tau/K\theta)$	2θ	0.5θ

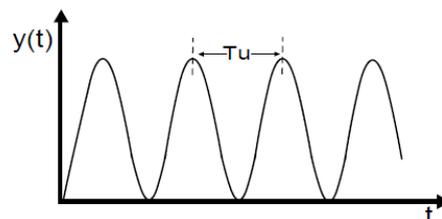
Fonte: adaptado de Ziegler-Nichols (1943).

tabela foi proposta, se foi para o tipo paralelo ou série. De acordo Skogestad (SKOGESTAD, 2004) o modelo utilizado nos trabalhos de Ziegler-Nichols foi o do PID ideal. A razão θ/τ é conhecida como *fator de controlabilidade*; para Corripio (CORRIPIO, 1996), esta razão deve estar entre [0.1,0.3] para uma boa sintonia; no entanto, de acordo com Rivera (RIVERA; MORARI; SKOGESTAD, 1986), este fator deverá estar entre [0.2,1.4], valores acima de 4 acarretarão em sistemas instáveis. Existem vários outros métodos para a obtenção dos parâmetros K , τ e θ também baseados na resposta ao degrau, que podem ser aproximados para a função de transferência de primeira ordem com atraso de transporte, alguns destes são: o método de Nishikawa, Sudaresan, Smith e de Hauglund (COELHO; COELHO, 2004).

b) Método da Oscilação Crítica

Este método diferentemente do primeiro de Ziegler-Nichols, utiliza uma malha fechada com o controlador proporcional (P), aumentando-se este ganho P de maneira gradual até obter-se uma resposta de caráter oscilatório com uma amplitude constante. A partir deste ponto, é determinado o *ganho crítico* (K_u), o qual é o valor do ganho do controlador P que gerou a resposta oscilatória de amplitude constante, e também o *período crítico* (T_u). A Figura 12 ilustra a forma da resposta obtida pelo método da oscilação crítica.

Figura 12 – Resposta do Processo de Primeira Ordem em Malha Aberta



Fonte: adaptado de Pinto (2014).

De posse dos valores de K_u e P_u , Ziegler e Nichols (ZIEGLER; NICHOLS, 1942) propuseram uma outra Tabela 3 para a obtenção dos parâmetros de sintonia do controlador PID,

semelhante à vista no método da resposta ao degrau, porém, desta vez usando como critério de desempenho uma razão de declínio de valor igual a 1/4. Todavia, este método não é muito utilizado, pelo fato de que tende a levar o processo a variar fora de uma região segura, podendo causar instabilidade do sistema. A seguir, a Figura 12 e a tabela 3 representam a metodologia para a sintonia por meio da oscilação crítica.

Tabela 3 – Parâmetros para Sintonia PID Ziegler-Nichols (Oscilação Crítica)

Controlador	K_p	T_i	T_d
P	$0.5K_u$	-	-
PI	$0.45K_u$	$T_u/1.2$	-
PID	$0.60K_u$	$T_u/2$	$T_u/8$

Fonte: adaptado de Ziegler-Nichols (1943).

2.3.2 Métodos de CHR

Criado por K. L. Chien, J. A. Hrones e J. B. Reswick, este método foi um dos primeiros a fazer uso do modelo aproximado de primeira ordem com tempo morto, representativo do comportamento de sistemas de alta ordem (CHIEN; HRONES; RESWICK, 1952). Desenvolvido no *Massachusetts Institute of Technology*, foi o pioneiro em determinar regras para os ajustes diferenciados nas características servo (atingir o valor *setpoint*) e regulatórias (compensar os efeitos de perturbações externas).

O trabalho propôs um estudo acerca de regras para ajustes dos parâmetros para três diferentes tipos de controladores PID, duas na forma paralelo e uma na forma série, as quais foram obtidas por meio de simulações em computador, envolvendo diversas condições e obedecendo a dois critérios: resposta mais rápida sem sobrelevação e resposta mais rápida com máxima sobrelevação. Originalmente o trabalho foi produzido para o PID paralelo, no entanto, pode-se convertê-lo para o PID ideal, presente nesta dissertação. As tabelas 4,5 e 6 apresentam os parâmetros para a sintonização dos controladores PID proposta por CHR.

Tabela 4 – Parâmetros para Sintonia PID por CHR sem Sobrevalor (Servo)

Controlador	K_p	T_i	T_d
P	$0.3(\tau/K\theta)$	-	-
PI	$0.35(\tau/K\theta)$	1.16τ	-
PID	$0.6(\tau/K\theta)$	τ	$\theta/2$

Fonte: adaptado de Chien, Hrones & Reswick (1952).

Tabela 5 – Parâmetros para Sintonia PID por CHR sem Sobrevalor (Regulatório)

Controlador	K_p	T_i	T_d
P	$0.3(\tau/K\theta)$	-	-
PI	$0.6(\tau/K\theta)$	4θ	-
PID	$0.95(\tau/K\theta)$	2.375θ	0.421θ

Fonte: adaptado de Chein, Hrones & Reswick (1952).

Tabela 6 – Parâmetros para Sintonia PID por CHR com 20% de Sobrevalor (Servo)

Controlador	K_p	T_i	T_d
P	$0.7(\tau/K\theta)$	-	-
PI	$0.6(\tau/K\theta)$	τ	-
PID	$0.95(\tau/K\theta)$	1.357τ	0.473θ

Fonte: adaptado de Chein, Hrones & Reswick (1952).

2.3.3 Método de Cohen e Coon

Este método foi formulado pelo engenheiro G. H. Cohen e o matemático G. A. Coon, o qual baseia-se, assim como no método de Ziegler e Nichols, no critério da razão de decaimento de 1/4, em resposta a um distúrbio na carga (COHEN; COON, 1953). O intuito era o de se obter uma sintonia dos processos com tempo morto mais elevados, proporcionando uma maior controlabilidade. Devido à existência de uma infinidade de modos harmônicos, a sintonia do controlador PID para sistemas de primeira ordem com tempo morto, baseada neste método, pode gerar divergência de valores. Sendo assim, os autores propuseram estudos baseados na harmônica fundamental, a qual tem como característica possuir a maior amplitude e menor frequência. De acordo com Rivera (RIVERA; MORARI; SKOGESTAD, 1986), este método possui um desempenho relativamente bom para valores de $\frac{\theta}{\tau}$ na faixa entre 0.4 e 0.6. A tabela 7 apresenta os parâmetros para a sintonização dos controladores PID proposta por Cohen e Coon.

Tabela 7 – Parâmetros para Sintonia PID por Cohen e Coon

Controlador	K_p	T_i	T_d
P	$(1.03+0.35(\frac{\tau}{\theta}))(\frac{\tau}{K\theta})$	-	-
PI	$(0.9+0.083(\frac{\tau}{\theta}))(\frac{\tau}{K\theta})$	$\frac{(0.9+0.083(\frac{\tau}{\theta}))}{(1.27+0.6(\frac{\tau}{\theta}))}\theta$	-
PID	$(1.35+0.25(\frac{\tau}{\theta}))(\frac{\tau}{K\theta})$	$\frac{(1.35+0.25(\frac{\tau}{\theta}))}{(0.54+0.6(\frac{\tau}{\theta}))}\theta$	$\frac{0.5\theta}{(1.35+0.25(\frac{\tau}{\theta}))}$

Fonte: adaptado de Cohen & Coon (1953).

2.3.4 Método de Auto-Sintonia com Relé Realimentado

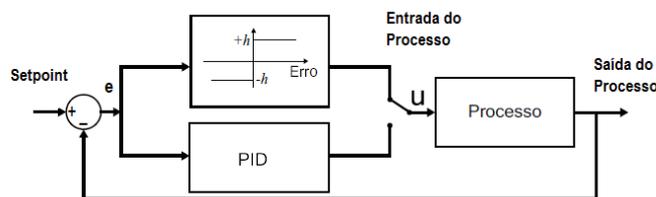
Ao observar algumas limitações do método de sintonização proposto por Ziegler e Nichols, Åström e Hägglund (ASTROM; HAGGLUND, 1984) desenvolveram um método para auto-sintonia de controladores, o qual foi baseado na resposta em frequência do sistema, abordada nos trabalhos de Ziegler e Nichols. A grande diferença foi a de que não era necessário alcançar o limite da estabilidade para encontrar o ponto crítico. Isso foi possível a partir de um ensaio em malha fechada. O método baseia-se na modelagem da não-linearidade por meio da função descritiva do relé e na interpretação em termos do diagrama de *Nyquist* para a obtenção da resposta em frequência do processo (PINTO, 2014).

No ensaio, o controlador é utilizado em modo manual e a saída do processo é conectada na entrada do relé. As Figuras 13 e 14 ilustram esse processo.

$$\text{Se } e(t) \geq 0 \rightarrow u(t) = h$$

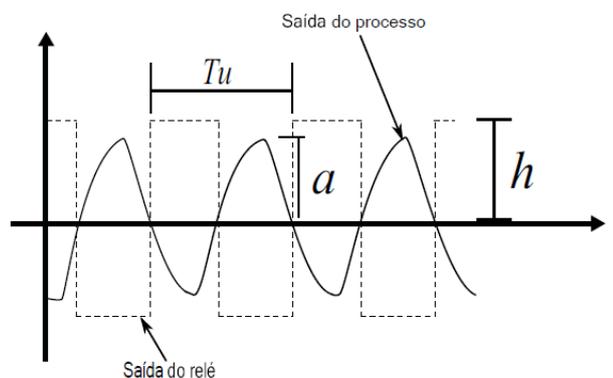
$$\text{Se } e(t) < 0 \rightarrow u(t) = -h$$

Figura 13 – Método do Relé em Malha Fechada



Fonte: adaptado de Pinto (2014).

Figura 14 – Saída do Processo com o Método do Relé



Fonte: adaptado de Pinto (2014).

Na saída do processo é possível observar uma oscilação de amplitude (a) e um período crítico T_u . A partir das informações obtidas pelo ensaio do relé é possível determinar os parâmetros do processo, o ganho crítico K_u e a frequência crítica ω_u .

$$K_u = \frac{4h}{\pi a} \quad (15)$$

$$\omega_u = \frac{2\pi}{T_u} \quad (16)$$

De posse destes valores do ponto crítico, determinam-se os parâmetros θ e τ do modelo de primeiro ordem com tempo morto pelas seguintes equações:

$$\tau = \frac{\sqrt{(K_u K)^2 - 1}}{\omega_u} \quad (17)$$

$$\theta = \frac{\pi - \arctan(\tau \omega_u)}{\omega_u} \quad (18)$$

O ganho estático (K) é obtido por meio da resposta ao degrau ($K = \Delta y / \Delta u$). De posse somente dos valores adquiridos por meio do ensaio do relé K_u e T_u , seria possível utilizar a tabela 3 de Ziegler e Nichols para conseguir uma sintonia do controlador. No entanto, com os parâmetros θ e τ obtidos pelas equações 17 e 18, juntamente com o ganho estático, é possível fazer o uso das demais tabelas de sintonia vistas nos métodos anteriores.

É importante mencionar algumas limitações pertencentes ao método do relé realimentado, dentre as quais destacam-se:

- Erros significativos podem ocorrer para um grande atraso de transporte.
- É necessário que o operador leve o processo em modo manual até o ponto de operação, em malha aberta em uma sintonia inicial.
- Possibilita a identificação de apenas um ponto da resposta em frequência do sistema, condição muitas vezes não suficiente para uma boa sintonia.

2.3.5 Limitações dos Métodos Tradicionais de Sintonia

As regras de sintonia formuladas por Ziegler e Nichols têm sido utilizadas por vários anos de maneira prática com o intuito de parametrizar os ganhos nos controladores PID para melhorar a aplicação do controle em diversos processos. Estas regras apresentam uma boa rejeição a perturbações externas. No entanto, existem algumas limitações inerentes a estas regras de sintonia, visto que são totalmente baseadas em informações insuficientes do processo, bem

como propõem uma resposta apenas ao sinal de referência, o que resulta em uma sintonia bastante pobre no que se refere principalmente à robustez (ASTROM; HAGGLUND, 2006).

Os métodos de sintonia CHR, Cohen e Coon e Relé Realimentado, abordados anteriormente, apresentam algumas melhorias em relação aos métodos tradicionais de Ziegler e Nichols; todavia, esses métodos também usam informações insuficientes do processo. A rigor tais métodos analíticos também se utilizam do modelo rigoroso da planta para projetar os ganhos do controlador. De uma maneira geral, a partir desses métodos é possível se obter os parâmetros necessários para a realização dos cálculos, por meio de equações definidas, obtendo como resultado valores da sintonia do controlador PID.

Contudo, é importante salientar que esses métodos analíticos de sintonia de controladores PID, em sua grande maioria, não conseguem determinar os melhores valores do ajuste do controlador, mas sim, um valor aproximado do que seria o ideal. No entanto, estes valores poderão servir como um ponto de partida para o refinamento da sintonia, por meio da tentativa e erro por parte do operador, o que resulta em um maior trabalho e desperdício de tempo, e às vezes, não se consegue obter valores ideais tão melhores.

Além disso, o processo de controle possui não linearidades encontradas nos atuadores e sensores, causando zonas mortas, instabilidade e erro estacionário. Existe também a variação dinâmica da planta ao longo do tempo e a sua sensibilidade a perturbações. Tais obstáculos podem deixar o controle lento e, em alguns casos, levar a grandes oscilações, desestabilizando o sistema de controle por completo.

Por estas e outras razões, os métodos de sintonização "clássicos" por si só não são suficientes para um bom desempenho no ajustes dos parâmetros do controlador. A presente dissertação aborda outros caminhos para os ajustes de tais parâmetros, utilizando a combinação de otimização e inteligência artificial, com o objetivo de garantir um melhor aproveitamento na busca dos melhores valores dos parâmetros do algoritmo do controlador PID, que proporcionem robustez e melhora na resposta global do sistema de controle.

Estes métodos analíticos de sintonização, garantem um bom desempenho na faixa de operação aos quais foram desenvolvidos, não garantindo no entanto, o mesmo desempenho em uma ampla faixa de operação. Alguns outros métodos de ajuste podem levar à escolha de ganhos que proporcionem um desempenho melhor em uma maior faixa de operação do sistema, mesmo que em alguns pontos específicos o desempenho pudesse ser otimizado.

3 IA como Ferramenta para a Otimização

3.1 Inteligência Artificial e Sistemas Especialistas

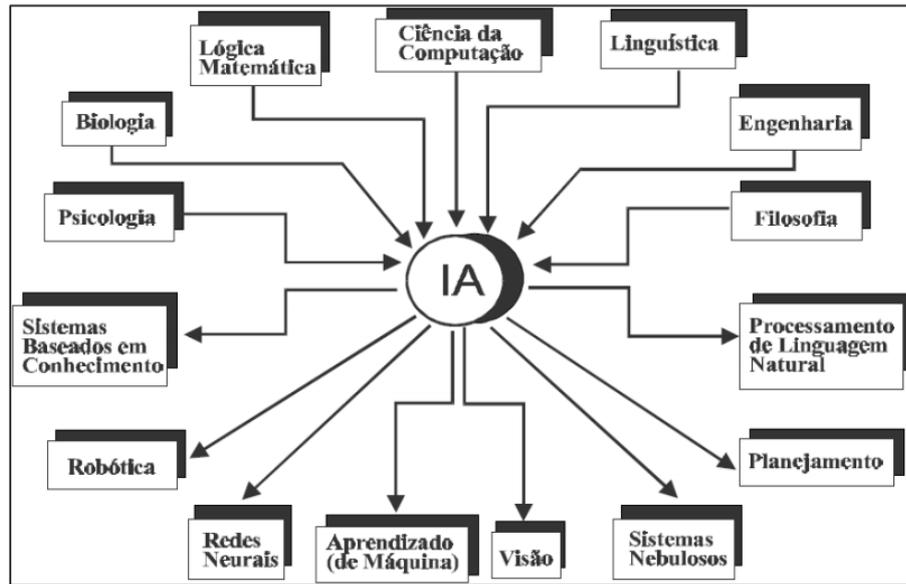
O matemático inglês Alan Mathison Turing, que desenvolveu a lógica computacional, é considerado o precursor da Inteligência Artificial (IA). No ano de 1950, Alan Turing escreveu um artigo intitulado "*Computing Machinery and Intelligence*", onde descreveu o famoso "Teste de Turing" cuja proposta foi a de verificar se uma máquina realmente consegue pensar (TURING, 1950). No entanto, atribui-se o nascimento oficial da IA à conferência de verão em Dartmouth College, New Hampshire, USA, em 1956. Nessa conferência, foi apresentado por um jovem grupo de cientistas, John McCarthy (Dartmouth), Marvin Minsky (Harvard), Nathaniel Rochester (IBM), e Claude Elwood Shannon (Bell Laboratories), um estudo sobre o tema IA, termo que ainda era pouco utilizado para designar um tipo de inteligência, construída pelo homem, para dotar máquinas de comportamentos inteligentes (MCCARTHY et al., 1955).

Desde o início, o termo IA causou muita controvérsia, principalmente em sua própria definição de "inteligência", que muitas vezes é de difícil compreensão. O uso do termo IA dispõe de diversas interpretações, algumas mais gerais, outras mais específicas, dentre as quais destacam-se:

- Algoritmos computacionais que tornam possível a uma máquina "perceber", "raciocinar" e "agir" (WINSTON; BROWN, 1979).
- Estudo das faculdades mentais através do uso de modelos computacionais (CHARNIAK; MCDERMOTT, 1985)
- Campo do conhecimento onde se estudam sistemas capazes de reproduzir algumas das atividades mentais humanas (NILSON, 1986).

Um dos principais objetivos da inteligência artificial é a concepção e implementação de sistemas inteligentes computacionais baseados em teorias e modelos criados para expressar a capacidade cognitiva do ser humano, imitando aspectos do comportamento, tais como o raciocínio, aprendizado e adaptação. Nos últimos tempos, a inteligência artificial se consolida cada vez mais como uma ferramenta poderosa para a obtenção de ganhos de produtividade em empresas, tendo resultados práticos nos mais diferentes nichos de negócio (ILAB, 2016). Por ser um tópico muito amplo, IA também está relacionada com psicologia, biologia, lógica matemática, linguística, engenharia, filosofia, entre outras áreas científicas (BARANAUSKAS; MONARD, 2000). a Figura 15 ilustra algumas áreas relacionadas com a Inteligência Artificial.

Figura 15 – Áreas Relacionadas com a Inteligência Artificial.



Fonte: adaptado de Baranauskas e Monard (2000).

O uso das técnicas de IA no desenvolvimento de aplicações práticas resultam nos chamados *sistemas especialistas*, nos quais um sistema baseado em conhecimento é especialmente projetado para emular a especialização humana de algum domínio específico. Tal sistema é construído a partir de uma base de conhecimento formado por fatos, regras e heurísticas sobre um domínio, tal como um especialista humano, devendo ser capaz de oferecer sugestões e conselhos aos usuários e, também, adquirir novos conhecimentos e heurísticas com essa iteração (BARONE, 2003).

Desta forma, um dos mitos de que esta classe de aplicações busca substituir a atuação humana perde totalmente o sentido. Todo o processo de busca e tomada de decisão deve ser orientado a partir do conhecimento dos "especialistas humanos", que serão os principais e essenciais condutores do sistema. Os programas nada mais são, portanto, do que ferramentas que embutiram dentro de seu código algum conhecimento ou método para resolver uma questão, e que permitem aos "especialistas humanos" uma visão mais aprofundada ou específica que seria impossível sem esse mecanismo de cálculo avançado. Dentro do âmbito de aplicações comerciais, diversos estudos e pesquisas têm direcionado os esforços da IA para o desenvolvimento de técnicas que solucionem problemas complexos de alocação, planejamento e otimização de recursos (ILAB, 2016).

3.2 A Otimização

A palavra ótimo é uma derivação do Latim *optimus*, que significa "o melhor". De maneira abrangente, a otimização é definida como sendo ferramentas matemáticas, adequadas

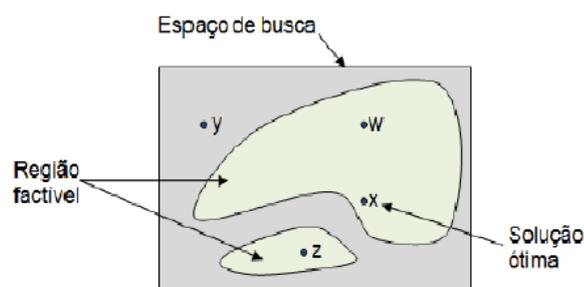
para se obter melhorias desejadas em um determinado processo, encontrando uma solução ou um conjunto de soluções ótimas (OLIVEIRA, 2013). Além disso, de acordo com Goldberg (GOLDBERG, 1989), citando Beightler, Phillips e Wilde (BEIGHTLER; PHILLIPS; WILDE, 1979), a otimização descreve como alcançar o que é o melhor, pressupondo que se saiba como medir e modificar o que é considerado bom ou ruim, abrangendo o estudo quantitativo do ótimo e os meios para encontrá-lo.

Há um interesse cada vez maior por parte da comunidade científica na resolução de problemas de otimização que incluam em sua modelagem matemática as incertezas, estocasticidade e informações dinâmicas do sistema em análise. A resolução de problemas sob estes aspectos, principalmente o da incerteza tem um grande impacto sobre o mundo real, uma vez que problemas de otimização práticos envolvem certas incertezas em sua modelagem, e estes, estão se tornando cada vez mais complexos e dinâmicos (BIANCHI; DORIGO; GAMBARDELLA, 2009).

3.2.1 Forma Geral do Problema de Otimização

A modelagem do problema de otimização inicia-se com a identificação das variáveis, reconhecendo quais são as principais variáveis envolvidas no processo a ser otimizado, chamadas *variáveis de decisão*. Definidas as variáveis do processo, o próximo passo é a definição do objetivo final do problema, maximização ou minimização de uma função das variáveis de decisão, a qual é comumente denominada de *função objetivo*. As variáveis de decisão devem respeitar algumas limitações associadas ao problema de otimização, chamadas de *restrições*. As equações que definem essas restrições podem ser de igualdade ou desigualdade. Por fim, a solução encontrada deve pertencer a um conjunto denominado *viável*, ou seja, um conjunto em que os valores ótimos das variáveis a variável ótima que satisfaz o problema obedece às restrições dentro do espaço de busca (WRIGHT; NOCEDAL, 1999). A Figura 16 ilustra uma região de busca em um processo qualquer de otimização.

Figura 16 – Regiões de Busca na Otimização.



Fonte: adaptado de Oliveira (2013).

De forma geral, o problema de otimização é dado por:

$$\begin{aligned}
 & \text{Minimizar} && f(\mathbf{x}) && (19) \\
 & \text{Sujeito a:} && h_i(\mathbf{x})=0, && i \in I \\
 & && g_j(\mathbf{x}) \leq 0, && j \in J \\
 & && \mathbf{x} \in D
 \end{aligned}$$

De acordo com esta formulação apresentada, o vetor \mathbf{x} é um vetor n -dimensional das variáveis x , onde $\mathbf{x} = (x_1, x_2, x_3, \dots, x_n)$ e $f(\mathbf{x})$, $g(\mathbf{x})$ e $h(\mathbf{x})$ são funções reais das variáveis x_i , os termos I e J representam os conjuntos das restrições de igualdade e desigualdade respectivamente, em que $I = 1, 2, 3, \dots, m$ e $J = 1, 2, 3, \dots, n$. No espaço n -dimensional existe um conjunto subdimensional D , onde $D \subset R^n$. A função f é conhecida como a função objetivo do problema, definida em $f : R^n \rightarrow R$ e as equações de igualdade $h_i = 0$ e desigualdade $g_j \leq 0$ são suas restrições, tal que $h_i : R^n \rightarrow R$ e $g_j : R^n \rightarrow R$ (LUENBERGER; YE, 2008).

Os problemas de otimização nos quais a função objetivo e as restrições são todas lineares. São denominados de problemas de *Programação Linear* (BREGALDA; OLIVEIRA; BORNSTEIN, 1988). Por outro lado, quando um modelo de otimização possuir qualquer não-linearidade na função objetivo ou em qualquer uma das restrições, é chamado de um problema de *Programação Não-Linear* (GOLDBARG; LUNA, 2005).

Algumas características importantes na modelagem dos problema de otimização são definidas a partir de suas variáveis de decisão; estas características incluem se o problema será do tipo discreto ou contínuo e se haverá ou não restrições. Os problemas de otimização em que suas variáveis são expressas por números inteiros, $x \in Z$, em que Z é o conjunto dos números inteiros, classificam-se como contínuos, em contrapartida, quando essas variáveis são números binários $x_i \in \{0,1\}$, a sua classe é a discreta (formato digital).

Alguns problemas de otimização são considerados irrestritos, ou seja, os conjuntos das restrições I e D são vazios ($I = D = 0$). No entanto, a grande maioria dos problemas encontrados no mundo real possuem algum tipo de restrição, seja em relação ao tempo, capacidade, ou recursos disponíveis, o que não permite que suas variáveis de decisão possam variar livremente, caracterizando assim um problema de otimização restrito, em que $I \neq 0$ e/ou $D \neq 0$.

Após a modelagem do problema, aplicam-se as técnicas de otimização, que são baseadas em algoritmos que determinam a melhor solução possível, conhecida como *solução ótima*. Não existe, porém, um algoritmo para a resolução dos modelos, mas um conjunto de métodos, entre os quais alguns são mais apropriados para determinadas soluções, e a sua escolha depende, em grande parte, da qualidade e precisão da solução desejada (WRIGHT; NOCEDAL, 1999).

3.2.2 Otimização Global e Local

Ao tratar-se do processo de busca pela melhor solução em problemas de otimização, faz-se necessário observar os conceitos de ótimo global e local. Um ponto x^* qualquer é dito ser uma solução ótima global da função $f(x)$ se $x^* \in D(f(x))$ e $f(x^*) \leq f(x) \forall x \in D$. Neste ponto a função objetivo possui um menor valor do que em todos os outros pontos da região viável. No caso da análise da solução ser feita em uma determinada faixa de valores da região viável, uma vizinhança definida por $\|x-x^*\| \leq \delta$, dado um ponto x^* dentro dessa vizinhança, tal que $x^* \in D(f(x))$ e $f(x^*) \leq f(x), \forall x \in \{x \mid \|x-x^*\| \leq \delta\}$, este ponto será então considerado um ótimo local.

3.2.3 Métodos Exatos e Heurísticos

Existem duas abordagens quanto à resolução dos problemas de otimização: os métodos *Exatos* e os métodos *Heurísticos*.

Geralmente, os métodos exatos são baseados em gradientes e possuem condições de otimalidade que garantem a solução ótima do problema de otimização. Também caracterizam-se pela rigidez matemática de seus modelos, fundamentados em teoremas e aproximações idealizadas, os quais, muitas vezes tornam difícil a representação do mundo real, cada vez mais dinâmico e complexo (OCHI, 1998). Nestes métodos, o modelo matemático é totalmente conhecido e a solução depende das derivadas da função objetivo, o que torna seus resultados melhores para funções contínuas, convexas e semi-modais (BRANDÃO; SARAMAGO, 2011).

No mundo real, a grande maioria dos problemas é de natureza complexa, não-lineares, de modelagem matemática difícil e baseados em funções que nem sempre são diferenciáveis, de forma que necessitam de métodos numéricos para sua solução (OCHI, 1998). Dessa forma, surgiu a necessidade do desenvolvimento de algumas técnicas capazes de obter soluções ótimas ou próximas da ótima, mesmo que sua qualidade não seja efetivamente ótima. Tais técnicas conhecidas como heurísticas, trouxeram uma maior flexibilidade ao algoritmo de busca ao associar ferramentas de inteligência artificial com técnicas de otimização. Desta forma, ao se tratar um problema de otimização deve-se escolher o método de solução baseado principalmente no comportamento da função que o representa (GOLDBARG; LUNA, 2005).

As vantagens dos métodos exatos em relação aos métodos heurísticos estão associadas, principalmente a: garantia da solução ótima, baixo número de avaliações da função objetivo, e em geral, convergência em tempo aceitável, dependendo do problema a ser resolvido. Em contrapartida, têm como desvantagens: à modelagem mais complexa, o alto custo computacional em problemas de grande número de variáveis, não sendo muito eficientes em tratar de problemas em que o espaço de busca é grande e discreto e, em muitos casos, os algoritmos dependem da existência de derivadas (OLIVEIRA, 2013).

No que concerne aos métodos heurísticos, entre suas vantagens sobre os métodos exatos, destacam-se: fácil implementação, flexibilidade do algoritmo com boa solução para a maioria

dos problemas, baixo custo computacional, capacidade de encontrar ótimos globais de funções de alta complexidade e não exigência do cálculo de derivadas. Por outro lado, suas principais desvantagens são: não garantia da otimalidade da solução obtida, um algoritmo eficiente para um determinado problema pode não ser tão eficiente para um outro tipo de problema e exigência de um número elevado de avaliações da função objetivo (OLIVEIRA, 2013).

3.3 Heurísticas e Metaheurísticas

O termo heurística deriva da palavra grega *heuriskein*, que significa "descobrir". Na realidade, heurísticas são algoritmos básicos de aproximação que procuram em um determinado espaço de busca, uma boa solução para um problema. Hoje em dia, esse termo é usado para descrever um método que baseado na experiência ou julgamento, parece conduzir a uma boa solução de um problema, mas que não garante produzir uma solução ótima (FOULDS, 1984). Um algoritmo pode ser considerado um método heurístico quando não se tem conhecimentos matemáticos completos sobre o seu comportamento, o algoritmo tem por objetivo resolver problemas complexos utilizando uma quantidade não muito grande de recursos, especialmente no que diz respeito ao consumo de tempo para encontrar soluções de boa qualidade (SUCUPIRA, 2004).

Grande parte das heurísticas foi desenvolvida para a solução de problemas específicos, não sendo eficientes ou até mesmo aplicáveis para uma gama maior de problemas. Desta maneira, a necessidade para obtenção de soluções que envolvam problemas de otimização mais complexos, de atuação mais ampla, resultou na construção das chamadas metaheurísticas, a partir da reunião de conceitos da área de Otimização e da Inteligência Artificial (SOUZA, 2005). Foi Glover quem primeiro introduziu o termo metaheurística, adicionando à palavra heurística o prefixo "meta", que derivada do grego significa "além de, em um nível superior"(GLOVER, 1986).

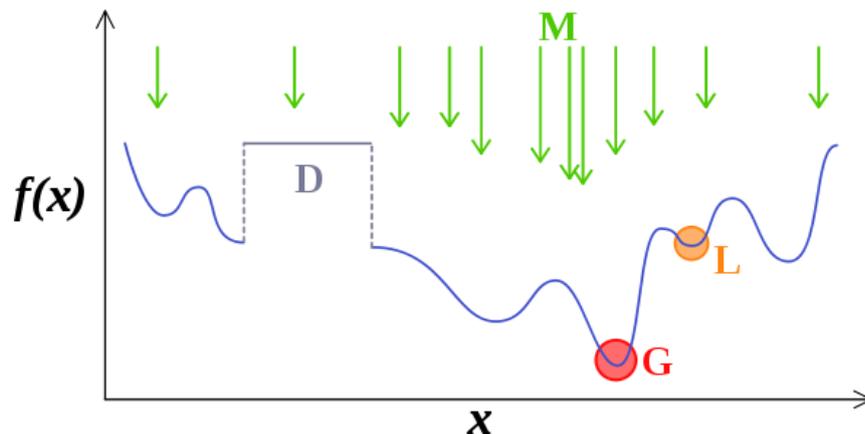
De acordo com Blum e Roli (BLUM; ROLI, 2003), ainda não há uma definição exata para o termo metaheurística. No entanto, ao longo dos anos algumas definições foram propostas. Porém, no contexto desta dissertação, a seguinte definição proposta por Osman e Laporte (OSMAN; LAPORTE, 2003) foi mais apropriada:

"Uma metaheurística é definida como um processo de geração iterativo, que guia uma heurística subordinada pela combinação de diferentes conceitos inteligentes para explorar o espaço de busca. Diferentes estratégias de aprendizagem são usadas para formar a estrutura das informações que têm por finalidade encontrar, de uma forma eficiente, soluções próximas ao ótimo".

Algoritmos metaheurísticos são geralmente iterativos estocásticos, de modo que a solução encontrada é dependente de um conjunto gerado de variáveis aleatórias, comportando-se como algoritmos de busca, tentando aprender as características de um problema, progredindo para um ótimo global (ANGEL, 1998). Em relação à otimização combinatória, no que diz respeito

à busca de um grande conjunto de soluções possíveis, metaheurísticas muitas vezes podem encontrar boas soluções com menor esforço computacional do que algoritmos de otimização, métodos iterativos ou métodos heurísticos simples (BLUM; ROLI, 2003). A Figura 17 demonstra o processo de busca de soluções por parte dos métodos heurísticos.

Figura 17 – Busca de Soluções por Métodos Heurísticos.



Fonte: adaptado de Dreco *et al.* (2003).

Dada a sua grande relevância prática, a maior parte da literatura sobre metaheurísticas é de natureza experimental, descrevendo resultados empíricos com base em experimentos computacionais com algoritmos. No entanto, para muitas heurísticas estão disponíveis muitos resultados teóricos, particularmente sobre sua convergência e a possibilidade de se encontrar o ótimo global (BLUM; ROLI, 2003).

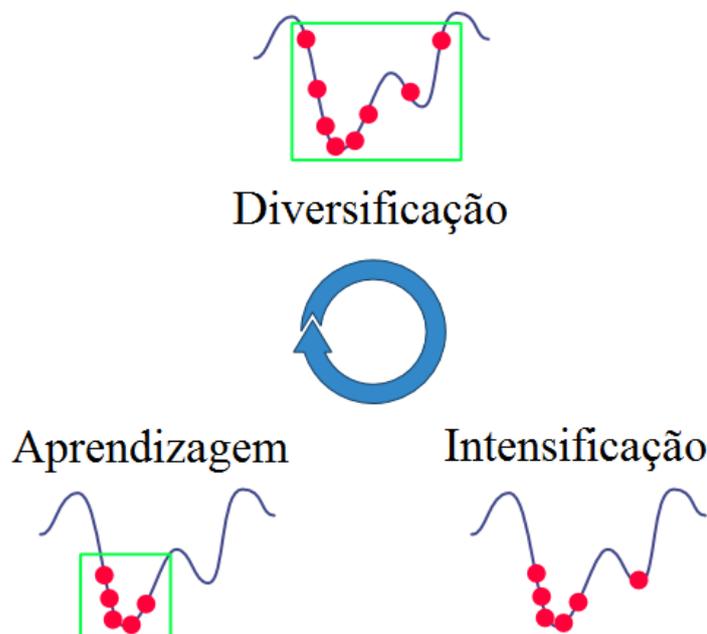
3.3.1 Classificação e Propriedades

De acordo com Blum (BLUM; ROLI, 2003), pode-se definir como as principais propriedades da maioria das metaheurísticas:

- Metaheurísticas são estratégias que orientam o processo de pesquisa.
- O objetivo é o de explorar de forma eficiente o espaço de busca para encontrar soluções ótimas ou quase ótimas.
- Técnicas que constituem os algoritmos metaheurísticos variam desde um procedimento de uma simples busca local até processos de aprendizagem complexos.
- Algoritmos metaheurísticos são aproximados e geralmente não-determinista.
- Metaheurística não são específicas do problema.

Uma metaheurística terá êxito em um problema de otimização se conseguir proporcionar um equilíbrio dinâmico entre as habilidades de exploração e intensificação na procura pela solução no espaço de busca. A diversificação quanto à exploração no espaço de buscas permite visitar novas regiões deste espaço. Em relação à intensificação das buscas, esta prioriza as buscas em regiões próximas a pontos já visitados, onde melhores soluções podem ser encontradas (BLUM; ROLI, 2003). A estratégia de busca de uma metaheurística depende da filosofia empregada por ela, e seu objetivo é escapar do mínimos locais a fim de proceder à exploração do espaço de busca por soluções ainda melhores. A Figura 18 ilustra as fases de diversificação, aprendizagem e intensificação compondo as fases iterativas de uma metaheurística.

Figura 18 – Fases Iterativas de uma Metaheurística.

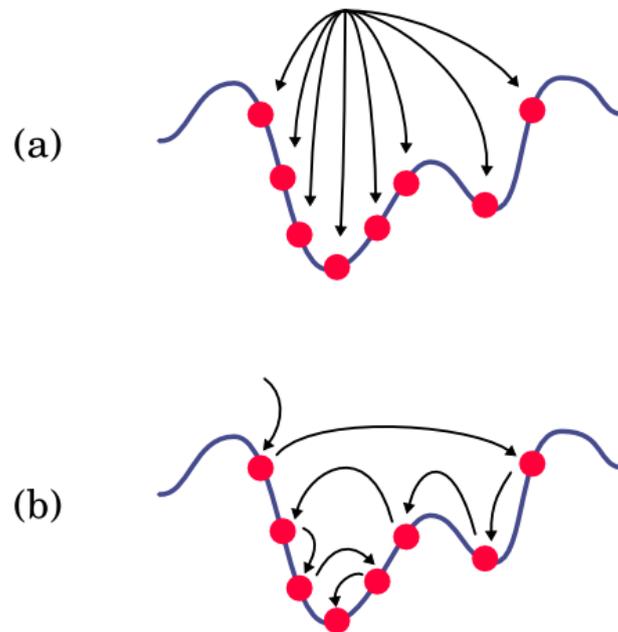


Fonte: adaptado de Dreoo *et al.* (2003).

a) Trajetória e População

As metaheurísticas mais clássicas são as que se baseiam no conceito de trajetória, onde o algoritmo apresenta apenas uma evolução da solução por iteração no espaço de busca. Nesse contexto, os algoritmos mais conhecidos são: recozimento simulado, a busca tabu, a vizinhança variável de pesquisa e o método GRASP ou método de efeitos sonoros. Nesta classificação, existe uma outra abordagem que utiliza o conceito de população, na qual o algoritmo metaheurístico manipula um conjunto de soluções em paralelo a cada iteração, sendo os algoritmos mais conhecidos: algoritmo genético, otimização por enxame de partículas e os algoritmos de colônia de formigas (DREOO *et al.*, 2003). A Figura 19 os caminhos de uma metaheurística, em forma de população ou trajetória.

Figura 19 – Caminhos das Metaheurísticas: (a) População ; (b) Trajetórias



Fonte: adaptado de Dreoo *et al.* (2003).

b) Memória

As metaheurísticas utilizam o histórico de sua busca para orientar as iterações subsequentes na busca da otimização do problema. De forma simples, elas consideram o estado da investigação em uma determinada iteração para determinar a próxima iteração, um processo conhecido por Decisão de Markov (DREOO *et al.*, 2003).

c) Função Objetivo Estática e Dinâmica

A maioria das metaheurísticas usam uma função objetivo do tipo estática, ou seja, essa função permanece constante ao longo das iterações, no entanto, alguns algoritmos, tal como o da busca local guiada, altera a representação do problema, incorporando à função objetivo informações recolhidas durante o processo de busca das soluções.

d) Caráter Evolutivo e Não Evolutivo

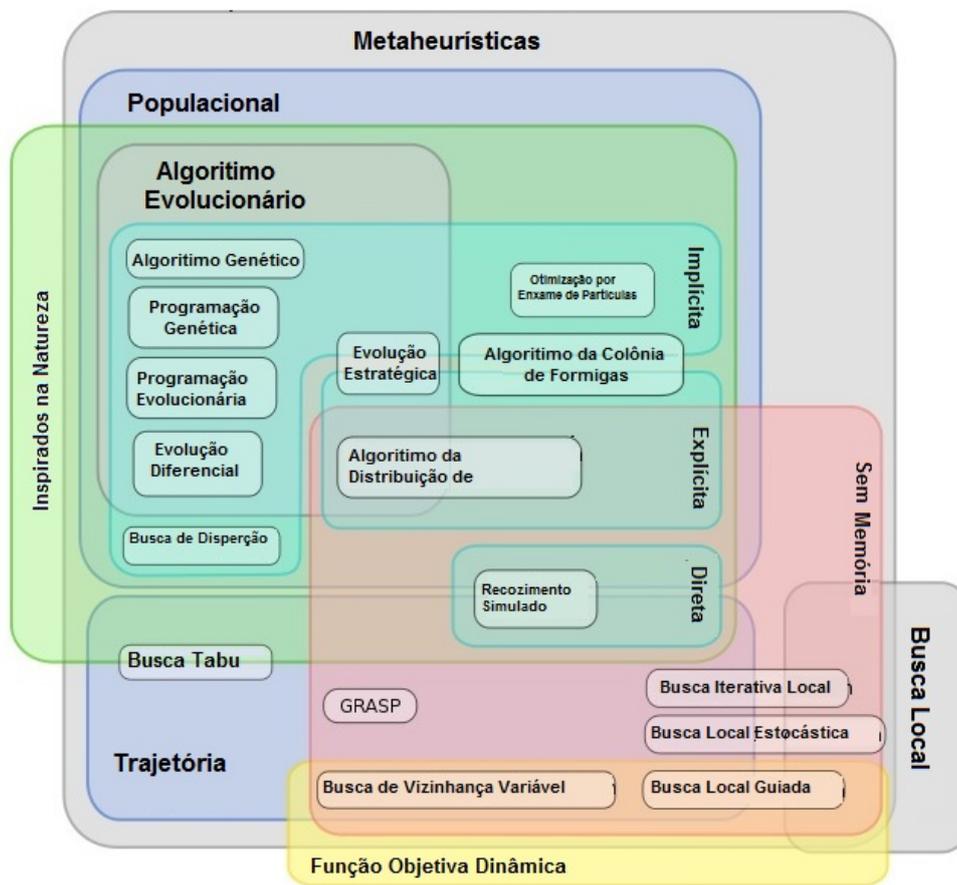
Fundamentados na teoria da Evolução Natural de Darwin, alguns algoritmos compartilham uma base de conceitos para simular a evolução de estruturas individuais, a partir dos chamados operadores, de acordo com algum algoritmo em geral. Tais algoritmos, conhecidos como evolucionários, simulam um processo natural de sobrevivência e reprodução das populações, essenciais à sua evolução. De forma análoga à natureza, os indivíduos competem entre si pelos recursos e reprodução, de forma que, os indivíduos mais aptos têm uma maior probabilidade de reprodução e assim transmitir suas características às novas gerações, os

indivíduos menos aptos tendem a ser descartados. Em contrapartida outros algoritmos não fazem uso de tais operadores, portanto não são considerados evolutivos. (ZUBEN; CASTRO, 2004).

e) Inspiradas ou Não na Natureza

Uma metaheurística é dita bio-inspirada quando suas regras de busca têm como característica principal aspectos similares ao do comportamento de alguns seres vivos, como por exemplo o algoritmos das formigas (BONABEAU; DORIGO; THERAULAZ, 1999), o algoritmo dos pássaros (EBERHART; SHI, 2001) ou o algoritmo das abelhas (ABBASS, 2001). A Figura 20 apresenta uma classificação geral das diversas metaheurísticas.

Figura 20 – Classificação das Metaheurísticas



Fonte: adaptado de Dreio *et al.* (2003).

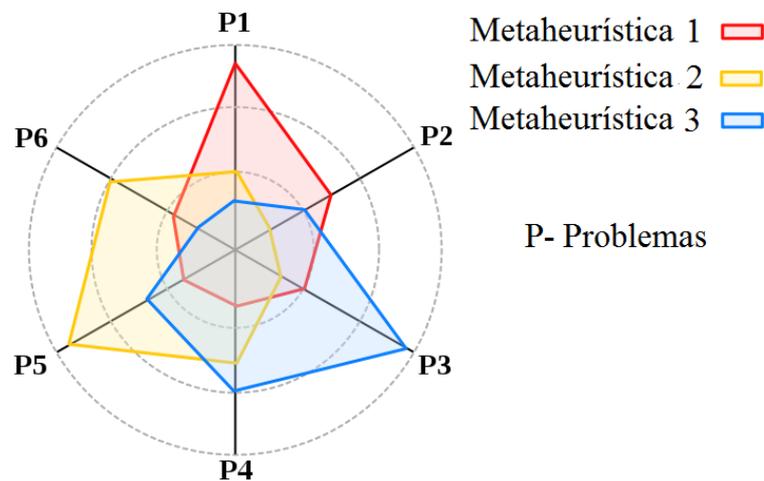
f) Vantagens e Desvantagens

De maneira simples, as metaheurísticas podem ser adaptadas à grande maioria dos problemas de otimização; no entanto, para certos tipos de problemas, estas são menos eficazes do que os métodos exatos de otimização e não garantem a descoberta do ótimo global em um tempo finito. Além disso, métodos heurísticos exigem um número elevado de avaliações da função

objetivo. Em contrapartida, existem problemas reais em que a abordagem puramente matemática não se torna eficaz, sendo as metaheurísticas uma boa forma de exploração do problema, pois a flexibilidade dos algoritmos permite uma maior exploração no espaço de busca das soluções (OLIVEIRA, 2013).

O uso de uma metaheurística pode parecer relativamente simples em uma primeira abordagem. Porém, muitas vezes faz-se necessária uma adaptação no problema a ser otimizado. Na prática, apenas a experiência do usuário pode gerenciar esses problemas. A partir de uma visão mais geral, não existe uma metaheurística realmente melhor que outra em todos os aspectos; o que realmente existe é a mais apropriada em algumas classes de problemas (OLIVEIRA, 2013). A Figura a seguir exemplifica como uma metaheurística pode ser mais aconselhável para um tipo de problema do que outro.

Figura 21 – Avaliação das Metaheurísticas para Diferentes Tipos de Problemas



Fonte: adaptado de Dreoo *et al.* (2003).

A Figura 21 demonstra que uma dada metaheurística pode ter afinidade para solucionar um tipo específico de problema, não sendo tão eficiente para outros problemas.

3.4 Otimização por Enxame de Partículas - PSO

3.4.1 A Inteligência de Enxame

A Inteligência de Enxame, conhecida como Inteligência de Colônias ou Inteligência Coletiva, é um conjunto de técnicas baseadas no comportamento coletivo de sistemas auto-organizáveis, distribuídos, autônomos, flexíveis e dinâmicos. Tais sistemas são formados a partir de um conjunto de agentes computacionais simples, que possuem capacidade de perceber e modificar o seu ambiente de maneira local. Tal capacidade de modificação do ambiente torna possível a comunicação entre os agentes, que interpretam a mudança no ambiente geradas a partir

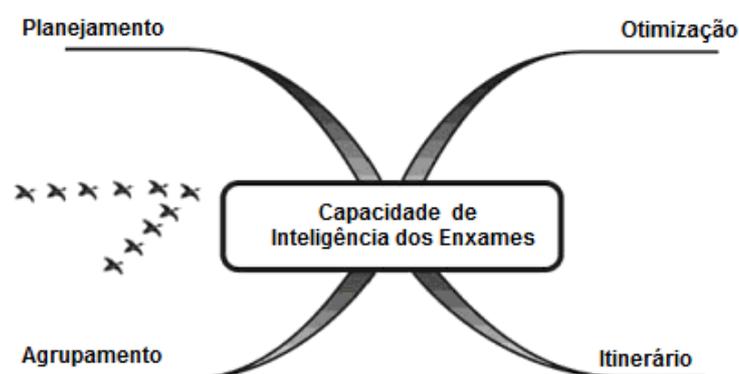
do comportamento de seus congêneres. De maneira geral, não existe uma estrutura centralizada de controle que estabelece o tipo de comportamento dos agentes, e mesmo havendo um modelo explícito do ambiente, as interações locais entre os agentes levam, em geral, ao surgimento de um comportamento global que aproxima-se da solução do problema (SERAPIÃO, 2011).

De acordo com Millonas (MILLONAS, 1994), as principais propriedades de um sistema de inteligência de enxames são :

- *Proximidade* - os agentes devem ser capazes de interagir, responder com seu comportamento às variações dos estímulos ambientais de tempo e espaço;
- *Qualidade* - os agentes devem ser capazes de avaliar seus comportamentos;
- *Diversidade* - permite ao sistema reagir a situações inesperadas (perturbações);
- *Estabilidade* - o comportamento dos agentes não deve ser afetado por toda ou qualquer variação ambiental;
- *Adaptabilidade* - os agentes devem ser capazes de adaptarem-se às variações ambientais.

Os trabalhos mais conhecidos de Inteligência de Enxame são a otimização por colônia de formigas (DORIGO; GAMBARDILLA, 1997), algoritmo *shuffled frog-leaping* (EUSUFF; LANSEY; PASHA, 2005), algoritmos de colônias de bactérias (KIM; ABRAHAM; CHO, 2007), algoritmos de colônia de abelhas (PHAM et al., 2005) e otimização por enxame de partículas (KENNEDY; EBERHART, 1995), este último sendo a técnica abordada nesta dissertação. A Figura 22 ilustra alguns conceitos a respeito da inteligência de enxame.

Figura 22 – Capacidade da Inteligência de Enxame



Fonte: adaptado de Techferry (2016).

A Inteligência de Enxame pode ser considerada como um ramo da abordagem computacional, *Computação Natural*. Esta abordagem se caracteriza pela versão computacional do processo de extrair ideias da natureza no desenvolvimento de sistemas computacionais (CASTRO, 2005).

3.4.2 O PSO

A otimização por enxame de partículas, *Particle Swarm Optimization* (PSO), foi inicialmente proposta por James Kennedy e Russell Eberhart (KENNEDY; EBERHART, 1995), a princípio como um modelo para otimização de funções contínuas não-lineares. O PSO é uma metaheurística populacional criada a partir de modelos do comportamento coletivo e social dos animais, em sua coordenação de movimentos nas tarefas de busca e obtenção de alimentos (HEPPNER; GREANDER, 1990). Esses modelos foram simplificados, perdendo a exigência de se manter uma distância mínima entre seus vizinhos. Além disso, transformou-se a arquitetura de comunicação, a qual era inicialmente inspirada em proximidade espacial e foi alterada para usar uma topologia definida por um grafo. Assim sendo, o PSO acaba por possuir, atualmente, mais semelhanças com modelos de influência mútua entre seres humanos em suas formas de pensar e agir (KENNEDY, 1998).

No PSO existe uma quantidade fixa de agentes, denominados de partículas. A esse conjunto de agentes é dado o nome de enxame, projetado de tal forma que cada agente seja capaz de comunicar-se com o seu vizinho, o qual é um subconjunto de seu par, podendo ser definido de forma estática ou dinâmica. Cada uma das partículas movimenta-se no espaço de solução com uma determinada velocidade, sempre avaliando em cada iteração a solução correspondente àquela posição ocupada. A velocidade das partículas deve sofrer influências de sua própria experiência (fator cognitivo), e também influência de seus vizinhos (fator social). Tais influências são implementadas como dois atratores, o primeiro localizado na melhor posição já avaliada pela própria partícula e o segundo localizado na melhor posição visitada pelas partículas vizinhas.

Figura 23 – Estratégia de Movimentação das Partículas no PSO



Fonte: adaptado de Nedjah (2013).

A Figura 23 apresentou de forma geral, o modo de funcionamento do algoritmo PSO, as parcelas dos fatores cognitivo cognitivo e social, contribuindo para o deslocamento da partícula.

A partir desta dinâmica, resulta que o enxame, inicialmente disperso por todo o espaço de busca, começa a focar em algumas determinadas regiões que ofereçam melhores soluções já encontradas, mas sem perder a capacidade de realizar uma busca ampla no espaço (MELLO, 2010).

O algoritmo PSO, mesmo sendo uma metaheurística relativamente recente, conseguiu adquirir um certo espaço no meio científico, devido principalmente à sua simplicidade e poder de processamento computacional (POLI; KENNEDY; BLACKWELL, 2007). Apesar de outras técnicas de otimização, o PSO não requer informações do gradiente da função objetivo, necessitando somente de seus valores nos pontos avaliados e de operadores matemáticos bastante simples. Os paradigmas de inteligência de enxame levam a processos altamente distribuídos, com baixa dependência de indivíduos isolados, de forma que o PSO é um modelo de otimização relativamente robusto contra a atração exercida por regiões de baixa qualidade sobre os agentes (PARSOPOULOS; VRAHATIS, 2002).

3.4.3 Origem e Etimologia do PSO

Kennedy e Eberhart (KENNEDY; EBERHART, 1995), descreveram que a inspiração para o método deve-se ao comportamento cooperativo dos vários tipos de animais, como os enxames de abelhas, cardumes de peixes e revoadas de pássaros por exemplo.

A Figura 24 apresenta um exemplo do comportamento de um bando de animais, voo coordenado de uma revoada de pássaros.

Figura 24 – Voo coordenado de um bando de pássaros



Fonte: adaptado de Oberes (2013).

Ao elaborar várias simulações Reynolds (REYNOLDS, 1987), particularmente, mencionou a riqueza dos movimentos na revoada dos pássaros, admitindo que o resultado adquirido pelo bando advém da iteração entre os componentes. O sincronismo do voo é coordenado visando evitar colisões. Algum tempo depois, o zoologista Frank Heppener (HEPPNER; GRENANDER, 1990) e seus colaboradores, dentre eles Reynolds, interessados em descobrir as regras que permitem aos pássaros reunirem-se sincronicamente, dispersarem-se e reagruparem-se novamente, realizaram diversas simulações computacionais no plano xy com pássaros. Nessas simulações, os pássaros "sobreviviam" a área delimitada na tela do computador e com poucas iterações o bando inteiro se aglomerava dentro de um círculo mínimo que representava o local com oferta de alimento.

Além disso, os resultados satisfatórios apresentados pela equipe de Heppener, inspiraram-se no trabalho escrito por Wilson (WILSON, 1975), em que defendia que os membros individuais de um grupo podem lucrar com as descobertas e as experiências anteriores dos membros, durante a busca por alimento. Tal indicação sugere que o compartilhamento social da informação pode fornecer uma vantagem evolucionária: ideia fundamental ao desenvolvimento do PSO.

3.4.4 O Algoritmo PSO

O algoritmo PSO desenvolvido por Kennedy e Eberhart (KENNEDY; EBERHART, 1995), apresenta duas versões anteriores. Uma das versões é a *GBEST*, que possibilita a exploração global da região de busca, e outra versão, *LBEST*, que favorece a busca local. A atual versão do algoritmo PSO, presente neste trabalho, foi proposta por Shi e Eberhart (SHI; EBERHART, 1998), na qual introduz um novo parâmetro, o peso inercial (w).

No algoritmo, as partículas no espaço de solução viável são soluções em potencial do problema, em que, a cada uma delas está associada um valor de aptidão (*fitness*), uma função de avaliação, a qual é associada à função objetivo do problema de otimização. Cada partícula mantém o rastro de suas coordenadas no espaço de solução, que estão associadas ao melhor valor da função *fitness* que ela tenha encontrado até o momento, o chamado *pbest*. Além deste, outro valor também é rastreado, o melhor de todos os valores da função *fitness* da população de partículas; bem como a sua posição, obtido por qualquer uma das partículas da população. A este valor é dado o nome de *gbest*.

As partículas possuem uma velocidade randômica para que possa percorrer o espaço de solução de forma mais abrangente possível. A i -ésima partícula é representada por:

$$x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{in})$$

A melhor posição individual de cada partícula (*pbest*) é dada por:

$$p_i = (p_{i1}, p_{i2}, p_{i3}, \dots, p_{in})$$

A taxa de variação de posição, sua velocidade, é representada por::

$$v_i = (v_{i1}, v_{i2}, v_{i3}, \dots, v_{in})$$

As partículas são manipuladas de acordo com Shi e Eberhart (SHI; EBERHART, 1998) pelas seguintes equações:

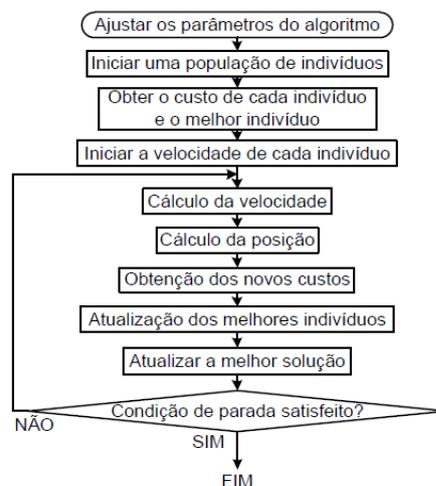
$$v_{id}^{k+1} = w * v_{id}^k + c_1 * r_1 * (pbest_{id} - x_{id}^k) + c_2 * r_2 * (gbest_d - x_{id}^k) \quad (20)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (21)$$

Onde:

- w : peso inercial, controla o impacto da velocidade prévia na atual velocidade;
- c_1 e c_2 : constantes positivas, controlam o comportamento social e individual de cada partícula, atraindo a partícula em direção à sua melhor posição histórica ($pbest$) e à melhor posição já ocupada pelo conjunto total de partículas ($gbest$). Tais fatores expressam a confiança que a partícula tem em si mesma e no próprio enxame;
- r_1 e r_2 : números randômicos no intervalo $[0,1]$, que de acordo com Trelea (TRELEA, 2003), contribuem para diversificar a exploração do espaço de busca do problema.

Figura 25 – Fluxograma do Algoritmo PSO



Fonte: adaptado de Andrade (2013).

O critério de parada do PSO, pode variar dependendo do objetivo do problema a ser escolhido; entre os critérios mais comuns, destacam-se :

- Número máximo de iterações. Esse critério possui um inconveniente de que o processo pode parar antes de chegar ao ótimo global;
- Limiar de erro - Pode-se usar apenas quando a solução do problema é conhecida *a priori*;
- Repetições excessivas do resultado final da função objetivo, no qual o algoritmo encontrou uma solução ótima ou quase ótima. Apesar das iterações continuarem, não se encontra um valor melhor para a solução do problema.

3.4.5 Controle dos Parâmetros no PSO

Para um melhor aproveitamento no funcionamento do algoritmo, Shi e Eberhart (SHI; EBERHART, 1998) sugerem a adoção dos valores $c_1=c_2=2$, a fim de manter um equilíbrio sobre a influência do aprendizado individual e social, no comportamento atual da partícula. Prado e Saramago (PRADO; SARAMAGO, 2005) dizem que alguns autores propõem valores diferentes para c_1 e c_2 , contanto que a soma desses valores seja 4 e que o peso inercial, w , seja escolhido em um intervalo de [0,7 a 1,4]. O peso inercial w permite uma maior diversidade na exploração do espaço de busca. Valores mais altos facilitam a busca global em novas regiões; em contrapartida, valores menores favorecem a busca local em uma região mais promissora. A boa escolha desses parâmetros favorecem um equilíbrio ao algoritmo entre suas habilidades, global e local de exploração.

Através de simulações, Shi e Eberhart (SHI; EBERHART, 1998) demonstraram que, fixados os outros parâmetros, pequenas alterações no valor de w pode ocasionar significativas alterações no número de alterações necessárias para a convergência do algoritmo dentro do número máximo de iterações pré-fixadas. Nestas mesmas simulações, notou-se também que valores adequados do peso inercial podem agilizar a convergência para a solução ótima, evidenciando o impacto deste parâmetro no algoritmo (GOMES, 2007).

Trelea (TRELEA, 2003) realizou vários testes com diferentes conjuntos de parâmetros na otimização de funções conhecidas na literatura, destacando que quanto maior for o número de partículas na população, menor será a quantidade de iterações necessárias para alcançar a solução do problema. Portanto, deve haver uma quantidade mínima de partículas para garantir maior varredura do espaço de busca, porém, sem elevar muito o custo da otimização (GOMES, 2007).

3.4.6 Aplicações PSO

Várias técnicas de otimização por PSO têm sido bastante investigadas na literatura. Um ramo de aplicação é o uso do PSO em modelos híbridos para auxiliar a melhoria de desempenho

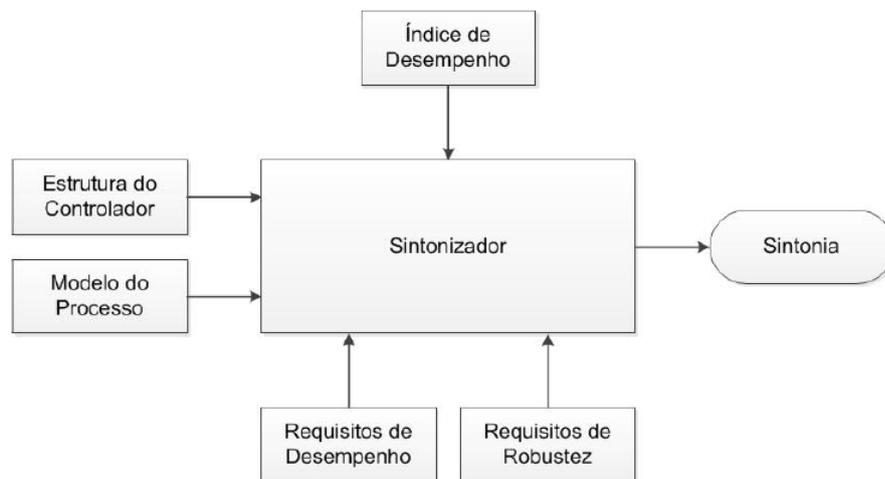
de outros métodos e algoritmos de otimização, como algoritmos genéticos (RU; JIANHUNA, 2008), redes neurais (BASHIR; EL-HAWARY, 2009), sistemas nebulosos (JUANG; WANG, 2009), evolução diferencial (WICKRAMASINGHE; LI, 2008) entre outros. Um outro ramo importante é a aplicação do PSO na resolução dos mais diversos problemas de engenharia: sintonização de controladores PID (GAING, 2004), controles robustos (H_2/H_∞) (THANH; PARNICHKUN, 2008), identificação de modelos (WANG et al., 2008), otimização de controle de potência reativa e tensão (ABIO, 2008), processamento de imagens (KWOK et al., 2008), processamento de sinais (XU; GAO, 2008), e modelagem de sistemas dinâmicos (ARAUJO et al., 2009).

4 Sintonização Aplicada

A metodologia principal adotada nesta dissertação é a realização da sintonia do controlador PI da malha de controle em um modelo computacional de tal maneira que este modelo reproduza o mais fielmente possível o sistema real modelado. O principal intuito desta metodologia é proporcionar um meio de sintonizar o controlador de maneira mais rápida e eficaz. Além disso, evitar o refinamento por tentativa e erro sem expor o sistema real a numerosos testes.

A malha do sistema do exaustor presente no LAMOTRIZ é totalmente controlada por meio de um CLP S7-300 da Siemens[®]. Nesse caso, a simples modelagem deste sistema de controle em modo contínuo, mais comumente utilizado em estudos, não será o suficiente para refletir todas as condições reais da dinâmica do processo, sendo então necessário um modelo digital que permita incluir as condições de funcionamento do sistema analógico/digital, de modo que os mesmos parâmetros resultantes da sintonia no modelo computacional possam ser diretamente empregados no controlador real. A Figura 26 apresenta a metodologia da sintonização ao controlador presente nesta dissertação.

Figura 26 – Metodologia Aplicada à Sintonização do Controlador por meio de IA



Fonte: adaptado de Godoy (2012).

Neste estudo, os passos da metodologia para a sintonização do controlador PI são os seguintes:

- Obtenção do modelo do processo;
- Determinação da estrutura do controlador a ser utilizado;
- Determinação dos requisitos e índices de desempenho e robustez do sistema controlado;

- Aplicação de técnicas de otimização baseadas em inteligência artificial.
- Validação dos resultados obtidos em ambiente computacional.
- Obtenção da melhor sintonia do controlador.
- Análise comparativa entre técnicas de sintonia utilizadas;
- Análise da eficiência energética da planta com o controle sintonizado.

4.1 Modelo do Processo

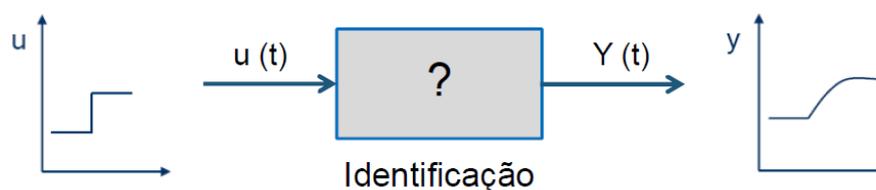
Para a obtenção da sintonia de um controlador para uma determinada planta, faz-se necessário ter um conhecimento sobre esta planta. Tal conhecimento é representado por meio de modelos.

Modelar é o princípio básico para qualquer análise de sistema, independentemente de suas características. Quando o modelo aproxima-se do sistema original, ele pode ser considerado como válido, ou seja, as informações que são significativas de sua dinâmica e desempenho podem ser obtidas pelo modelo. De acordo com Garcia (GARCIA, 2005), um modelo é uma aproximação do processo real, o qual não consegue incorporar por completo todas as características físicas do sistema real. Deve haver, no entanto, um compromisso entre o custo de se ter o modelo e o nível de detalhes do mesmo e os benefícios esperados por sua aplicação.

4.1.1 Identificação do Modelo do Processo

A identificação do modelo da planta, em termos de função transferência, foi realizada de maneira experimental. A partir de um conjunto de experimentos na bancada física do exaustor, foi possível obter pares de dados entrada-saída do sistema em malha aberta. A Figura 27 ilustra o processo de identificação utilizado; aplica-se um sinal de controle ao processo em malha aberta e, obtém-se a curva resposta do sistema.

Figura 27 – Processo de Identificação de Sistemas



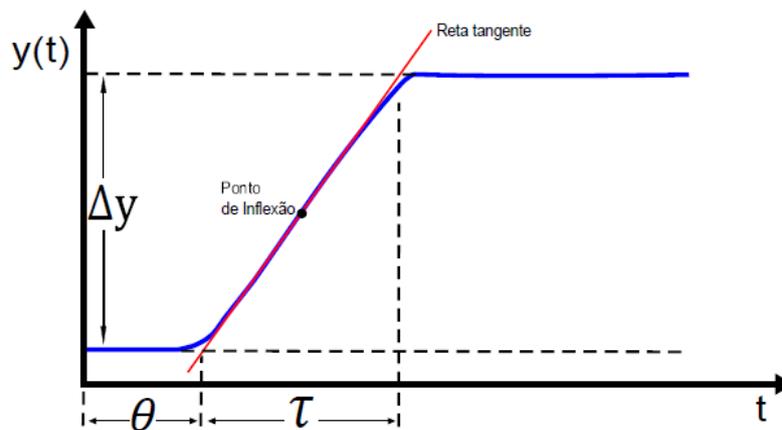
Fonte: próprio autor (2016).

Toda a análise realizada neste estudo se concentrou no controle da vazão através do inversor de frequência do qual o sinal de entrada do processo é um determinado valor de

frequência no motor, regulada pelo inversor de frequência; devido ao fato de que o valor de frequência motor é fornecido pelo sistema supervisor. O sinal de saída do sistema é a vazão de ar no duto de saída do exaustor. Desta maneira, de acordo com essa característica de resposta dinâmica do sistema é possível aproximar o sistema físico da bancada por um sistema dinâmico de primeira ordem com atraso, onde o modelo matemático tem a característica apresentada na equação 14 reescrita a seguir:

$$G_p(s) = \frac{K}{\tau s + 1} e^{\theta s} \quad (14)$$

Figura 28 – Resposta do processo de primeira ordem em malha aberta



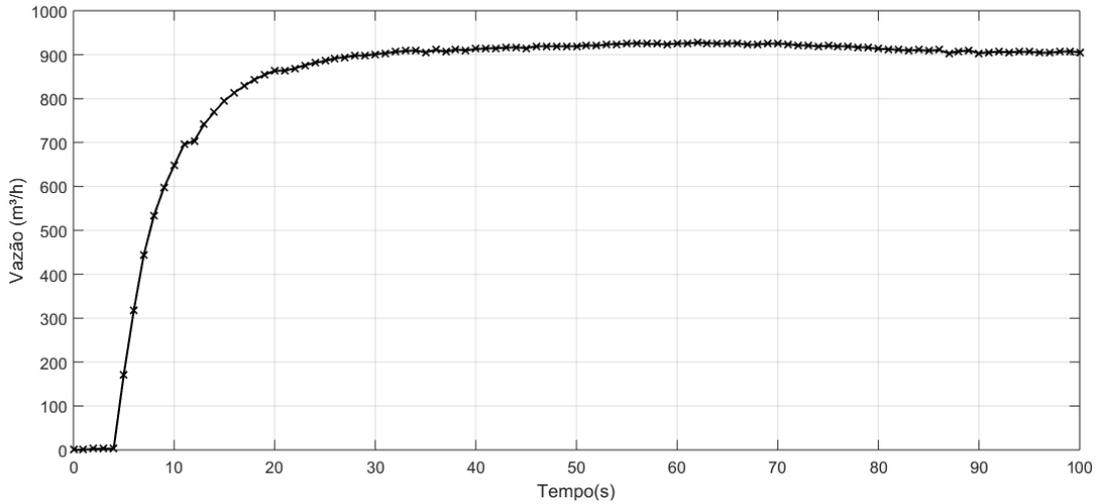
Fonte: adaptado de Gomery (2014).

Os parâmetros da equação 14 são obtidos a partir curva apresentada na Figura 28. Existe na literatura de controle de processos uma variedade de métodos matemáticos para a identificação da planta, baseados na resposta do processo ao degrau. Entre eles estão o método de Ziegler e Nichols (ZIEGLER; NICHOLS, 1942) e o método de Smith os quais são abordados nesta dissertação; além desses, existem os métodos computacionais iterativos os quais podem ser implementados por meio de ferramentas computacionais como o MATLAB[®], Fortan[®] e SPLUS[®]. O melhor método considerado será aquele que mais se aproximar da curva original.

Por meio do sistema supervisor, a planta do sistema foi configurada em modo de malha aberta e, a partir disso, realizou-se um experimento para a identificação da mesma. Aplicando-se um degrau de frequência de 41 Hz no inversor de frequência, que comanda o motor de indução da bancada, obteve-se como saída os valores de vazão do exaustor. Os dados de saída foram obtidos por meio dos sensores instalados na planta e que estão em comunicação com o sistema supervisor com intervalos de 1s, tempo de amostragem do supervisor; com o auxílio da ferramenta computacional MatLab[®] foi possível criar o gráfico dos valores de saída da vazão em relação ao tempo, bem como encontrar os pontos na curva necessários à obtenção do valores

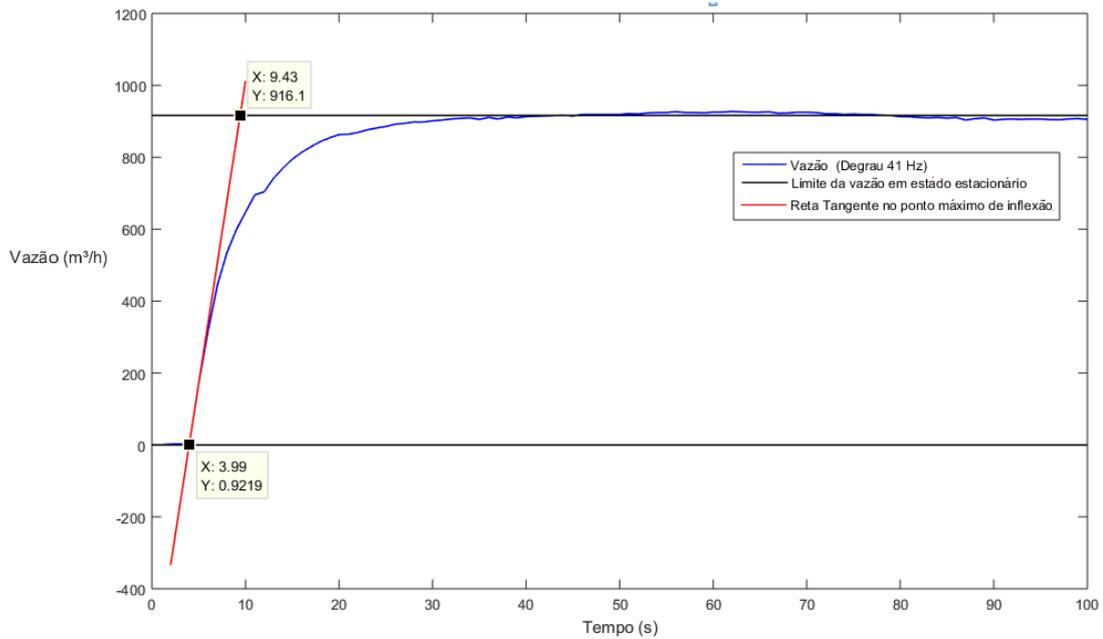
de τ e θ . A Figura 29 demonstra o resultado da aplicação do degrau de 41 Hz em malha aberta ao sistema da bancada, permitindo o cálculo dos parâmetros da função de transferência, a Figura 30 demonstra a obtenção do ponto máximo de inflexão da curva resposta.

Figura 29 – Curva de Resposta da Vazão do Sistema em Malha Aberta devido à Aplicação de um Degrau de 41 Hz.



Fonte: próprio autor (2016).

Figura 30 – Tangente no Ponto Máximo de Inflexão da Curva da Vazão



Fonte: próprio autor (2016).

Baseado no método de Ziegler Nichols e pela observação dos pontos destacados na curva tangente, é possível obter os parâmetros da equação de primeira ordem com tempo morto que definem o sistema, por meio das seguintes equações:

$$K = \frac{\Delta y}{\Delta u} = \frac{916,46}{41} = 22,35 \quad (22)$$

$$\theta = 3,99s$$

$$\tau = 9,43 - \theta = 5,44s \quad (23)$$

De acordo com Smith, os valores de τ e θ devem ser selecionados de tal modo que o modelo e as respostas reais coincidam em dois pontos na região da mais elevada taxa de mudança. Basicamente, nesse método deve-se conhecer os tempos t_1 e t_2 , em que estes valores de tempo representam 23,8% e 63,5% do valor final do estado estacionário (Δy) respectivamente. De posse desses valores aproximados, obtidos graficamente, aplicam-se as equações de Smith para encontrar os parâmetros τ e θ .

$$\tau = 1,5 * (t_2 - t_1) = 1,5 * (8,72 - 5,62) = 4,65s \quad (24)$$

$$\theta = t_2 - \tau = 8,72 - 4,65 = 4,07s \quad (25)$$

Semelhantemente ao método de Smith, o método de Sundaresan e Krishnaswamy, também se utiliza de dois tempos, t_1 e t_2 , representando 35,3% e 85,3% do valor final do estado estacionário (Δy) respectivamente. A partir disso, determinam-se τ e θ pelas seguintes equações:

$$\theta = 1,3 * (t_1 - 0,29 * t_2) = 1,3 * 6,04 - 0,29 * 14,45 = 3,66s \quad (26)$$

$$\tau = 0,67 * (t_2 - t_1) = 0,67 * (14,45 - 6,04) = 5,63s \quad (27)$$

Por fim, utilizando o pacote de ferramentas de identificação de sistemas do software MATLAB[®], foi possível obter K , τ e θ de forma iterativa, a partir dos dados do experimento do degrau de 41 Hz, obtendo como resultado:

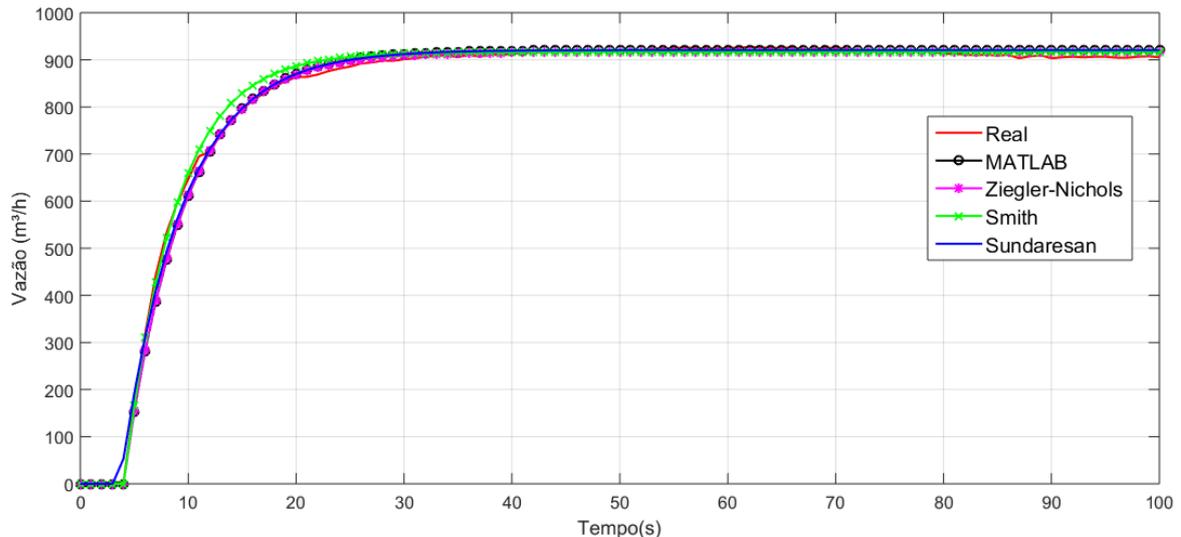
$$K = 22,46$$

$$\theta = 4 \text{ s}$$

$$\tau = 5,5 \text{ s}$$

Finalmente, a escolha dos melhores valores de K , τ e θ , deu-se por meio de simulação computacional. Diferentes funções de transferências com os valores obtidos foram utilizadas para obter a resposta ao mesmo degrau de 41 Hz, as respostas foram comparadas entre o valor real de saída da vazão do exaustor, de acordo com a Figura 31.

Figura 31 – Comparação entre Diferentes Métodos de Identificação de Sistemas para um Degrau de 41 Hz.



Fonte: próprio autor (2016).

É possível observar que os métodos de identificação de sistemas possuem respostas muito parecidas entre si e muito próximas ao valor real, significando que não haverá tanta alteração no modelo matemático entre si; foram avaliadas outras velocidades, obtendo praticamente resultados parecidos. Neste trabalho trata de sintonização de controlador, é necessário escolher o mais próximo possível do valor real; mesmo com pouca diferença, o método iterativo do MATLAB[®] foi o que obteve a melhor aproximação, conclusão essa obtida por meio da observação visual dos diferentes métodos; a função de transferência de primeira ordem com tempo morto que reproduz o sistema real é a seguinte:

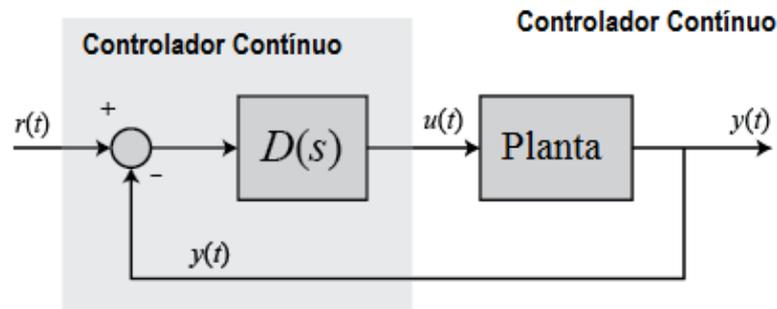
$$G_p(s) = \frac{22.46}{5.5s + 1} e^{-4s} \quad (28)$$

4.1.2 Modelo Digital

Embora a maioria das técnicas dos projetos de controladores sejam feitas em tempo contínuo, sua implementação dá-se em formato digital, no qual estará sujeita a efeitos de discretização e quantização. Estes efeitos devem ser considerados na sintonia do controlador, uma vez que afetam de maneira significativa o comportamento do controlador (GODOY, 2012).

Como o objetivo desta dissertação é a exploração dos ganhos em eficiência energética no modelo real do sistema de controle, faz-se necessária a implementação digital dos mesmos. A Figura 32 ilustra uma planta de processo em malha fechada em sistema contínuo.

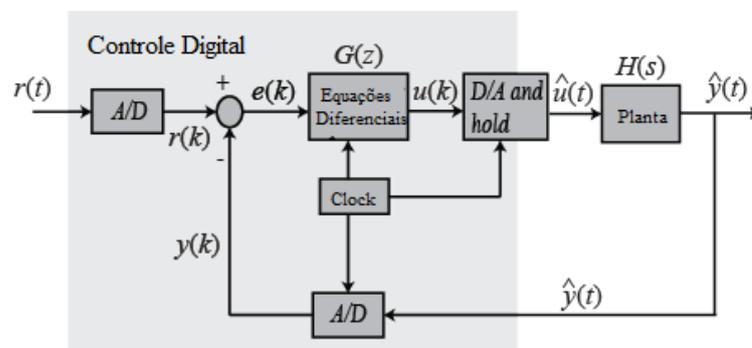
Figura 32 – Planta do Processo com Controle Contínuo.



Fonte: adaptado de Michigan (2014).

O controlador em tempo contínuo pode ser substituído por um controlador digital, executando a mesma tarefa de controle. A grande diferença está no que diz respeito aos sinais de controle do discreto, que trabalha com amostras do sinal detectado em determinado tempo, em vez de sinais contínuos. A Figura 33 apresenta uma planta de processo em malha fechada com um controlador digital; substituindo o controlador contínuo apresentado anteriormente na Figura 32.

Figura 33 – Planta do Processo com Controle Digital.



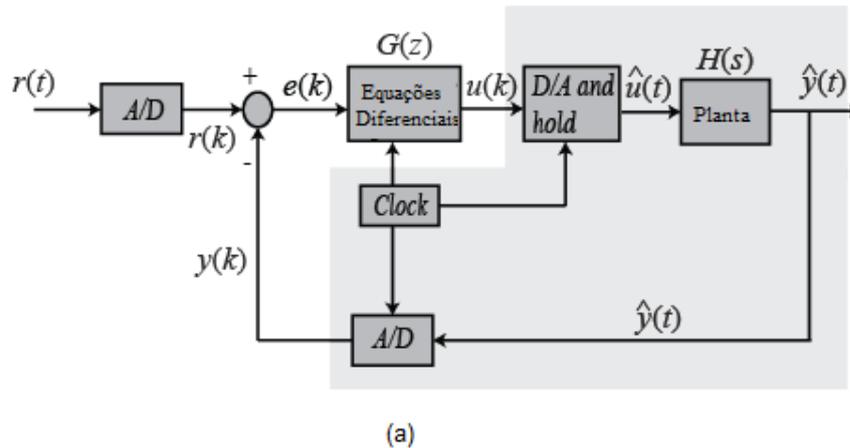
Fonte: adaptado de Michigan (2014).

Ao projetar um sistema de controle digital, é necessário encontrar o equivalente discreto da porção contínua, de modo que só precise lidar com funções discretas.

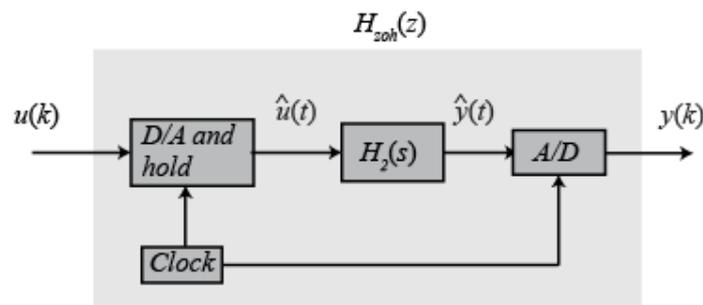
Considerando uma parte do sistema (saída do controlador e a planta contínua); reorganizando esta de acordo com a técnica de discretização *Zero-Order-Hold*, obtém-se uma correspondência aproximada entre os sistemas contínuos e discretos. Essa parte da metodologia

é muito importante, uma vez que a dinâmica real do processo é influenciada pelas taxas de amostragem dos dados. As Figuras 34(a) e 34(b) a seguir ilustram o processo de discretização da função transferência pelo método *Zero-Order-Hold*.

Figura 34 – Equivalência do Processo Contínuo-Digital em uma Malha de Controle.



(a)



(b)

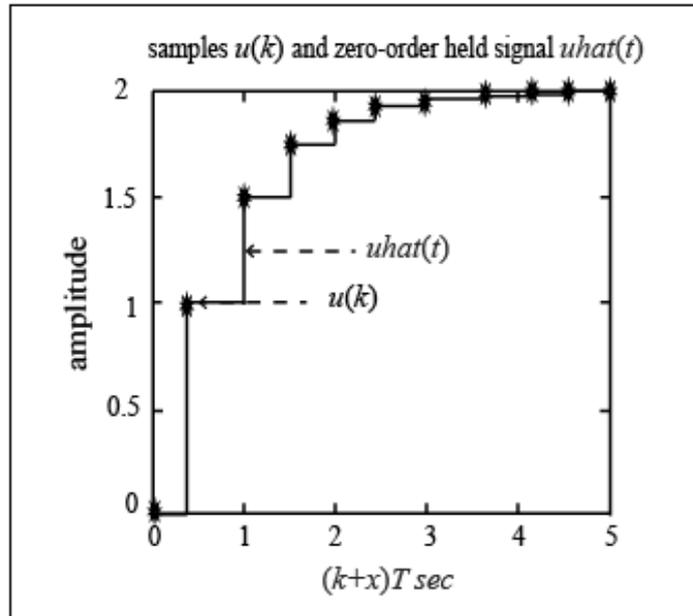
Fonte: adaptado de Michigan (2014).

Deseja-se encontrar uma função discreta $H_{zoh}(z)$ de modo que para partes de uma entrada constante ao sistema contínuo $H(s)$, a saída amostrada do sistema contínuo seja tão próxima quanto possível da saída discreta. Como exemplo, seja um sinal $u(k)$ representando uma amostra do sinal de entrada, há técnicas que tomam esta amostra $u(k)$, e a mantêm para produzir um sinal contínuo de saída $u_{hat}(t)$. O sinal $u_{hat}(t)$ é mantido constante em $u(k)$ ao longo do intervalo de $t=kT$ a $t=(k+1)T$ (MICHIGAN, 2014).

No tocante à escolha do período de amostragem, esta pode ser afetada por vários fatores, entre os quais os mais relevantes são: o critério de controle, valores exigidos da variável controlada e mudanças nessa variáveis; a dinâmica do sistema controlado, caracterizada pelo valor do tempo de atraso, por exemplo; exigências sobre a intervenção do operador, limitando o seu período máximo (KAGUEYAMA, 2011). As Figuras 35 e 36 apresentam um resumo do

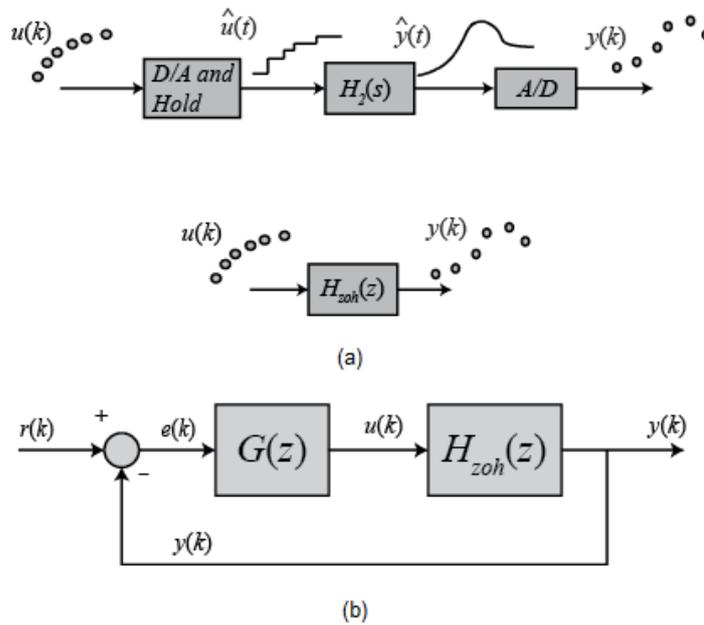
processo *Zero-Order-Hold*, incorporando à função de transferência os processos de conversões analógico-digital e digital analógico .

Figura 35 – Processo Zero-Order-Hold.



Fonte: adaptado de Michigan (2014).

Figura 36 – Equivalência entre $H(s)$ e $H_{zoh}(z)$



Fonte: adaptado de Michigan (2014).

Com o objetivo de encontrar o modelo digital da parte linear da função de transferência do sistema descrito da equação 30, utilizou-se o comando *c2d* (*continuous to discrete*) em ambiente MATLAB[®] para aplicar o método *Zero-Order-Hold* a essa equação.

Uma importante observação é a respeito da taxa de amostragem escolhida para a discretização da função de transferência de tempo contínuo. Nesta dissertação, o tempo de amostragem escolhido para a função discreta foi de 1 segundo; esta escolha deu-se devido principalmente à dinâmica de reação da planta, uma vez que os sensores de vazão da saída do sistema de exaustação em análise fornecem dados aproximadamente neste intervalo de tempo.

Uma escolha errônea no tempo de amostragem de $H_{zoh}(z)$ acarretará em erros significativos, pois diferentemente do sistema contínuo, o sistema discreto realiza as operações em intervalos de tempo da taxa de amostragem, significando que haverá perdas de informações ou até sobre sinais de erro (MICHIGAN, 2014). A função de transferência em tempo discreto referente à equação 30, obtida pelo método *Zero-Order-Hold* com 1 segundo de amostragem é dada por:

$$H(z) = \frac{3.773}{z - 0.338} \quad (29)$$

4.2 Sistema de Controle

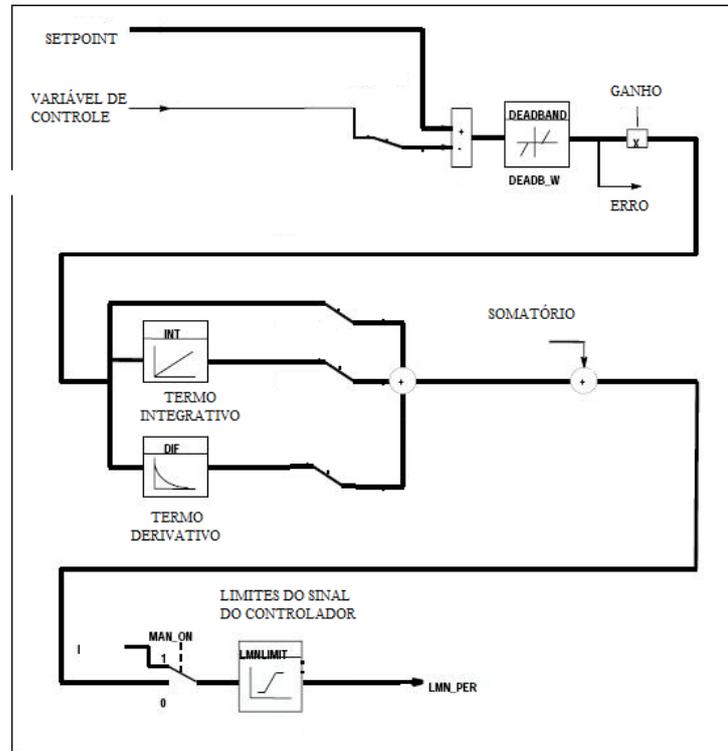
A busca pelo modelo computacional da malha de controle mais fidedigno ao do sistema real permite realizar estudos mais eficazes por meio de simulações que apresentem valores próximos dos resultados reais.

Por meio de simulação da malha de controle é possível variar os parâmetros de sintonia do controlador e simular o processo para cada uma das sintonias testadas, determinando-se desta maneira a resposta esperada da planta e podendo-se utilizar esta resposta, ou índices calculados sobre esta resposta, neste procedimento de otimização.

4.2.1 Estrutura do Controlador

A estrutura do controlador utilizado nos experimentos reais da bancada do protótipo de exaustor será o do tipo PID ideal, visto que todo o processo é controlado por um PLC Siemens[®] modelo S7-300 e este tipo de controlador, PID ideal, está implementado de fábrica através de um grupo de funções denominado FB41 (*Standard PID Control*), o que facilita a implementação no sistema de controle real. A Figura 37 apresenta o controlador PID implementado no CLP da bancada; são apresentadas as entradas (*setpoint* e variável de controle para formarem o erro), os respectivos ganhos P, I e D; bem como alguns limites operativos.

Figura 37 – Diagrama de Blocos do Controlador Standard PID Control Siemens®.



Fonte: adaptado de Siemens (2003).

Como abordado anteriormente no capítulo 2 desta dissertação, o algoritmo PID da Siemens® no formato discreto (digital) é dado de acordo com a equação 13:

$$u(k) = K_p(e(k) + \frac{T_s}{T_i} \sum_{i=1}^k e(i) + \frac{T_d}{T_s}(e(k) - e(k-1))). \quad (13)$$

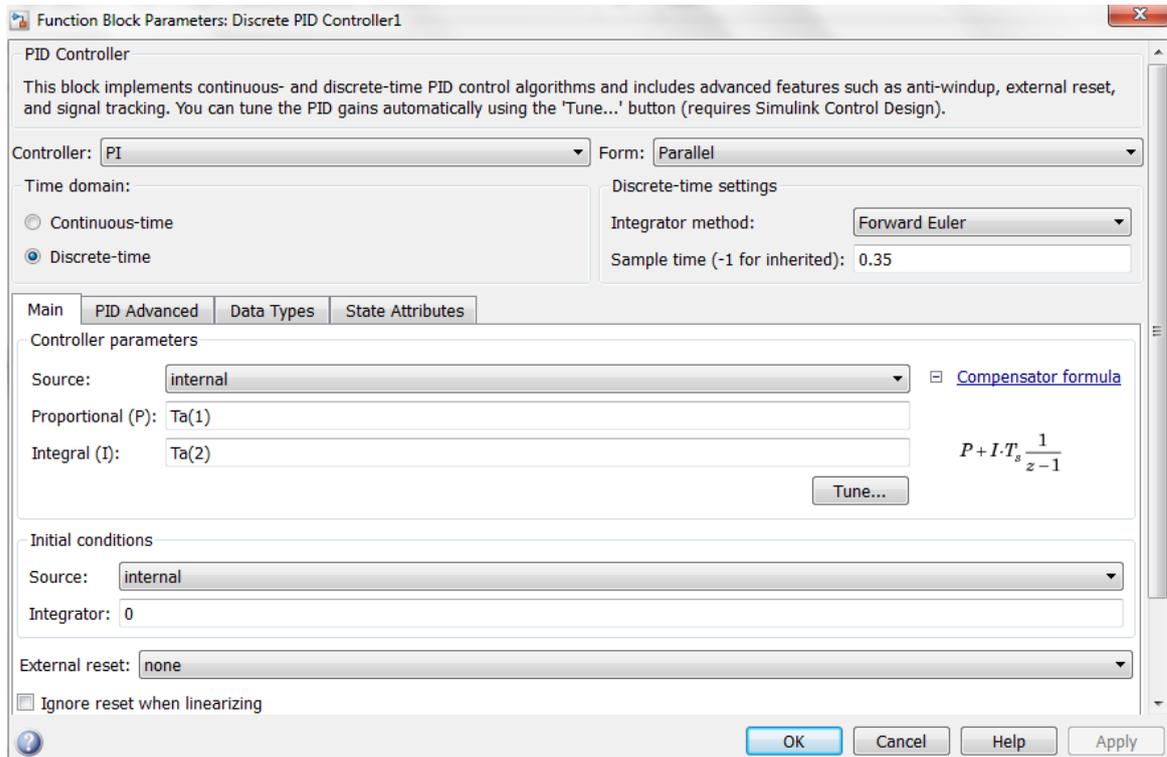
No entanto, a estrutura de controle escolhida foi a PI (Proporcional e Integral), devido principalmente aos inconvenientes da parte derivativa do algoritmo PID, os quais foram abordados anteriormente; assim a equação assume a seguinte forma:

$$u(k) = K_p(e(k) + \frac{T_s}{T_i} \sum_{i=1}^k e(i)). \quad (30)$$

A equação do algoritmo PI (equação 32), por si só não retrata as condições reais de funcionamento inerentes ao controlador implementado no PLC Siemens® S7-300, sendo necessária a adição de algumas características restritivas. Com o objetivo de retratar melhor as condições reais do controlador em ambiente de simulação, bem como facilitar sua implementação computacional, utilizou-se na modelagem da estrutura do controlador PI a biblioteca SIMULINK

do MATLAB[®], o bloco *Discrete PID Controller*. Este bloco permite a configuração de alguns parâmetros do controlador PI discreto a ser simulado computacionalmente de acordo com a necessidade da planta e o objetivo necessário. A Figura 38 apresenta o bloco do controlador PID discreto utilizado para as simulações deste trabalho.

Figura 38 – Bloco PID Discreto da Biblioteca SIMULINK MATLAB[®].



Fonte: adaptado de SIMULINK MATLAB[®] (2015).

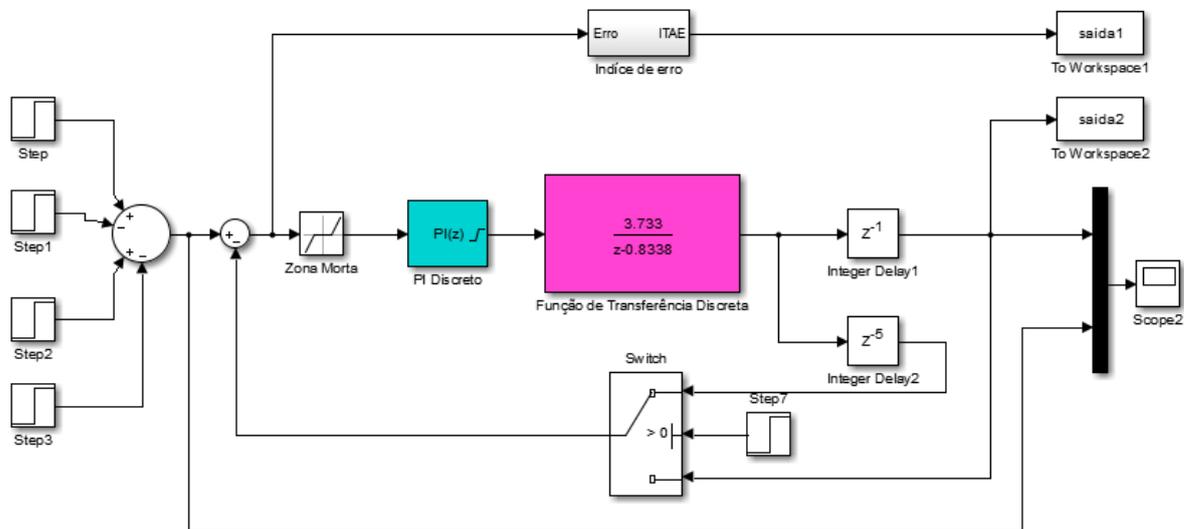
Nesta dissertação, os parâmetros Proporcional e Integral são as variáveis $Ta(1)$ e $Ta(2)$ respectivamente, as quais desejam-se encontrar por meio das técnicas de otimização inteligente propostas. O parâmetro *Sample Time*, foi definido em 0,35s; representando a velocidade de processamento e atualização das variáveis dentro do controlador PI, simulando o CLP, este valor também foi configurado no CLP real; este valor foi obtido de maneira experimental por meio dos experimentos na bancada.

Além destes parâmetros, outros também importantes foram definidos, como os limites das variáveis de entrada, definidas em 6,5 Hz e 41 Hz, tal como estão os limites reais de segurança no protótipo do exaustor, e por fim, o sistema *anti-windup* foi habilitado, o qual foi abordado no capítulo 2 desta dissertação.

4.2.2 Malha de Controle

A modelagem da função de transferência, o controlador PI e os respectivos elementos da malha de controle em SIMULINK[®] é apresentada na Figura 39.

Figura 39 – Malha de Controle em SIMULINK[®] Representando o Protótipo do Exaustor no LEEQE



Fonte: próprio autor (2016).

A principal simulação da malha de controle do exaustor ocorrerá a partir da aplicação de quatro degraus (*Steps*) de referência para vazão de ar na saída do processo, na seguinte ordem: $800 \text{ m}^3/\text{h}$, $400 \text{ m}^3/\text{h}$, $800 \text{ m}^3/\text{h}$ e $400 \text{ m}^3/\text{h}$. Esses degraus de referência serão aplicados em intervalos de tempos iguais de 2 minutos cada, simulando assim um padrão de funcionamento do exaustor.

Um bloco *Zona Morta* foi acrescentado à simulação pelo fato de também estar no algoritmo controlador PID da Siemens[®]. Seu efeito é o de produzir uma faixa do sinal de controle em que não há ganho no sistema; nesta simulação a faixa utilizada foi entre $-0,5$ a $0,5 \text{ m}^3/\text{h}$ do valor de referência do sinal de entrada. Além disso, foi necessário acrescentar dois *delays* de tempos diferentes, um no instante do primeiro degrau de entrada com 1 unidade de tempo devido à inércia inicial do sistema ser diferente, o outro delay de 5 unidades de tempo foi utilizado para o restante da simulação. Estes delays finais foram obtidos de forma empírica, a partir da observação das simulações e experimentos em bancada, tomando como ponto inicial de análise o atraso no tempo, obtido pelo método do degrau.

4.3 Avaliação do Desempenho da Malha de Controle

A qualidade do comportamento de uma malha de controle pode ser indicada por meio de um índice de desempenho, através do qual se torna possível realizar uma avaliação quantitativa do sistema. Assim, é possível comparar diferentes tipos de controladores para uma mesma malha de controle, bem como analisar diferentes sintonias para um mesmo controlador em uma

determinada planta de controle, sendo este último caso um dos objetivos desta dissertação.

Um ou mais requisitos de desempenho podem ser utilizados para compor o índice de desempenho do sistema, o qual servirá como a função objetivo (*fitness*) do problema de otimização utilizado na obtenção da sintonia do controlador. Os requisitos de desempenho e robustez funcionam como restrições na sintonia do controlador, ou seja, permitem impor limites ao comportamento da malha de controle. O índice de desempenho para ser útil ao problema deve ser composto por parâmetros do sistema, além de que, deve ser computado com certa facilidade, analiticamente ou experimentalmente (OGATA, 2003).

Neste trabalho, a otimização do problema de sintonia teve como objetivo a minimização do índice de desempenho do sistema de controle avaliado, de tal forma a obter os melhores parâmetros do algoritmo do controlador PI. A seguir são apresentados os requisitos de desempenho utilizados:

4.3.1 Requisitos de Desempenho Baseados na Resposta ao Degrau

Um dos meios mais comuns de especificar os requisitos de desempenho da avaliação de um controlador é baseado na resposta ao degrau do sistema. Os principais índices associados à resposta ao degrau, empregados para determinar os requisitos de desempenho são:

a) Tempo de Subida (Rise Time)

O tempo de subida (*Rise Time*), t_r , é o tempo para a resposta ao degrau do sistema atingir aproximadamente 90% do valor de estado estacionário. Esse requisito tem por objetivo garantir uma boa velocidade de resposta do controlador. Contudo, a redução do tempo de subida até um certo ponto implica o aumento direto do tempo de acomodação e no sobressinal da resposta (OGATA, 2003).

b) Tempo de Acomodação (Settling Time)

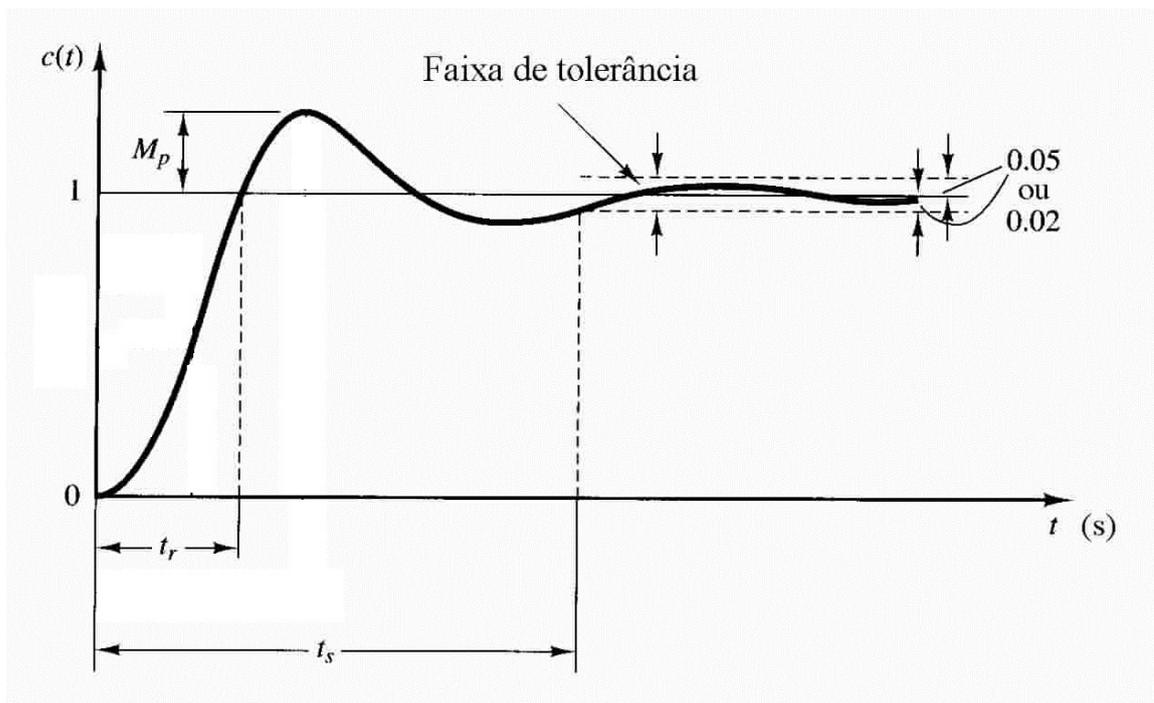
O tempo de acomodação (*Settling Time*), t_s , é o tempo mínimo a partir do qual a resposta permanece aproximadamente em 5% do valor de estado estacionário. Esse tempo t_s pode ser considerado um dos mais importantes requisitos de desempenho de controladores, pois determina o tempo em que a planta estabiliza no valor desejado (OGATA, 2003).

c) Sobressinal (Overshoot)

O sobressinal (*Overshoot*), M_p , é o ponto mais elevado em que a resposta em estado transitório do sistema alcança; geralmente expressa-se este valor em relação à amplitude do valor do grau. O objetivo desse requisito de desempenho é o de garantir que o valor da saída do processo não ultrapasse um determinado valor desejado acima do degrau do sinal aplicado, o que poderá acarretar problemas ou até mesmo danos ao sistema (OGATA, 2003).

A Figura 40 apresentou a forma típica da resposta de um sistema de primeira ordem em

Figura 40 – Parâmetros da resposta padrão a um degrau unitário de um sistema em malha fechada



Fonte: adaptado de Ogata (2003).

malha fechada a um degrau na entrada do processo.

4.3.2 Requisitos Baseados na Integral do Erro

Os critérios baseados em função da integral do erro do sistema compõem uma forma mais clássica de avaliação do desempenho de uma malha de controle, além dos parâmetros da resposta transitória ao degrau do sistema (OGATA, 2003). Os índices de desempenho baseados na integral do erro são:

a) Integrated Squared Error (ISE)

Este índice apresenta pouca seletividade, apresentando pequenas ponderações para pequenos erros e grande ponderações para erros maiores, portanto, não sendo ideal para uma sintonia PID. Além disso, uma outra desvantagem desse índice é a de quantificar em maior escala os erros iniciais que possam ocorrer em sistemas oscilatórios, sendo mais indicado para malhas características menos oscilatórias (PINTO, 2014). O ISE é obtido por:

$$ISE = \int_0^T e(t)^2 dt. \quad (31)$$

b) Integrated Absolute Error (IAE)

Um dos índices mais utilizados devido, principalmente, a bons resultados experimentais de implementação computacional. Um sistema projetado a partir deste critério tem como característica um amortecimento razoável, isto é, apresenta uma boa resposta transitória, e sobressinal não muito oscilatória. O IAE é calculado por:

$$IAE = \int_0^T |e(t)| dt. \quad (32)$$

c) Integrated Time Squared Error (ITSE)

Este critério apresenta uma melhor seletividade do que o critério ISE em relação à identificação dos parâmetros do PID, sendo portanto melhor para aplicação de sintonia do controlador. Durante a resposta ao degrau, este critério realiza uma ponderação do erro inicial com peso baixo, ao passo que os erros ocorrerem mais tarde na resposta transitória serão bastante penalizados. O ITSE é computado por:

$$ITSE = \int_0^T t e(t)^2 dt. \quad (33)$$

d) Integrated Time Absolute Error (ITAE)

A característica do sistema desenvolvido a partir deste critério é o de apresentar na resposta transitória um pequeno sobressinal, além de produzir oscilações bem amortecidas. Este critério tem uma característica mais seletiva de parâmetros do controlador PID. Desta maneira, apresenta uma melhora em relação ao índice de IAE. Pode-se obter o ITAE por:

$$ITAE = \int_0^T t |e(t)| dt. \quad (34)$$

Em relação à análise dos sistemas de controle discretos, as integrais devem ser expressas em forma de somatório e o erro em função do erro discreto $e(k)$. A Tabela 8 apresenta os índices de erro em tempo discreto:

Tabela 8 – Índices de Desempenho Baseados na Integral do Erro no Modelo Discreto.

Controlador	Modelo Discreto
ISE	$\sum_{k=1}^N e^2(k)$
IAE	$\sum_{k=1}^N e(k) $
ITSE	$\sum_{k=1}^N k e^2(k)$
ITAE	$\sum_{k=1}^N k e(k) $

Fonte: adaptado de Pinto (2014).

A partir dos vários índices e requisitos de avaliação e desempenho da malha de controle vistos nesta seção, foi possível modelar a função *fitness* que melhor correspondesse ao objetivo

do problema de sintonia, resultando em um melhor controle da planta do processo, a partir dos parâmetros identificados do controlador PI pela minimização dessa função objetivo. A função objetivo do problema (J) não será composta por apenas um índice de desempenho, mas por uma função que pondere índices compostos. Esta é uma avaliação clássica para problemas de avaliação e otimização quando há múltiplos aspectos relevantes (GODOY, 2012).

Nesta dissertação os múltiplos índices de desempenho escolhidos e suas respectivas ponderações que compõem a função objetivo do problema de otimização da sintonia do controlador PI ocorreu de forma analítica e experimental, baseados no conhecimento do problema. A saber, os índices são: t_r , t_s , M_p e IAE. Os pesos da equação foram obtidos de maneira empírica de acordo com resultados de simulações. A função objetivo do problema é dada de acordo com a seguinte equação:

$$J(k) = \sum_{k=1}^N |e(k)| + 1000 * M_p + 500 * t_r + 500 * t_s, \quad (35)$$

Em que:

M_p	-	Overshoot
t_r	-	Tempo de Subida
t_s	-	Tempo de Estabilização

4.4 Aplicação da Técnica de Otimização a Sintonia PI

Nesta parte da dissertação será abordado o algoritmo de otimização inteligente PSO adaptado ao problema da sintonia do controlador PI em modo discreto, de modo que os resultados obtidos por meio das simulações sejam equivalentes ou muito próximos ao do processo real em questão.

Como visto anteriormente, os dados de saída das simulações realizadas neste âmbito do trabalho em ambiente computacional SIMULINK[®] (t_r, t_s, M_p e ITAE) serão os valores de entrada da função objetivo J a ser minimizada pelo algoritmo de otimização PSO abordado nesta dissertação.

4.4.1 PSO Adaptado ao Problema de Sintonia PI

O algoritmo PSO trabalha com um conjunto de partículas (população), candidatas à solução do problema de otimização. As posições e velocidades das partículas são armazenadas nas matrizes X e V respectivamente. A primeira e segunda colunas da matriz X é composta pelos ganhos K_p e K_i respectivamente, a terceira corresponde ao valor da função objetivo associado a esses parâmetros. As matrizes são atualizadas a cada iteração e as melhores posições ocupadas

(*pbest*) são armazenadas na matriz *P*. A melhor das posições em *P* é armazenada no vetor *G*, melhor posição global (*gbest*). Ao atingir o critério de parada estabelecido no algoritmo, o vetor *G* será a solução do problema de otimização, ou seja, a solução ótima ou quase ótima da função objetivo *J*. O critério de parada adotado foi o número máximo de iterações, 50 iterações; de maneira que evite-se uma convergência prematura.

$$\mathbf{X} = \begin{bmatrix} K_{p1} & K_{i1} & J_1 \\ K_{p2} & K_{i2} & J_2 \\ \vdots & \vdots & \vdots \\ K_{pn} & K_{in} & J_n \end{bmatrix} \quad \mathbf{V} = \begin{bmatrix} v(K_{p1}) & v(K_{i1}) \\ v(K_{p2}) & v(K_{i2}) \\ \vdots & \vdots \\ v(K_{pn}) & v(K_{in}) \end{bmatrix}$$

$$\mathbf{P} = \begin{bmatrix} Pbest(K_{p1}) & Pbest(K_{i1}) & Pbest(J_1) \\ Pbest(K_{p2}) & Pbest(K_{i2}) & Pbest(J_2) \\ \vdots & \vdots & \vdots \\ Pbest(K_{pn}) & Pbest(K_{in}) & Pbest(J_n) \end{bmatrix}$$

$$\mathbf{G} = \begin{bmatrix} Gbest(K_p) & Gbest(K_i) & Gbest(J) \end{bmatrix}$$

Na formulação matricial do algoritmo PSO aplicado ao problema desta dissertação, as linhas representam as iterações, as colunas os respectivos parâmetros de cada iteração.

A condição de parada adotada neste problema é o número máximo de iterações. O algoritmo de implementação PSO adaptado à solução do problema tratado, pode ser descrito pelos seguintes passos:

1. Inicie a posição e a velocidade associada das partículas de forma aleatória dentro dos limites laterais estabelecidos;
2. Calcule a aptidão de cada uma das partículas por meio da função objetivo *J*;
3. Determine a melhor posição já ocupada pela partícula (*Pbest_i*);
4. Determine a melhor posição do enxame (*Gbest*);
5. Se $J_i < Pbest(J_i)$, então substitua *Pbest_i* pela atual posição da partícula;
6. Se $Pbest(J_i) < Gbest(J)$, então atualize o *Gbest* com o atual *Pbest_i*;
7. Atualize a velocidade das partículas de acordo com a equação:

$$v_{id}^{k+1} = w * v_{id}^k + c_1 * r_1 * (pbest_{id} - x_{id}^k) + c_2 * r_2 * (gbest_d - x_{id}^k)$$

8. Atualize a posição da partícula de acordo com a equação:

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1}$$

9. Repita as etapas 2-8 até que um dos critérios de parada seja alcançado;
10. Mostre a solução do problema : o vetor G .

5 Resultados e Discussões

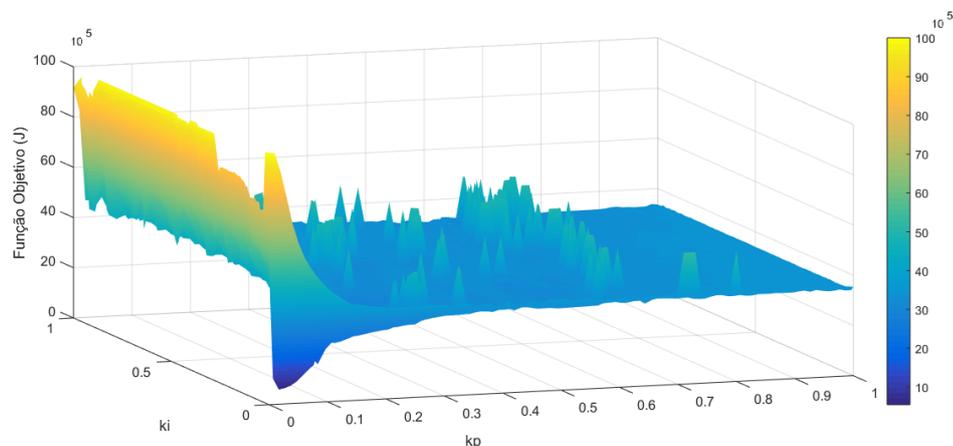
Nesta seção são apresentados os resultados das sintonias do controlador PI, assim como os de algumas das sintonias clássicas mais comuns e a consequente melhora neste processo de sintonia, obtida pela aplicação da metaheurística PSO. Os resultados adquiridos das sintonias do controlador PI, por meio de simulação, serão comparados com os do processo real na bancada do exaustor industrial. Além disso, alguns resultados acerca da eficiência energética do processo de controle com o controlador PI sintonizado serão avaliados.

5.1 Região do Espaço de Busca da Solução

Nos processos de otimização, na maioria dos casos, um conhecimento prévio do espaço de busca das soluções fornece uma melhora no desempenho da busca pela solução, aumentando assim, a probabilidade de encontrar-se a solução ideal ou aproximadamente ideal do problema analisado. No que se refere ao problema de sintonia PI, fruto de interesse desta dissertação, o controlador é bastante sensível aos parâmetros K_p e K_i , ou seja, pequenas variações nestes parâmetros acarretam mudanças evidentes na saída do controlador. A análise prévia do controlador PI na malha de controle, evidenciou que ambos os parâmetros K_p e K_i estão situados em regiões de pequenos valores entre $[0,1]$, de tal forma que o sistema de controle funcione de maneira aceitável.

Por meio de simulação, foi possível obter e reproduzir a região de interesse da busca pela solução da função objetivo (J) do problema de otimização limitada entre $[0,1]$. Tal região está apresentada na Figura 41.

Figura 41 – Espaço das soluções da Função Objetivo J da Sintonia PI



Fonte: próprio autor (2016).

É possível observar que a região que apresenta os menores valores da função J , situa-se em um pequeno espaço perto da origem, semelhantemente a um formato de funil. Esta região representa a área do mínimo global da função J , o qual é bem delimitado nesta região, podendo-se afirmar que para um algoritmo conseguir atingir esta região, a qual possui o menor valor solução possível, deve-se ter uma busca diversificada na região delimitada no espaço de busca, visto que para outros locais, a região da função é quase uniforme.

Para este tipo de mínimo global, a metaheurística do tipo PSO tem boa aceitação, pois trabalha de maneira que a exploração do espaço de busca ocorra de forma "inteligente", evitando os mínimos locais. Contudo, vale salientar que para isso, faz-se necessária uma delimitação apropriada do espaço de busca, neste caso $[0,1]$.

5.2 Análise das Sintonias Clássicas do Controlador PI

Em primeiro lugar, faz-se necessário realizar uma análise das sintonias clássicas do controlador PI, apresentadas nesta dissertação. O intuito desta análise é o de verificar as condições do funcionamento do controlador e, além disso, ter uma base comparativa para a análise do ganho proporcionado pela aplicação da metaheurística PSO na sintonia do controlador PI.

De acordo com a metodologia proposta nesta dissertação, a análise dos métodos de sintonia clássicos foi realizada em primeiro lugar em ambiente computacional e em seguida aplicada ao controlador real, permitindo uma avaliação quantitativa e qualitativa de cada sintonia. Além disso, dentre os quatro degraus de referência aplicados na entrada do controlador, apenas o terceiro degrau ($400 \text{ m}^3/\text{h} \rightarrow 800 \text{ m}^3/\text{h}$) foi escolhido para verificar as informações acerca dos índices de qualidade do degrau, pelo fato de este reproduzir melhor a dinâmica real do sistema; o principal motivo desta escolha foi que este ponto de operação aproximou-se bastante com o resultado experimental em bancada.

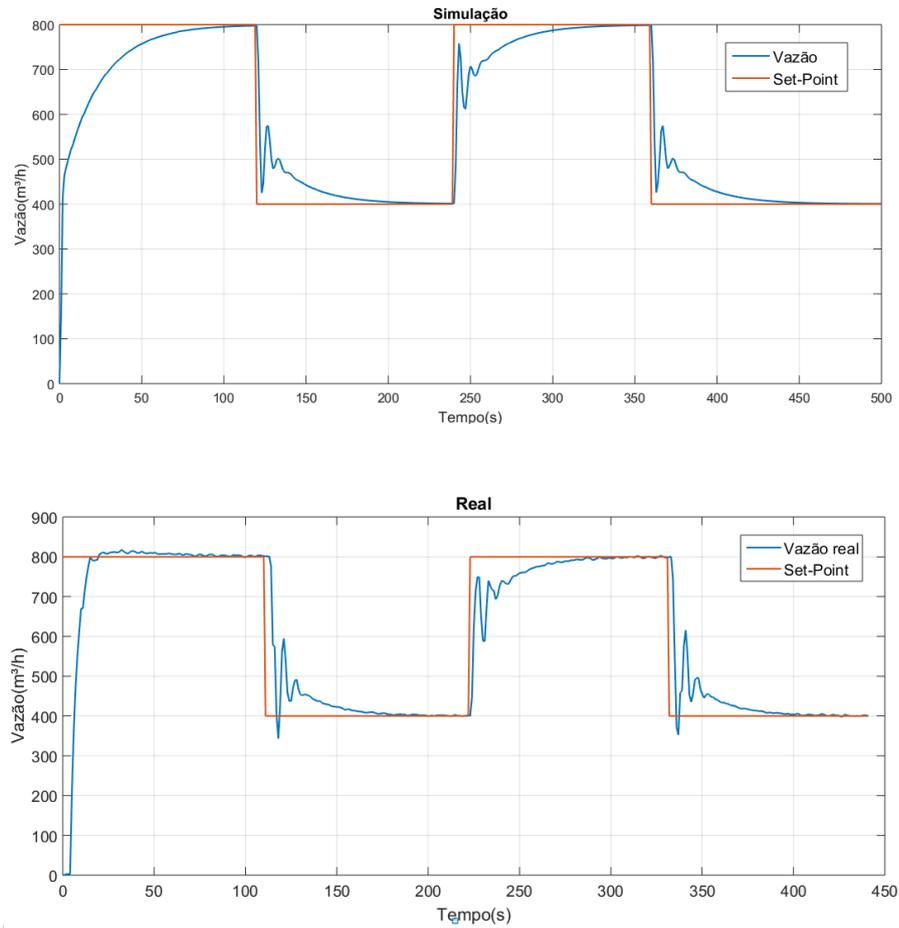
a) Sintonia Ziegler-Nichols

Tabela 9 – Índices de Qualidade do Controlador PI Ziegler-Nichols (Simulação).

$K_p = 0.05509$ $K_i = 0.00414$			
Índice do Degrau	Resultado	Índice do Erro Acumulado	Resultado
Tempo de Subida (t_r)	33.94s	IAE	2.2657e+04
Tempo de Estabilização (t_s)	72.10s	ITAE	3.7120e+06
Pico (M_p)	798.64 m^3/h	ISE	4.2147e+06
Overshoot (%)	0	ITSE	5.2166e+08

Fonte: próprio autor (2016).

Figura 42 – Sintonia PI Ziegler Nichols Simulação x Real.



Fonte: próprio autor (2016).

b) Sintonia CHR Servo

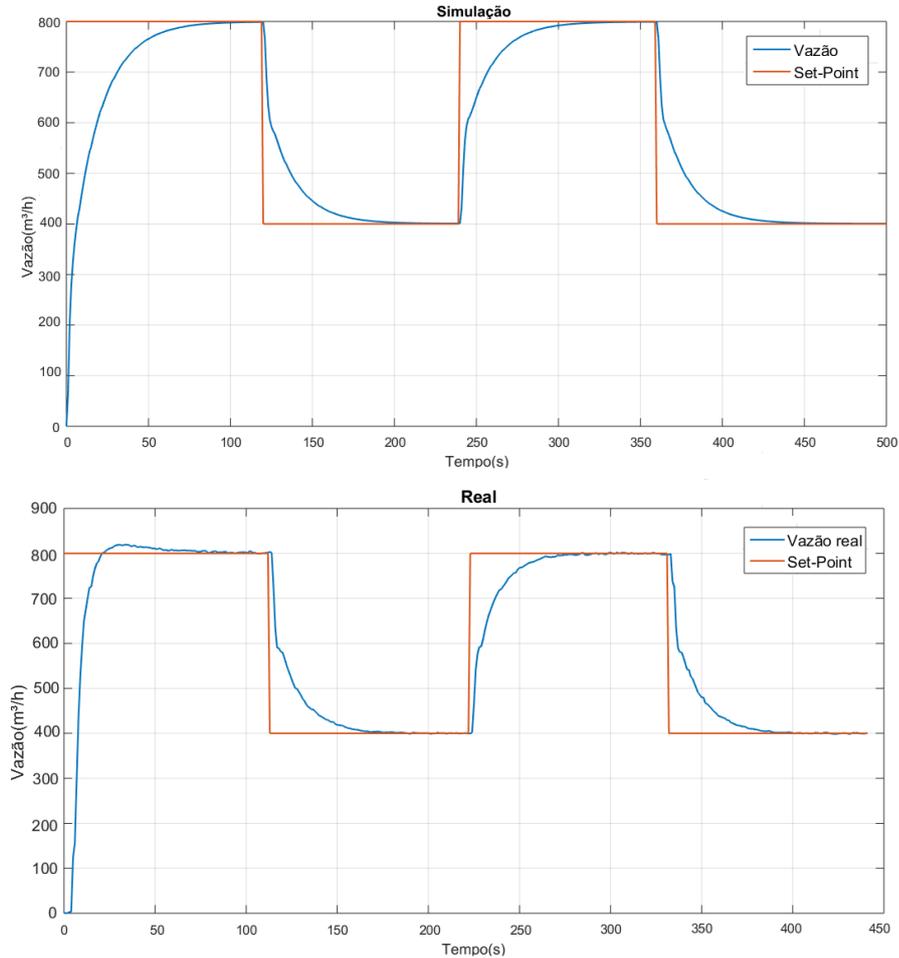
Tabela 10 – Índices de Qualidade do Controlador PI CHR Servo (Simulação).

$K_p=0.02143$ $K_i=0.00336$

Índice do Degrau	Resultado	Índice do Erro Acumulado	Resultado
Tempo de Subida (t_r)	31.01s	IAE	2.6787e+04
Tempo de Estabilização (t_s)	60.79s	ITAE	4.3212e+06
Pico (M_p)	799.28 (m ³ /h)	ISE	6.4271e+06
Overshoot (%)	0	ITSE	7.6012e+08

Fonte: próprio autor (2016).

Figura 43 – Sintonia PI CHR Servo Simulação x Real.



Fonte: próprio autor (2016).

c) Sintonia CHR Regulatório

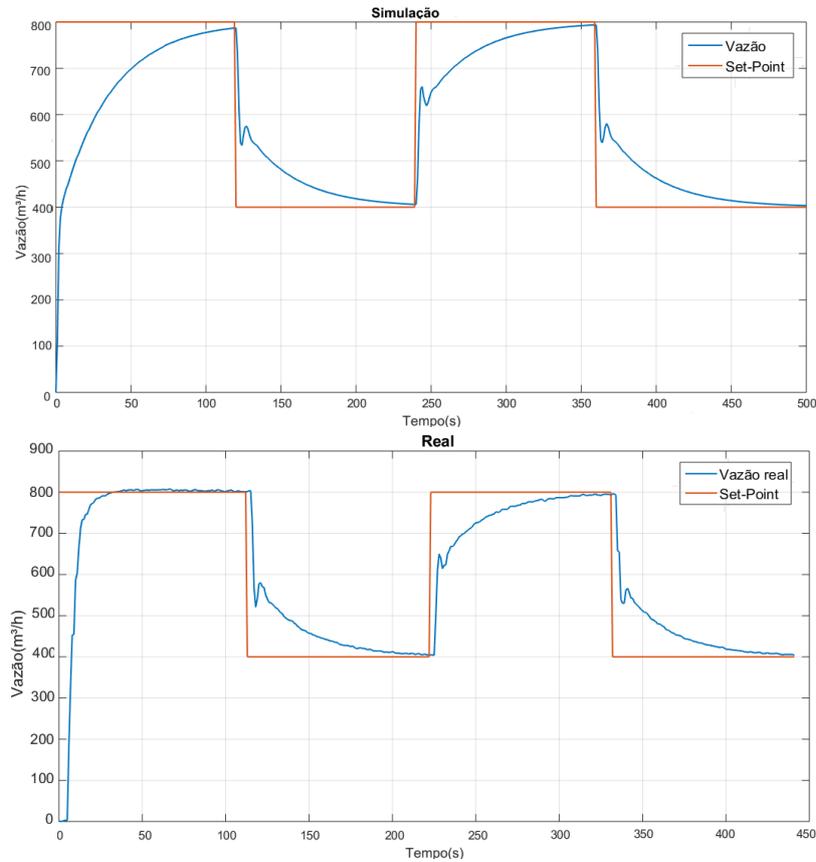
Tabela 11 – Índices de Qualidade do Controlador PI CHR Regulatório (Simulação).

$K_p=0.03673$ $K_i=0.00229$

Índice do Degrau	Resultado	Índice do Erro Acumulado	Resultado
Tempo de Subida (t_r)	54.79s	IAE	3.7376e+04
Tempo de Estabilização (t_s)	111.23s	ITAE	6.4640e+06
Pico (M_p)	793.81 (m ³ /h)	ISE	7.0198e+06
Overshoot (%)	0	ITSE	8.5215e+08

Fonte: próprio autor (2016).

Figura 44 – Sintonia PI CHR Regulatório Simulação x Real.



Fonte: próprio autor (2016).

d) Sintonia CHR 20% de Sobressinal Servo

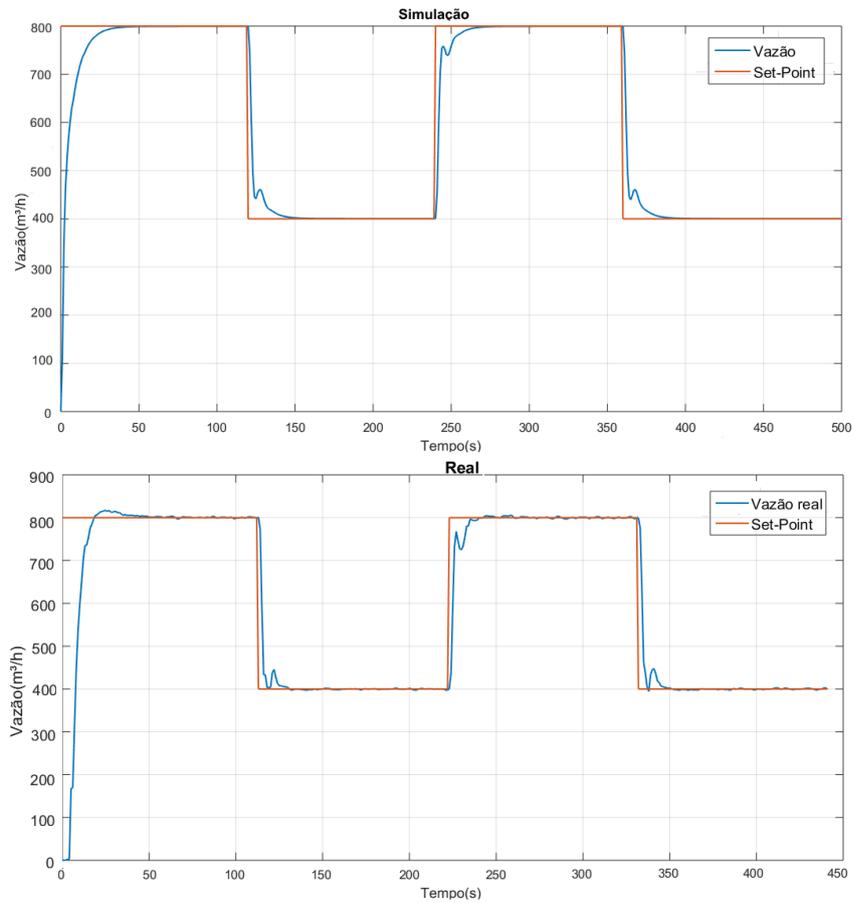
Tabela 12 – Índices de Qualidade do Controlador PI CHR 20% de Sobressinal Servo (Simulação).

$$K_p = 0.03673 \quad K_i = 0,00918$$

Índice do Degrau	Resultado	Índice do Erro Acumulado	Resultado
Tempo de Subida (t_r)	9.44s	IAE	1.0042e+04
Tempo de Estabilização (t_s)	21.15s	ITAE	1.5396e+06
Pico (M_p)	799.50 (m ³ /h)	ISE	2.8789e+06
Overshoot (%)	0	ITSE	3.6917e+08

Fonte: próprio autor (2016).

Figura 45 – Sintonia PI CHR 20% de Sobressinal Servo Simulação x Real.



Fonte: próprio autor (2016).

e) Sintonia Cohen e Coon

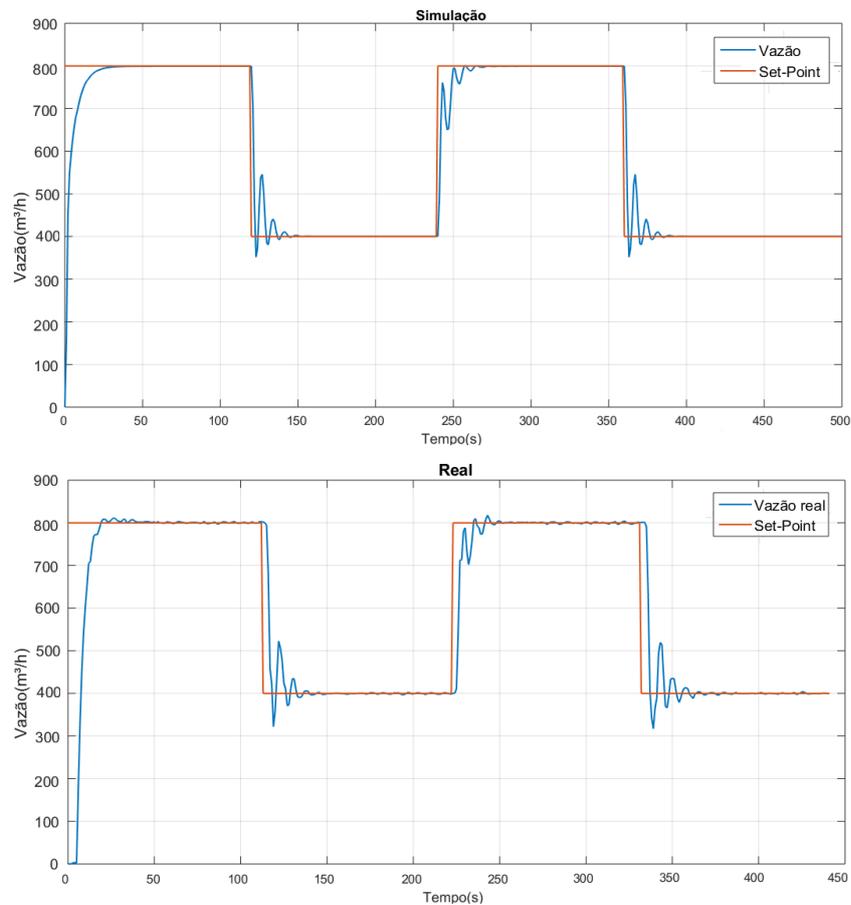
Tabela 13 – Índices de Qualidade do Controlador PI Cohen e Coon (Simulação).

$$K_p = 0.06208 \quad K_i = 0.01519$$

Índice do Degrau	Resultado	Índice do Erro Acumulado	Resultado
Tempo de Subida (t_r)	2.53s	IAE	8.9179e+03
Tempo de Estabilização (t_s)	23.34s	ITAE	1.4932e+06
Pico (M_p)	801.0425 (m ³ /h)	ISE	2.4859e+06
Overshoot (%)	0	ITSE	3.5390e+08

Fonte: próprio autor (2016).

Figura 46 – Sintonia PI Cohen e Coon Simulação x Real.



Fonte: próprio autor (2016).

A partir da observação das diversas sintonias clássicas do controlador PI é possível observar que em todos os casos abordados, alguns de maneira mais evidente, faz-se necessário um refinamento nos valores de K_p e K_i para alcançar uma ação de controle mais adequada sobre a planta em questão.

A sintonia Ziegler-Nihcols apresenta um comportamento oscilatório durante a mudança de set-point, estabilizando-se no valor de referência em um tempo considerado longo. No caso das sintonias do tipo CHR, os tempos de subida e o de estabilização foram altos, tornando o controle bastante lento, enquanto as sintonias CHR Regulatório e CHR com 20% de Sobressinal Servo, possuem tempos de subida menores, o que implica uma resposta mais rápida da ação de controle. Contudo, a sintonia CHR Regulatório possui uma estabilização no valor de referência bem mais demorada do que a sintonia CHR com 20 % de Sobressinal.

Por fim, a sintonia Cohen e Coon, apresenta uma resposta bastante rápida e oscilatória na mudança do set-point, devido principalmente ao baixo valor no tempo de subida, bem como ao efeito do sistema anti wind-up, também observado nas respostas de tempo curto de subida em outras sintonias. Além disso, a estabilização desta sintonia é considerada rápida.

5.3 Análise da Metaheurística PSO na Sintonia PI

Com o objetivo de refinar o algoritmo PSO de maneira adequada ao problema de sintonia PI, os parâmetros de controle do algoritmo foram ajustados. As constantes c_1 e c_2 da equação 20, foram ambas fixadas no valor 2, de modo que permitam um equilíbrio no comportamento social e cognitivo da partícula (SHI; EBERHART, 1998).

Para a determinação do peso inercial (w), realizou-se testes com 50 iterações para valores diferentes de w , entre $[0,6 \mid 1,2]$ (SHI; EBERHART, 1998). Uma convergência prematura foi verificada entre valores mais baixos desse intervalo, no qual as partículas em poucas iterações agrupavam-se em torno do melhor histórico, mesmo com uma busca inicial diversificada. Em geral, para os valores maiores do intervalo de análise de w , algumas partículas não conseguem retornar aos seus melhores valores, nas iterações mais avançadas, de forma que não se juntam em torno do melhor valor do enxame (g_{best}). O melhor valor verificado nos testes foi 0,8, o qual apresentou um maior equilíbrio com relação à habilidade do algoritmo de realizar buscas locais e globais, minimizando a convergência prematura e proporcionando que as partículas se acumulem em torno do ótimo global de maneira mais eficaz.

Em relação ao número de partículas (N), foram estabelecidos os valores de 20, 30, e 50 para a demonstração dos resultados da simulação do algoritmo. No que se refere ao incremento da posição das partículas; com o intuito de amenizar uma possível saída da partícula da região de busca limitada foi utilizado um fator de 0,2 na equação da velocidade; desta forma a equação do incremento da posição da partícula é dada por:

$$x_{id}^{k+1} = x_{id}^k + 0,2 * v_{id}^{k+1} \quad (38)$$

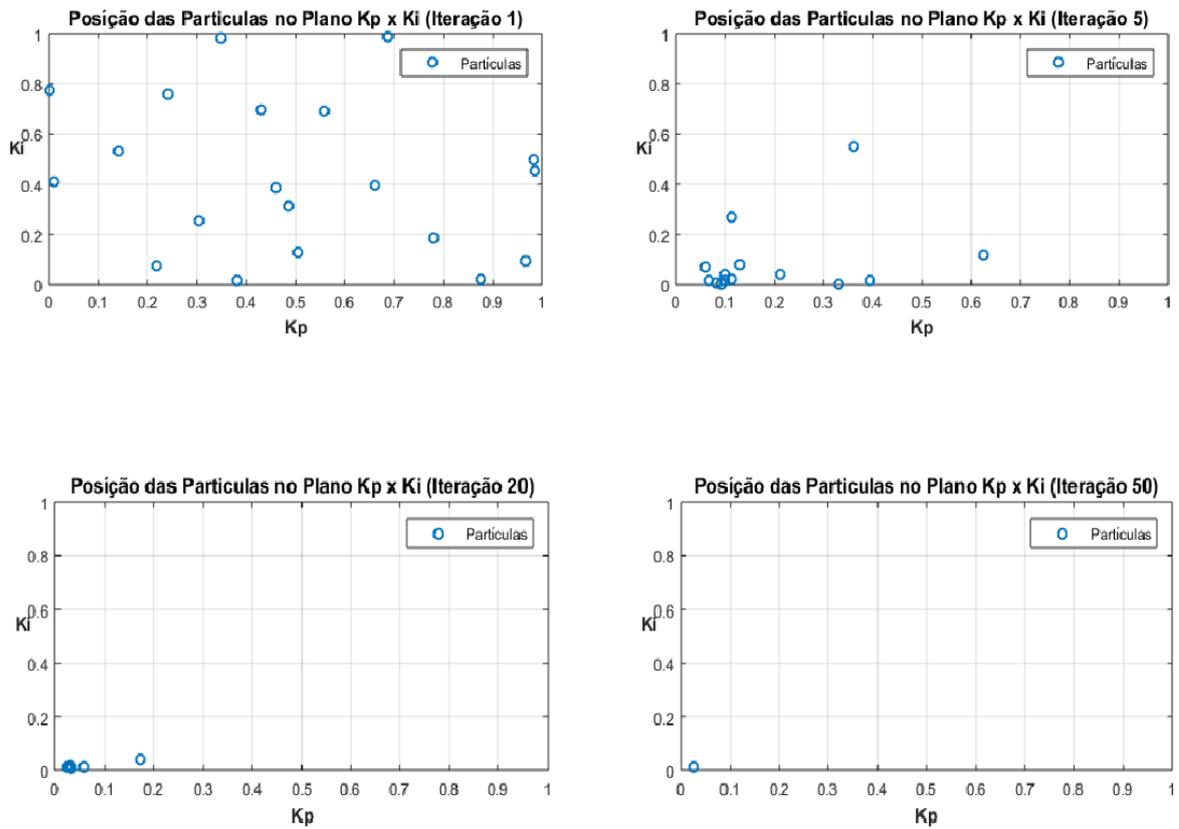
A seguir são apresentados os resultados da aplicação do PSO na sintonia do controlador PI, otimizando os parâmetros K_p e K_i que melhor proporcionam uma ação de controle eficiente, a qual é baseada nas características desejadas, uma rápida resposta na mudança do *setpoint* e boa estabilidade no valor de referência. Todas as simulações computacionais têm ao total 50 iterações, representando o critério de parada do algoritmo. As Tabelas 14, 15 e 16 apresentam resultados numéricos da otimização por PSO; as Figuras 47, 50 e 53 demonstram a posição das partículas em quatro instantes de tempos diferentes; as Figuras 48, 51 e 54 demonstram o caminho das variáveis durante as iterações do PSO; as Figuras 49, 52 e 55 apresentam a minimização da função objetivo do problema por PSO; todas as figuras e tabelas foram realizadas com 20, 30 e 50 partículas respectivamente.

Tabela 14 – Resultado da Otimização por PSO com 20 Partículas.

Iteração	K_p	K_i	Função Objetivo (J)
1	0.1752	0.1494	1.9736e+05
5	0.0591	0.0256	3.8622e+04
10	0.0235	0.0106	1.3272e+04
15	0.0265	0.0111	1.2019e+04
20	0.0268	0.0112	1.1970e+04
25	0.0267	0.0112	1.1865e+04
30	0.0267	0.0112	1.1842e+04
35	0.0267	0.0112	1.1836e+04
40	0.0267	0.0112	1.1833e+04
45	0.0267	0.0112	1.1831e+04
50	0.0267	0.0112	1.1827e+04

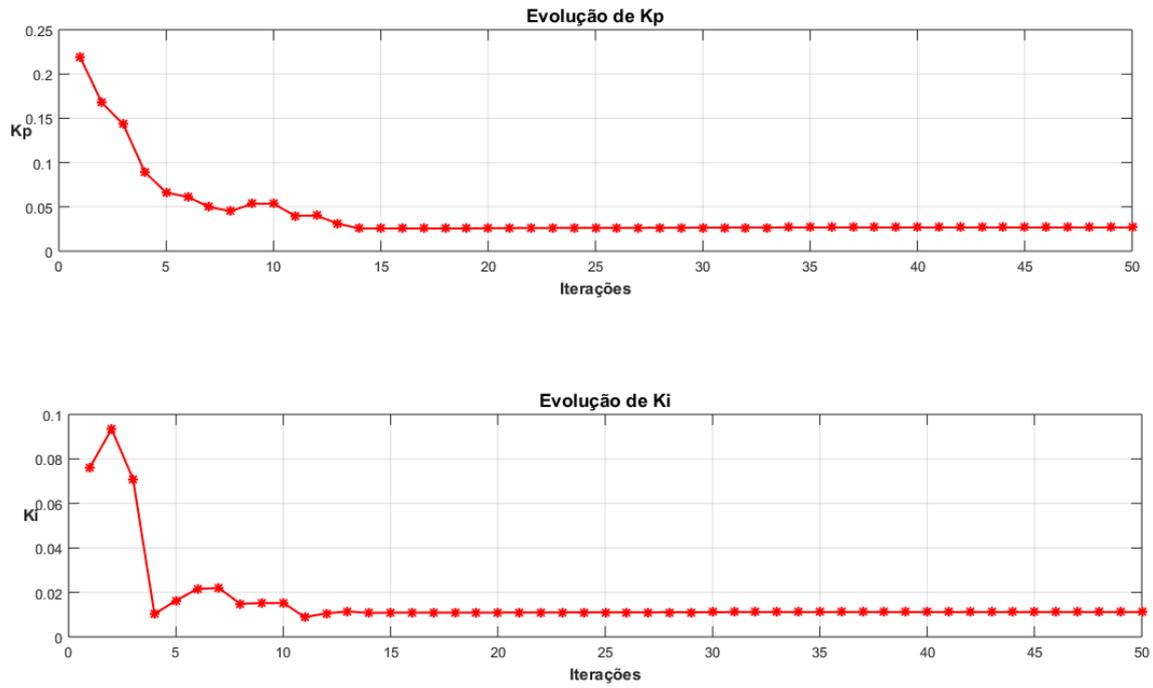
Fonte: próprio autor (2016).

Figura 47 – Deslocamento das Partículas Durante as Iterações.



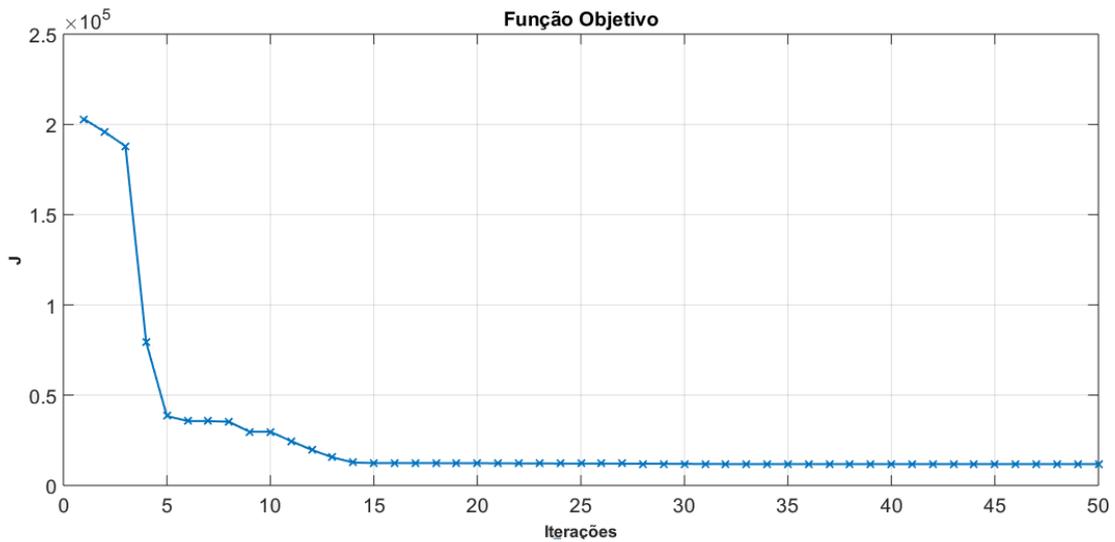
Fonte: próprio autor (2016).

Figura 48 – Evolução dos Valores das Partículas Durante as Iterações.



Fonte: próprio autor (2016).

Figura 49 – Minimização da Função Objetivo por PSO.



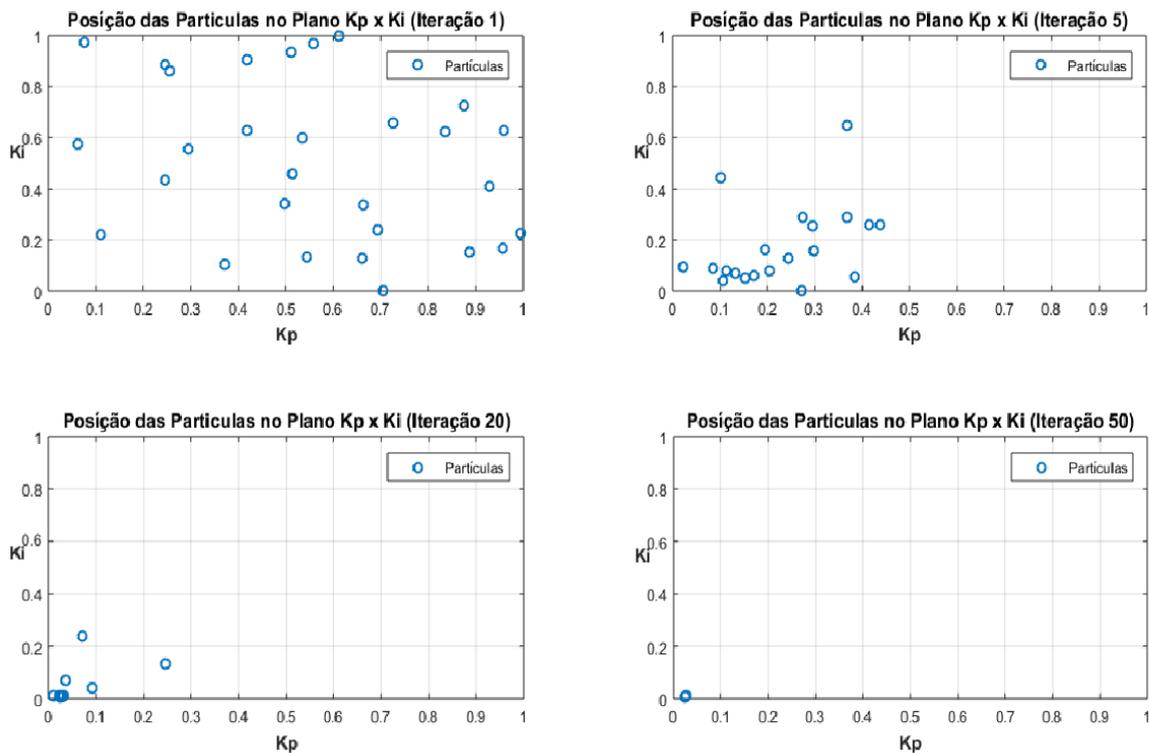
Fonte: próprio autor (2016).

Tabela 15 – Resultado da Otimização por PSO com 30 Partículas.

Iteração	K_p	K_i	Função Objetivo (J)
1	0.1668	0.2313	1.9871e+05
5	0.0307	0.0064	3.3372e+04
10	0.0232	0.0102	1.3933e+04
15	0.0235	0.0105	1.3196e+04
20	0.0268	0.0112	1.2059e+04
25	0.0266	0.0111	1.1910e+04
30	0.0268	0.0112	1.1842e+04
35	0.0267	0.0112	1.1830e+04
40	0.0267	0.0112	1.1827e+04
45	0.0267	0.0112	1.1826e+04
50	0.0267	0.0112	1.1826e+04

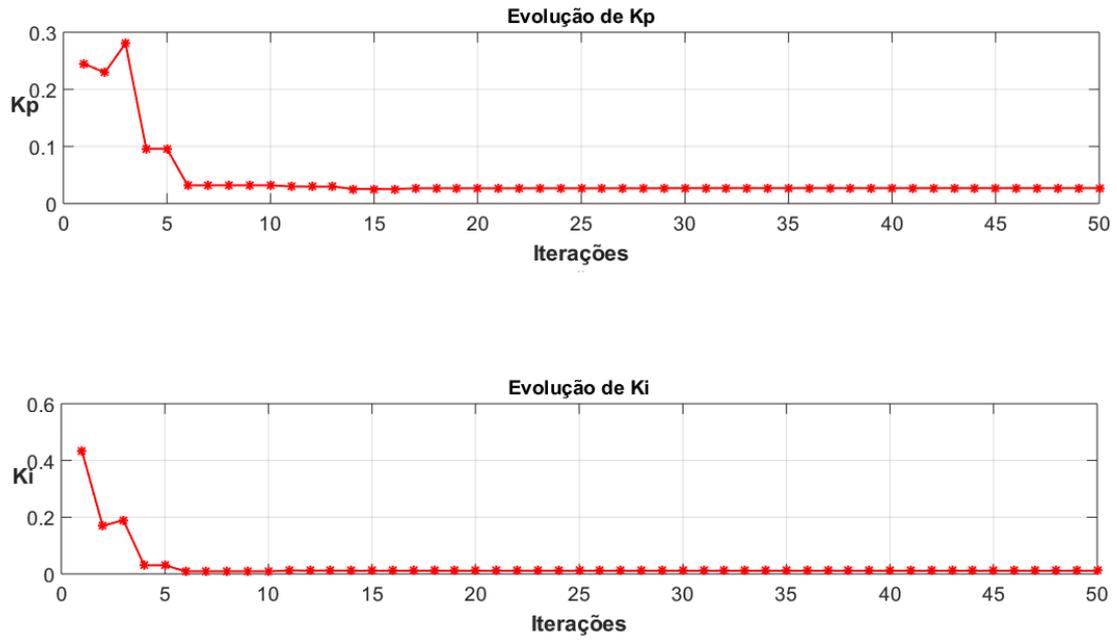
Fonte: próprio autor (2016).

Figura 50 – Deslocamento das Partículas Durante as Iterações.



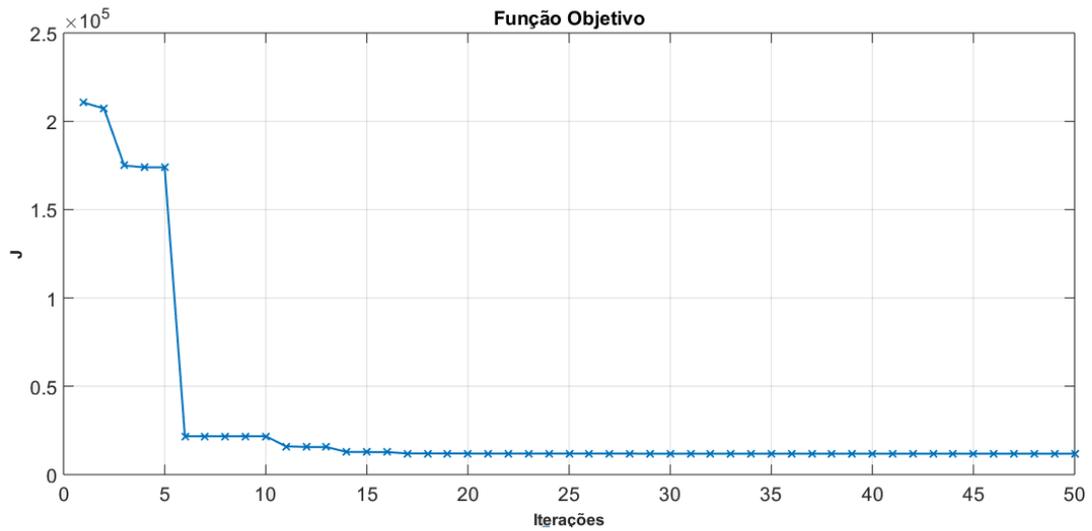
Fonte: próprio autor (2016).

Figura 51 – Evolução dos Valores das Partículas Durante as Iterações.



Fonte: próprio autor (2016).

Figura 52 – Minimização da Função Objetivo por PSO.



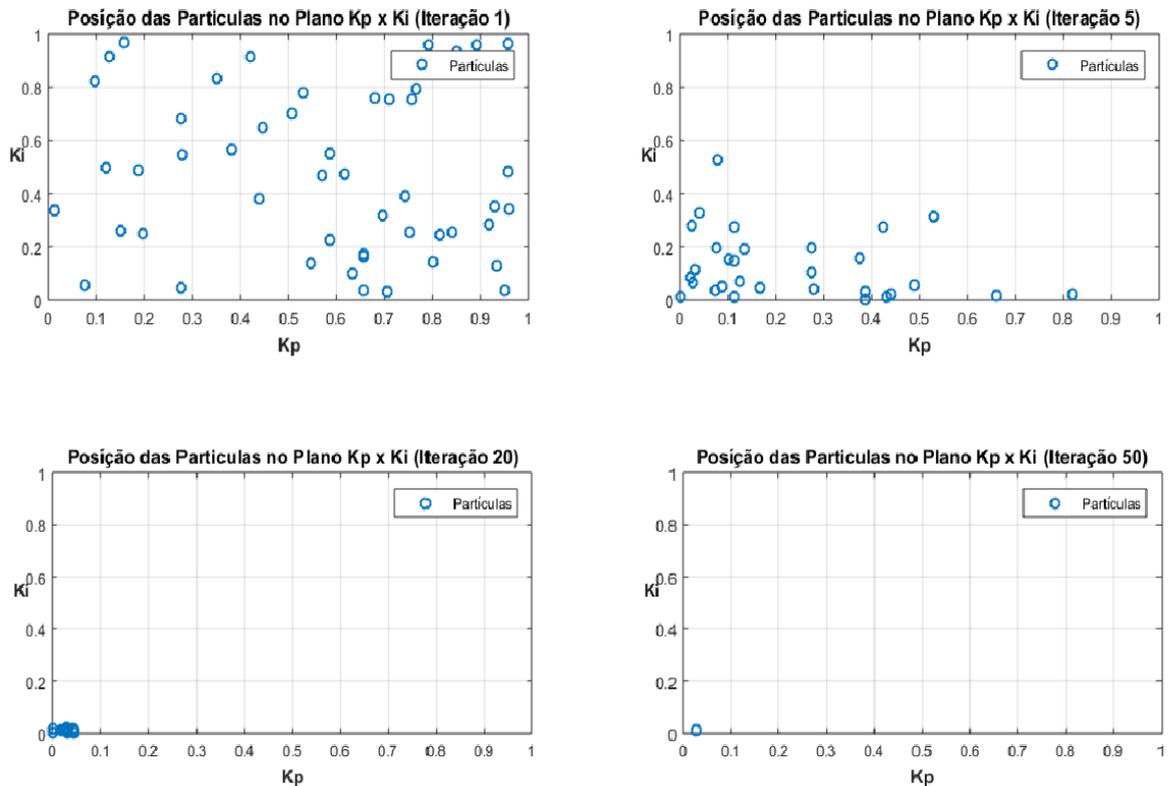
Fonte: próprio autor (2016).

Tabela 16 – Resultado da Otimização por PSO com 50 Partículas.

Iteração	K_p	K_i	Função Objetivo (J)
1	0.1668	0.2313	1.9871e+05
5	0.0307	0.0064	3.3372e+04
10	0.0232	0.0102	1.3933e+04
15	0.0235	0.0105	1.3196e+04
20	0.0268	0.0112	1.2059e+04
25	0.0266	0.0111	1.1910e+04
30	0.0268	0.0112	1.1842e+04
35	0.0267	0.0112	1.1830e+04
40	0.0267	0.0112	1.1827e+04
45	0.0267	0.0112	1.1826e+04
50	0.0267	0.0112	1.1826e+04

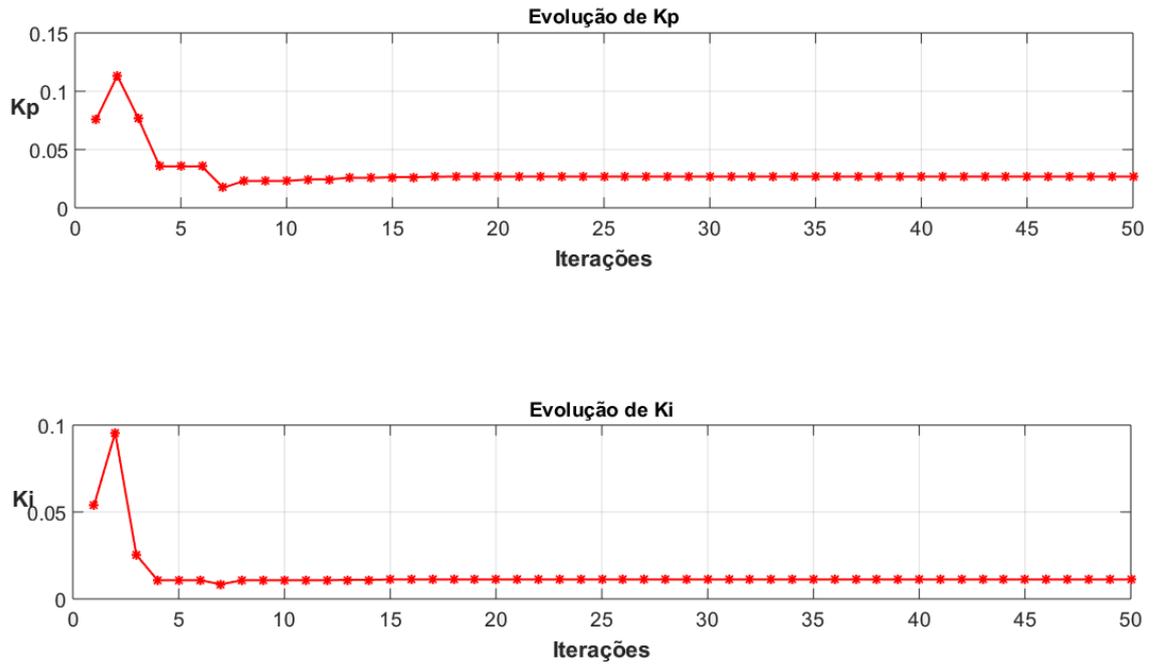
Fonte: próprio autor (2016).

Figura 53 – Deslocamento das Partículas Durante as Iterações.



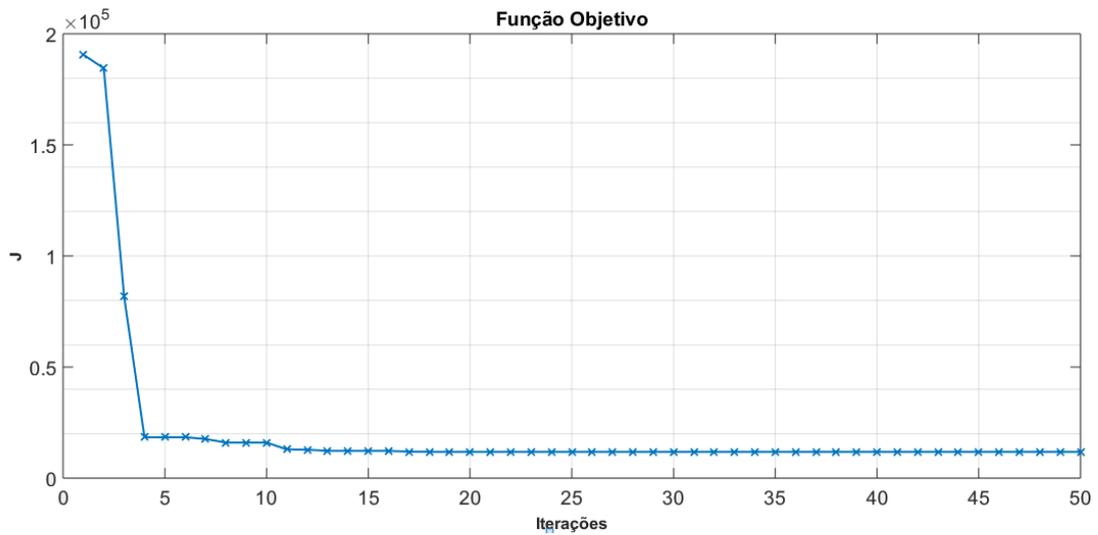
Fonte: próprio autor (2016).

Figura 54 – Evolução dos Valores das Partículas Durante as Iterações.



Fonte: próprio autor (2016).

Figura 55 – Minimização da Função Objetivo por PSO.



Fonte: próprio autor (2016).

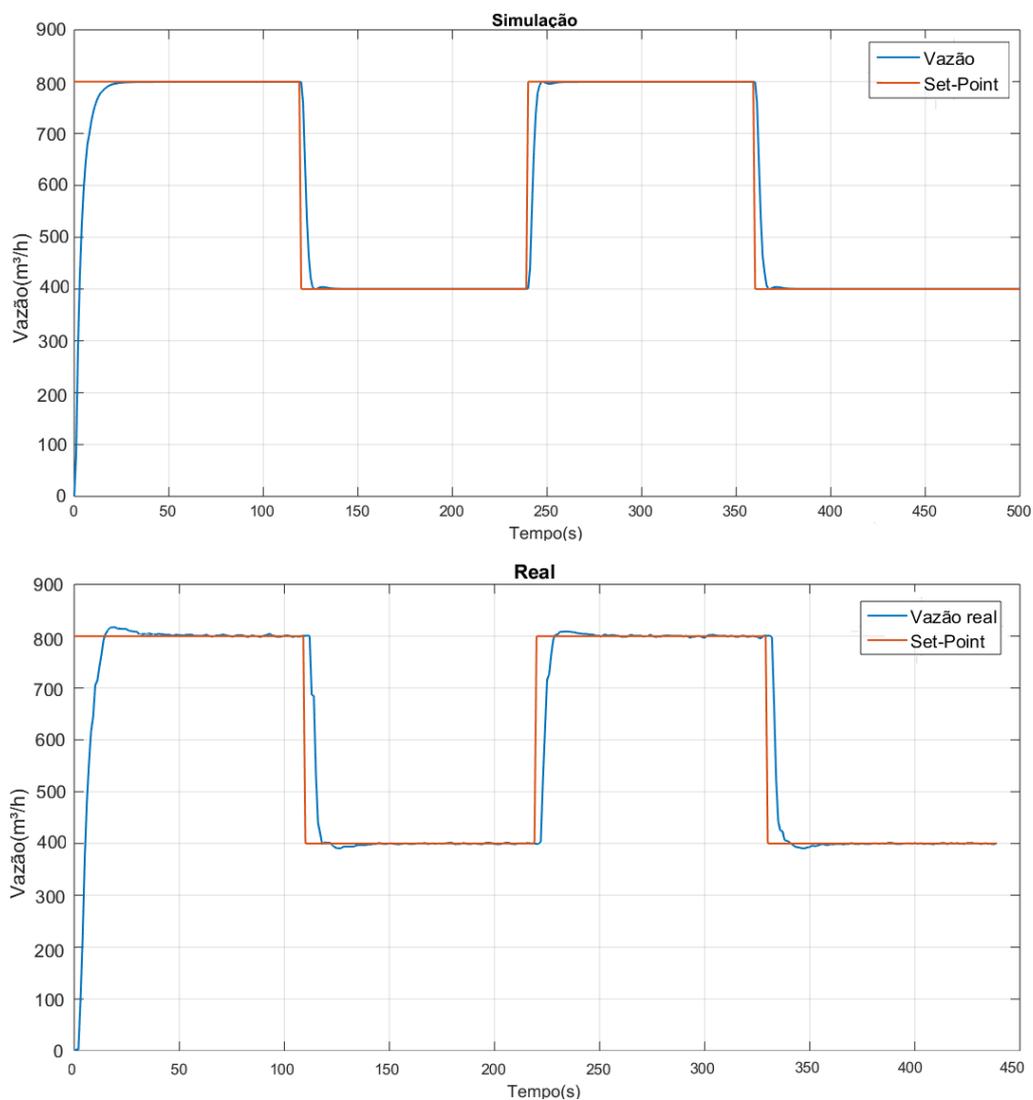
Tabela 17 – Índices de Qualidade do Controlador PI Otimizado por PSO (Simulação).

$$K_p = 0.02674 \quad K_i = 0.01117$$

Índice do Degrau	Resultado	Índice do Erro Acumulado	Resultado
Tempo de Subida (t_r)	3.56s	IAE	8.3126e+03
Tempo de Estabilização (t_s)	6.99s	ITAE	1.2598+06
Pico (M_p)	800 (m ³ /h)	ISE	2.9660e+06
Overshoot (%)	0	ITSE	1.2598e+06

Fonte: próprio autor (2016).

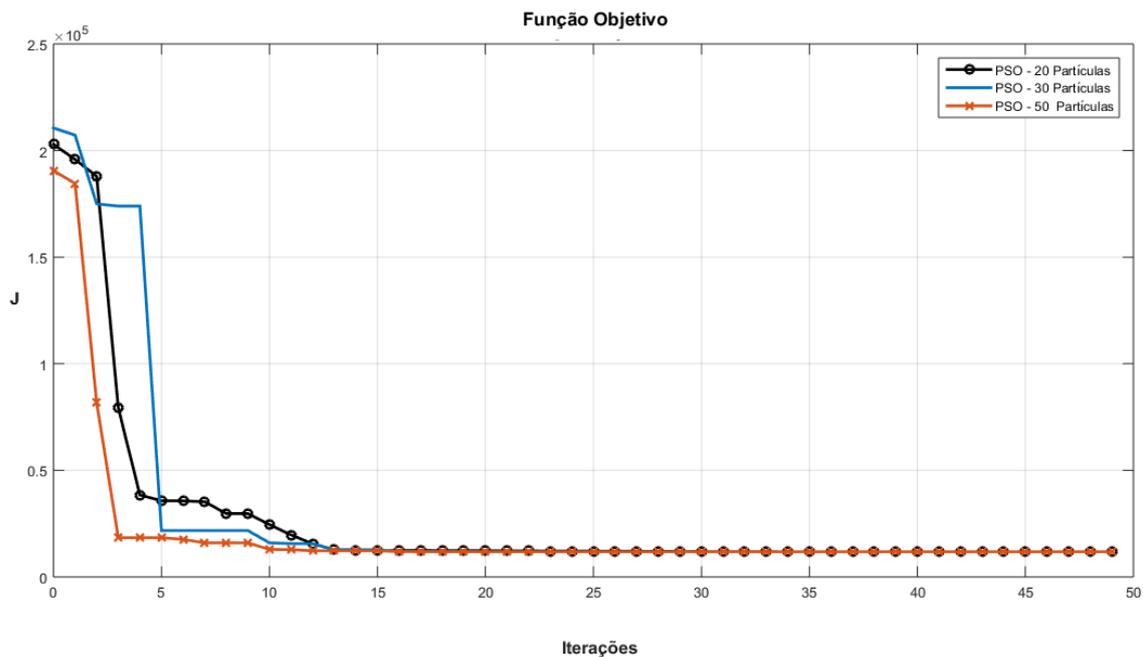
Figura 56 – Sintonia do Controlador PI por PSO Simulação x Real.



Fonte: próprio autor (2016).

A Tabela 17 apresentou os índices de qualidade da sintonia PI por PSO; A Figura 56 demonstrou o comportamento do controle sintonizado por PSO, a parte real e simulada. A análise dos resultados do PSO demonstram que o algoritmo obteve um bom comportamento na exploração do espaço de busca, tanto local como global (dentro do intervalo de análise do controle estável), proporcionado pelos parâmetros ajustados c_1, c_2 e w . A Figura 57 apresentou as minimizações da função objetivo por PSO para 20, 30 e 50 partículas respectivamente.

Figura 57 – Minimização da Função Objetivo pela Metaheurística. PSO.



Fonte: próprio autor (2016).

Como esperado, o algoritmo possui uma rápida convergência para o valor de mínimo da função objetivo (J) à medida que o número de partículas é aumentado, decorrente do fato de haver uma maior exploração dentro dos espaços de busca da solução, analogamente ao conceito do PSO; quando um indivíduo dentro do bando encontra uma região de mais atrativos (mais alimentos), todo o bando é comunicado; caso os outros indivíduos do bando não encontrem uma região melhor, todos irão convergir para este ponto mais propício.

No que se refere ao tempo de processamento dos algoritmos, pela forma como foi implementado o PSO, o máximo tempo apresentado foi de aproximadamente 30 minutos para realizar a simulação das 50 iterações com 50 partículas.

Tabela 18 – Quadro Comparativo das Diversas Sintonias do Controlador PI.

Sintonia	Tempo de Subida (t_r)	Tempo de Estabilização (t_s)	IAE
Ziegler-Nichols	33,94s	72,10s	2.2657e+04
CHR Servo	31,01s	60,79s	2.6787e+04
CHR Regulatório	54,79s	111,23s	3.7376e+04
CHR 20% Sobressinal	9,44s	21,15s	1.0042e+04
Cohen e Coon	2,53s	23,34s	8.9179e+03
PSO	3,56s	6,99s	8.3126e+03

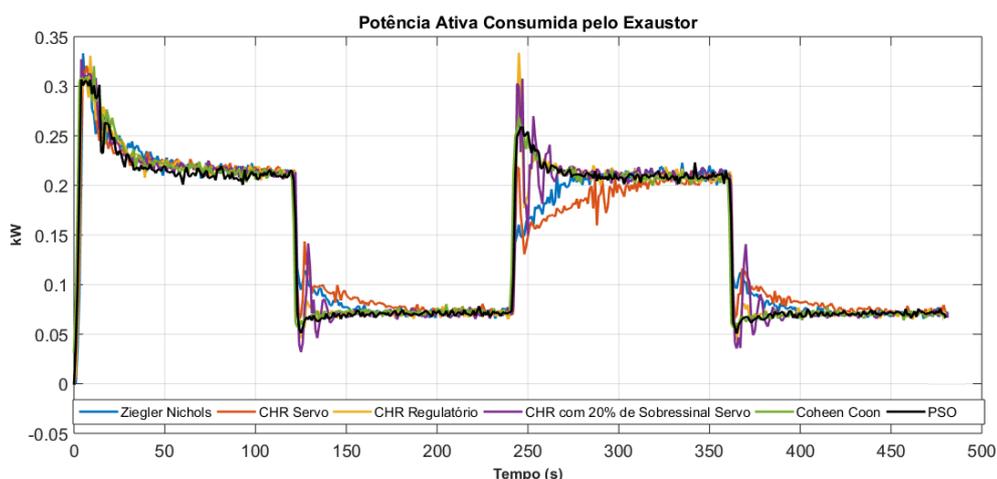
Fonte: próprio autor (2016).

A partir da tabela 18 e da Figura 56, pode-se observar que o tempo de estabilização (t_s) e os erros acumulados foram menores do que os obtidos pelas sintonias clássicas apresentadas anteriormente neste capítulo; apesar do tempo de subida (t_r) ser um pouco maior do que observado na sintonia Cohen e Coon, esta situação permitiu um melhor equilíbrio na estabilidade, evidenciando o fato de que a otimização do controlador PI por meio do PSO obteve como resultado um controle rápido e mais estável para a malha de controle do protótipo do exaustor industrial presente no LEEQE.

5.4 Análise Energética das Sintonias do Controlador PI

Uma análise importante a respeito da sintonia do controlador PI nesta dissertação, é o impacto no consumo de energia por parte do sistema de exaustão industrial.

Figura 58 – Comportamento da Potência Ativa pelas diferentes Sintonias do Controlador PI



Fonte: próprio autor (2016).

A partir da observação da figura 58, é possível perceber que o comportamento da ação de controle tem influência direta no consumo da potência ativa por parte do exaustor.

Todas as sintonias que tiveram algum tipo de oscilação na estabilização no valor de referência devido à mudança no *setpoint*, apresentaram os maiores picos de consumo de potência ativa instantânea, como é o caso das sintonias Ziegler-Nichols, CHR com 20% de sobressinal Servo e a Cohen e Coon. No caso das sintonias "mais lentas", mesmo não apresentando os maiores valores de pico da potência ativa, a sua estabilização foi mais demorada, principalmente no caso da mudança para um *setpoint* menor, implicando um maior consumo por parte delas. A sintonia obtida pela aplicação da metaheurística PSO apresentou um bom comportamento no consumo da potência ativa, possuindo menores valores de pico, maior estabilidade e menor consumo total de potência no intervalo de tempo analisado.

Tabela 19 – Consumo Acumulado de Energia (W.h) das Sintonias (8 min)

Sintonia	W.h
Ziegler-Nichols	19,4116
CHR Servo	19,3475
CHR Regulatório	19,4188
CHR 20% Sobressinal	19,4221
Cohen e Coon	19,4675
PSO	19,2015

Fonte: próprio autor (2016).

Como foi utilizada a mesma estrutura de controle, controlador PI, apenas com diferença na sintonia do mesmo, os valores de energia elétrica consumidos não tiveram muita disparidade. Todavia, houve um menor consumo por parte da sintonia por PSO. A sintonia clássica de menor consumo foi a CHR Servo, apresentando um consumo total de 9.2868 kW.h. Porém, esse foi um controle muito lento do sistema, mesmo com uma das menores energias consumidas, esse caso não é interessante para um controle eficiente. Por outro lado, a sintonia CHR 20% Sobressinal apresentou um consumo de 9.344 kW.h; mesmo com um valor maior de consumo, o controle foi melhor do que a sintonia CHR Servo.

A sintonia por PSO apresentou um consumo de 19,2015 W.h, uma redução de 0.15 W.h (0,78%) e 0,27 W.h (1,39 %) em relação às sintonias CHR Servo e CHR 20% Sobressinal respectivamente. Admitindo um ciclo de trabalho maior, 6h diárias por exemplo, a economia neste caso representaria uma redução de 6,75 W.h por dia, em um mês (30 dias) 202,5 W.h e durante um ano 2.430 kW.h.

6 Conclusão e Trabalhos Futuros

Sem dúvidas, existe uma grande urgência na questão do uso eficiente dos recursos energéticos, a eficiência energética evita desperdícios e diminui a necessidade de uma maior geração de energia por parte de geradores poluidores, vistos os impactos sociais e ambientais inerentes a estes. No setor industrial, a necessidade de bons ajustes nos controladores PID, abordada especificamente neste trabalho, tem uma grande influência no desempenho do controlador nas malhas dos processos produtivos.

Como abordado anteriormente, existem diversos tipos de sintonia de controladores PID, no entanto, a aplicação delas por si só não garante um controle eficiente, servindo como um ponto inicial na busca por melhores parâmetros do controlador que permitam garantir um funcionamento dentro dos padrões de qualidade e com elevada produtividade do processo. Um controlador bem sintonizado não deixa apenas as malhas de controle mais produtivas. Implicam diretamente em economia de energia, redução de custos associados a fadigas de equipamentos, além de melhorar a qualidade dos produtos.

Neste trabalho foi investigada a utilização da inteligência artificial como um recurso de otimização, especificamente o uso da metaheurística, devido principalmente à inteligência desta, ou seja, sua capacidade de aprendizado ao longo do processo de exploração do espaço de busca das soluções, evitando desta maneira muitos pontos de mínimos locais da função objetivo. Nesta dissertação, a metaheurística utilizada foi o algoritmo PSO, baseado na inteligência envolvida no trabalho em grupo (enxames) dos animais, obtendo-se um promissor desempenho na otimização dos parâmetros da sintonia do controlador PI/PID.

Com o objetivo de demonstrar a eficiência energética produzida a partir da sintonia do controlador PI através do algoritmo PSO em um processo industrial real, utilizou-se uma bancada com um protótipo de exaustor industrial presente LAMOTRIZ, localizado na UFPE; no entanto, para que fosse possível utilizar os mesmo parâmetros (K_p , K_i) encontrados na otimização pela simulação, foi necessária realizar a modelagem da malha de controle em formato digital, utilizando o processo de Zero-Order-Hold. Além disso, foi necessária a adição restrições presentes no controlador real (CLP), como o sistema anti-windup por exemplo. O resultado da modelagem digital do processo aproximou-se bastante da situação real. Contudo, o resultado experimental obtido teve algumas pequenas divergências, entre as causas associadas, pode-se destacar a questão das não linearidades do sistema dinâmico de primeira ordem; todavia, essas pequenas divergências não tiveram muita influência no resultado final da otimização.

Os resultados da implementação no sistema real dos parâmetros da sintonia, provenientes dos processos de otimização por PSO e simulação, demonstraram baixos valores de *overshoot* e um bom desempenho no tempo de estabilização do sinal de controle. Comparado a alguns

sistemas convencionais de sintonia, a metaheurística do PSO apresentou os melhores resultados em todos os critérios de desempenho avaliados nas simulações, o qual foi ratificado na implementação do sistema de controle real.

Além disso, a sintonia por PSO apresentou um comportamento da potência ativa mais estável, com um menor consumo de energia dentre todas as sintonias avaliadas, durante o intervalo de tempo do experimento real praticado nesta dissertação, permitindo ter uma melhor noção do impacto proporcionado por uma boa sintonia do controlador PI no sistema industrial.

Os algoritmos baseados em inteligência de enxame, de maneira geral, vêm mostrando resultados extremamente eficientes nos quesitos de robustez da descoberta de soluções, da velocidade da solução e precisão numérica. Um dos principais motivos desse êxito deve-se à simplicidade, versatilidade, generalidade e paralelismo desses algoritmos, sobretudo quando comparados à dificuldade de modelagem matemática de certos problemas. Nos últimos tempos, essas técnicas vêm experimentando bastante crescimento na variedade das aplicações, devido em parte, à grande quantidade de problemas que envolvem características como não-linearidade, alta dimensionalidade, dificuldade de modelagem, impossibilidade no cálculo de derivadas, entre outros. Em muitos casos, tais situações prejudicam o uso de técnicas tradicionais, tais como programação combinatória, linear, não-linear, dinâmica, inteira, etc.

Por outro lado, as metaheurísticas no geral, apresentam ainda certas dificuldades quanto à sua aplicação em larga escala nos problemas de otimização com alta dimensão, principalmente por causa do custo computacional exigido. Todavia, os últimos desenvolvimentos na área do processamento na computação das máquinas modernas, bem como o desenvolvimento de novos modelos, estão permitindo superar antigos desafios, mostrando que o futuro das técnicas baseadas em inteligência artificial como um todo é promissor.

A respeito de trabalhos futuros na área de controle e automação com ferramentas de inteligência artificial, podem destacar-se:

- Sintonia ótima de controladores PID através de novas técnicas de inteligência artificial, como os Algoritmos Genéticos;
- Aplicações de novas estruturas de controladores por meio de inteligência artificial, sistemas Neurofuzzy por exemplo;
- Otimizar a estrutura do controlador PI com inteligência artificial por meio de adição de um sistema inteligente, como a lógica Fuzzy (PI-Fuzzy);

Referências

- ABBASS, H. A. Marriage in honey bees optimization, a haplometrosis polygynous swarming approach. *In Proceedings of the IEEE Congress on Evolutionary Computation.*, v. 1, p. 207–214, 2001. Citado na página 50.
- ABIO, M. Optimal design of power system stabilizers using particle swarm optimization. *IEEE Trans Energy Conversion*, v. 17, p. 406–413, 2008. Citado na página 58.
- ANDRADE, L. H. S.; COSTA, B. L. G.; ANGÉLICO, B. A. Pso aplicado à sintonia do controlador pi/pid da malha de nível de uma planta didática industrial. *Simpósio Brasileiro de Automação Inteligente*, 2013. Nenhuma citação no texto.
- ANGEL, V. *La rugosité des paysages : une théorie pour la difficulté des problèmes d'optimisation combinatoire relativement aux métaheuristiques*. Dissertação (Tese de Doutorado) — l'université de Paris-Sud, Paris, França, 1998. Citado na página 46.
- ARAUJO, E. et al. Dynamical vibration system modeling by using particle swarm optimization with turbulence. *Proceedings of the XX International Congress of Mechanical Engineering (COBEM)*, 2009. Citado na página 58.
- ASTROM, K. J.; HAGGLUND, T. Automatic tuning of simple regulators with specifications on phase and amplitude margins. *Automatica*, v. 20, p. 645–651, 1984. Citado 2 vezes nas páginas 17 e 38.
- ASTROM, K. J.; HAGGLUND, T. *Pid controllers: Theory, design and tuning*, 2nd ed. *Research Triangle Park, NC, USA:Instrument Society of America*, 1995. Citado na página 27.
- ASTROM, K. J.; HAGGLUND, T. The future of pid control. *Control Engineering Practice*, v. 11, p. 1163–1175, 2001. Citado na página 33.
- ASTROM, K. J.; HAGGLUND, T. *Advanced pid control*. *Instrument Society of America, Durham, NC, USA*, 2006. Citado 3 vezes nas páginas 29, 33 e 40.
- BARANAUSKAS, J. A.; MONARD, M. C. *Aplicações de inteligência artificial: Uma visão geral*. *Instituto de Ciências Matemáticas e de Computação de São Carlos*, 2000. Citado na página 41.
- BARONE, D. *Sociedades Artificiais: A Nova Fronteira da Inteligência nas Máquinas*. 1. ed. Porto Alegre, Brasil: Bookman, 2003. Citado na página 42.
- BASHIR, Z. A.; EL-HAWARY, M. E. Applying wavelets to short-term load forecasting using pso-based neural networks. *IEEE Transactions on Power Systems. Article in Press*, 2009. Citado na página 58.
- BEIGHTLER, C. S.; PHILLIPS, D.; WILDE, D. *Foundations of Optimization (Prentice-Hall international series in industrial and systems engineering)*. 2. ed. USA: Prentice Hall, 1979. Citado na página 43.
- BIANCHI, L.; DORIGO, M.; GAMBARDILLA, L. A survey on metaheuristics for stochastic combinatorial optimization. *Natural Computing*, v. 8, p. 239–287, 2009. Citado na página 43.

- BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *acm computing surveys*. *ACM Computing Surveys*, v. 35, p. 268–308, 2003. Citado 3 vezes nas páginas 46, 47 e 48.
- BOBÁL, V. et al. Digital self-tuning controllers. *Springer*, 2005. Citado 2 vezes nas páginas 30 e 32.
- BONABEAU, E.; DORIGO, M.; THERAULAZ, G. *From natural to artificial swarm intelligence*. Rio de Janeiro, Brasil: Oxford University Press, 1999. Citado na página 50.
- BRANDÃO, M. A. L.; SARAMAGO, S. F. P. Métodos estocásticos de otimização: Algoritmos genéticos e evolução diferencial. *São Carlos, SP: SBMAC*, 2011. Citado na página 45.
- BREGALDA, P. F.; OLIVEIRA, A. A. F.; BORNSTEIN, C. T. Introdução à programação linear. *In Proceedings of the IEEE Congress on Evolutionary Computation.*, p. 329, 1988. Citado na página 44.
- CAMPOS, M. C. M. M.; TEIXEIRA, H. C. G. *Controles Típicos de Equipamentos e Processos Industriais*. 1. ed. São Paulo, Brasil: Edgard Blucher, 2006. Citado na página 29.
- CARDOSO, P. M. *Estudo, Proposta e Avaliação de Novas Metodologias de Sintonia Automática de Controladore PID Baseadas no Ensaio do Relê Realimentado*. Dissertação (Dissertação de Mestrado) — Universidade Federal de Uberlândia, Uberlândia, Uberlândia, Brasil, 2002. Citado na página 26.
- CASTRO, L. N. D. Fundamentals of natural computing: basic concepts, algorithms, and applications. *CRC Press LLC*, 2005. Citado na página 52.
- CHARNIAK, E.; MCDERMOTT, D. *Intkoduction to Artificial Intelligence*. USA: Addison-Wesley Publ, 1985. Citado na página 41.
- CHENG, C. Y. Autotunig of pid controllers: A relay feedback approach. *Jornal of Process Control*, v. 12, p. 143–162, 2002. Citado na página 33.
- CHIEN, K. L.; HRONES, A.; RESWICK, J. B. On the automatic control of generalized passive systems. *Transactions ASME*, v. 74, p. 175–185, 1952. Citado 2 vezes nas páginas 17 e 36.
- COELHO, A. A. R.; COELHO, L. S. *Identificação de Sistemas Dinâmicos Lineares*. 1. ed. Santa Catarina, Brasil: UFSC, 2004. Citado 2 vezes nas páginas 34 e 35.
- COHEN, G. H.; COON, G. A. Theoretical considerations of retarded control. *Transactions ASME*, v. 74, p. 827–837, 1953. Citado 2 vezes nas páginas 17 e 37.
- CORRIPIO, A. B. *Tunning of Industrial Control Systems, Instrumentations Systems*. 1. ed. NC, USA: ISA, 1996. Citado 2 vezes nas páginas 29 e 35.
- DORIGO, M.; GAMBARDELLA, M. L. M. Ant colony system: A cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, v. 1, p. 53–66, 1997. Citado na página 52.
- DREO, J. et al. *Métaheuristiques pour l'optimisation difficile*. 2. ed. Paris, França: Ed. Eyrolles, 2003. Citado 2 vezes nas páginas 48 e 49.

EBERHART, R. C.; SHI, Y. Particle swarm optimization: developments, applications and resources. *Proc. congress on evolutionary computation 2001 IEEE service center, Piscataway, NJ., Seoul, Korea.*, v. 1, p. 81–86, 2001. Citado na página 50.

EPE. *Plano Nacional de Energia 2030*. 2007. Disponível em: <<http://www.epe.gov.br/PNE/Forms/Empreendimento.aspx>>. Acesso em: 04 jan. 2017. Citado na página 20.

EPE. *Anuário Estatístico de Energia Elétrica 2016*. 2016. Disponível em: <<http://www.epe.gov.br/AnuarioEstatisticodeEnergiaEletrica/Forms/Anurio.aspx>>. Acesso em: 02 jan. 2017. Citado na página 15.

EUSUFF, M.; LANSEY, K.; PASHA, F. Shuffled frog-leaping algorithm: a memetic meta-heuristic for discret optimization. *Engineering Optimization*, v. 38, p. 129–154, 2005. Citado na página 52.

FIRMINO, F. *Estudo Comparativo de Métodos de Sintonia de Controladores PID*. Dissertação (Trabalho de conclusão de curso) — Universidade de São Paulo - Escola de Engenharia, São Carlos, Brasil, 2014. Citado 2 vezes nas páginas 17 e 19.

FOULDS, L. R. Combinatorial optimization for undergraduates. *Springer-Verlag, New York*, p. 114, 1984. Citado na página 46.

GAING, Z. L. A particle swarm optimization approach for optimum design of pid controller in avr system. *IEEE Transaction on Energy Conversion*, v. 19, p. 384–391, 2004. Citado na página 58.

GARCIA, C. Modelagem e simulação de processos industriais e sistemas eletromecânicos. *EDUSP ISBN, São Paulo 2 Ed.*, 2005. Citado na página 60.

GLOVER, F. *Future Paths for Integer Programming and Links to Artificial Intelligence*. Dissertação — University of Colorado, Boulder, USA, 1986. Citado na página 46.

GODOY, R. J. C. *Sintonia Ótima de Controladores*. Dissertação (Mestrado) — USP-SP, São Paulo, Brasil, 2012. Citado 4 vezes nas páginas 16, 17, 64 e 75.

GOLDBARG, M. C.; LUNA, H. P. L. *Otimização Combinatória e Programação Linear: Modelos e Algoritmos*. Rio de Janeiro, Brasil: Elsevier, 2005. Citado 2 vezes nas páginas 44 e 45.

GOLDBERG, D. *Genetic Algorithms in Search, Optimization and Machine Learning*. 1. ed. Boston, USA: Addison-Wesley Longman Publishing Co., 1989. Citado 2 vezes nas páginas 18 e 43.

GOMES, M. M. R. C. *Aplicação das Metaheurísticas PSO e AG na Estimação de Parâmetros de um Modelo de Secagem em Leito Fluidizado*. Dissertação. Dissertação (Dissertação de Mestrado) — Centro Federal DE Educação Tecnológica de Minas Gerais, Campinas, Brasil, 2007. Citado na página 57.

HEPPNER, F.; GRENANDER, U. stochastic nonlinear model for coordinated bird flocks. *American Association for the Advancement of Science*, 1990. Citado 2 vezes nas páginas 53 e 55.

ILAB. *Técnicas de Otimização*. 2016. Disponível em: <<http://www.ilab.com.br/tecnicas.html>>. Acesso em: 08 set. 2016. Citado 2 vezes nas páginas 41 e 42.

JOHNSON, M. A.; MORADI, M. Pid control - new identification and design. *Springer-Verlag, London*, 2005. Citado 2 vezes nas páginas 29 e 32.

JUANG, C. F.; WANG, C. Y. A self-generating fuzzy system with ant and particle swarm cooperative optimization. *Expert Systems with Applications*, v. 36, p. 5362–5370, 2009. Citado na página 58.

KAGUEYAMA, C. A. *Sintonia do Controlador PID: Método de Ziegler Nichols Modificado*. Dissertação (Trabalho de conclusão de curso) — Universidade Estadual de Londrina-PR, Londrina, Brasil, 2011. Citado na página 66.

KENNEDY, J. Thinking is social: Experiments with the adaptive culture model. *The Journal of Conflict Resolution*, v. 1, p. 56–76, 1998. Citado na página 53.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. *Proceedings of IEEE International Conference on Neural Networks*, p. 1942–1948, 1995. Citado 4 vezes nas páginas 52, 53, 54 e 55.

KIM, D. H.; ABRAHAM, A.; CHO, J. H. A hybrid genetic algorithm and bacterial foraging approach for global optimization. *Information Sciences*, v. 177, p. 3918–3937, 2007. Citado na página 52.

KWOK, N. M. et al. Optimal design of power system stabilizers using particle swarm optimization. *IEEE Trans Energy Conversion*, v. 17, p. 406–413, 2008. Citado na página 58.

LIU, G. P.; DALEY, S. Optimal-tuning pid control for industrial systems. *Control Engineering Practice*, v. 9, p. 1185–1194, 2001. Citado na página 17.

LUENBERGER, D. G.; YE, Y. *Linear and nonlinear programming*. New York, USA: Springer, 2008. Citado na página 44.

MALIK, O. P.; CHENG, S. J. Some issues on the practical use of the recursive least squares identification in self-tuning control. *International Journal of Control*, v. 53, p. 1021–1033, 1991. Citado na página 32.

MCCARTHY, J. et al. A proposal for the dartmouth summer research project on artificial intelligence. *Dartmouth Conferences*, v. 1, 1955. Citado na página 41.

MEDEIROS, J. A. C. C. *Enxame de Partículas como Ferramenta de Otimização em Problemas Complexos de Engenharia Nuclear*. Dissertação (Tese de Doutorado) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, 2005. Citado na página 18.

MELLO, A. G. S. *Aplicação de Redes Complexas para a Definição de Vizinhança na Otimização por Enxame de Partículas*. Dissertação (Dissertação de Mestrado) — Faculdade de Engenharia Elétrica e de Computação, Campinas, Brasil, 2010. Citado na página 54.

MICHIGAN, U. *Control Tutorials for MATLAB e SIMULINK*. 2014. Disponível em: <<http://ctms.engin.umich.edu/CTMS/index.php?example=Introduction§ion=ControlDigital>>. Acesso em: 28 nov. 2016. Citado 2 vezes nas páginas 66 e 68.

MILLONAS, M. M. Swarms, phase transitions and collective intelligence. In C.G. Langton(Ed), *Artificial Life III*, p. 417–445, 1994. Citado na página 52.

- MME. *Plano Nacional de Eficiência Energética*. 2011. Disponível em: <<http://www.epe.gov.br/PNE/Forms/AllItems.aspx>>. Acesso em: 02 jan. 2017. Citado na página 15.
- MURRAY, R. M. et al. Future directions in control in an information-rich world. *IEEE Control Systems Magazine*, v. 1, p. 20–23, 2003. Citado na página 26.
- NEDJAH, N. *Inteligência de enxame: PSO*. 2016. Disponível em: <<http://www.eng.uerj.br/~nadia/pso.pdf>>. Acesso em: 20 set. 2016. Nenhuma citação no texto.
- NILSON, J. "probabilistic logic," artificial intelligence. *Elsevier Science Publishers B.V.*, v. 1, p. 71–87, 1986. Citado na página 41.
- OBERES, D. 2013. Disponível em: <<https://br.pinterest.com/oberes/science/>>. Acesso em: 20 set. 2016. Nenhuma citação no texto.
- OCHI, L. S. Algoritmos genéticos: Origem e evolução. *Sociedade Brasileira de Matemática Aplicada e Computacional*, 1998. Citado na página 45.
- OGATA, K. *Engenharia de Controle Moderno*. 4. ed. Rio de Janeiro, Brasil: Prentice-Hall, 2003. Citado 3 vezes nas páginas 16, 72 e 73.
- OI, A. et al. Pid optimal tuning method by particle swarm optimization. *2008 SICE Annual Conference*, p. 3470–3473, 2008. Citado na página 17.
- OLIVEIRA, C. P. *Métodos Metaheurísticos Aplicados a um Modelo de Planejamento de Culturas*. Dissertação (Dissertação de Mestrado) — Universidade Estadual Paulista, São Paulo, Brasil, 2013. Citado 4 vezes nas páginas 43, 45, 46 e 51.
- OSMAN, I. H.; LAPORTE, G. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Computing Surveys*, v. 35, p. 268–308, 2003. Citado na página 46.
- PARSOPOULOS, K. E.; VRAHATIS, M. N. Recent approaches to global optimization problems through particle swarm optimization. *Natural Computing*, v. 1, p. 235–306, 2002. Citado na página 54.
- PASSINO, K.; YURKOVICH, S. *Fuzzy Control*. 1. ed. Columbus, EUA: Addison-Wesley Longman Publishing Co., 1997. Citado na página 18.
- PHAM, D. T. et al. The bees algorithm. *Technical Note, Manufacturing Engineering Centre, Cardiff University, UK*, 2005. Citado na página 52.
- PINTO, J. E. M. G. *Aplicação Prática do Método de Sintonia de Controladores PID utilizando o Método do Relé com Histerese*. Dissertação (Dissertação de Mestrado) — Universidade Federal do Rio Grande do Norte, Natal, Brasil, 2014. Citado 3 vezes nas páginas 32, 38 e 73.
- POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimization. *Swarm Intelligence*, v. 1, p. 33–57, 2007. Citado na página 54.
- POPESCU, D.; TAMBOZI, G.; PETRESCU, C. Some considerations about the refinements and the accuracy of pid controllers. *IFAC Digital Control: Past, Present and the Future of PID Control*, p. 247–252, 2000. Citado na página 30.

PRADO, J. R.; SARAMAGO, S. F. P. Otimização por colônia de partículas. *FAMAT em Revista*, v. 4, p. 87–103, 2005. Citado na página 57.

PROCEL. *Oportunidades de Negócios para a Indústria em Projetos de Eficiência Energética com MDL programático*. 2006. Disponível em: <<http://www.procelinfo.com.br>>. Acesso em: 10 agos. 2016. Citado na página 15.

REYNOLDS, C. W. Flocks, herds, and schools: a distributed behavioral model. *Computer Graphics*, v. 21, p. 25–34, 1987. Citado na página 55.

RIVERA, D. E.; MORARI, M.; SKOGESTAD, S. Internal model control. *PID Controller Design*, v. 1, p. 252–265, 1986. Citado 2 vezes nas páginas 35 e 37.

RU, N.; JIANHUNA, Y. A ga and particle swarm optimization based hybrid algorithm. *Proceedings of the 2008 IEEE Congress on Evolutionary Computation (CEC 2008)*, p. 1047–1050, 2008. Citado na página 58.

RUBAAI, A. Design and implementation of parallel fuzzy pid controller for high-performance brushless motor drivers: An integrated environment for rapid control prototyping. *IEEE Transactions on Industrial Electronics* 44, p. 1090–1098, 2008. Citado na página 16.

SERAPIÃO, A. B. S. Fundamentos de otimização por inteligência de enxames: Uma visão geral. *UNESP, IGCE, DEMAC, Rio Claro, São Paulo*, 2011. Citado na página 52.

SHI, Y.; EBERHART, R. C. Comparison between genetic algorithm and particle swarm optimization. *Evolutionary Programming VII: Proceedings of the Seventh Annual Conference on Evolutionary Programm*, p. 611–616, 1998. Citado 5 vezes nas páginas 18, 55, 56, 57 e 85.

SHIRAHIGE, A. B. *Metodologia para Aferição da Ação de Controle Proporcional Integrak Derivativa implementada em Controladores Industriais*. Dissertação (Dissertação de Mestrado) — USP-SP, São Paulo, Brasil, 2007. Citado na página 29.

SIEMENS. *Standard PID Control Manual*. 2003. Disponível em: <http://cache.industry.siemens.com/dl/files/084/1137084/att_27126/v1/Stdpid_e.pdf>. Acesso em: 28 nov. 2016. Nenhuma citação no texto.

SKOGESTAD, S. Simple analytic rules for model reduction and pid controller tuning. *Modeling, Identification and Control*, v. 2, p. 85–120, 2004. Citado 2 vezes nas páginas 17 e 35.

SOUZA, M. J. F. *Inteligência Computacional para Otimização*. Dissertação (Notas de aula) — UFOP, Ouro Preto, Brasil, 2005. Citado na página 46.

SUCUPIRA, I. R. *Métodos Heurísticos Genéricos: Meta-heurística e Hiper-metaheurística*. Dissertação (Monografia) — USP, São Paulo, Brasil, 2004. Citado na página 46.

SUNG, S. W.; LEE, T.; PARK, S. Optimal pid controller tuning method for single-input/single-output processes. *AIChE Journal*, v. 48, p. 1358–1361, 2002. Citado na página 17.

TAN, K. K.; LEE, T. H.; JIANG, X. Online relay identification, assessment and tuning of pid controller. *Journal of Process Control*, v. 11, p. 483–496, 2001. Citado na página 33.

THANH, B. T.; PARNICKUN, M. Balancing control of bicyrobo by particle swarm optimization-based structure-specified mixed control. *International Journal of Advanced Robotic Systems*, v. 5, p. 395–402, 2008. Citado na página 58.

THIMOTIO, F. S. *Simulated Annealing Aplicado ao problema de sintonia de parâmetros de controladores PID*. Dissertação (Monografia) — USP-SP, Ouro Preto, Brasil, 2005. Citado na página 33.

TRELEA, I. O. The particle swarm optimization algorithm: convergence analysis and parameter selection. *Information Processing Letters*, v. 85, p. 317–325, 2003. Citado 2 vezes nas páginas 56 e 57.

TURING, A. M. Computing machinery and intelligence. *Mind*, p. 433–460, 1950. Citado na página 41.

VANDORE, V. *Auto-tuning control using ziegler nichols*. 2006. 9th IEEE/AS International Conference on Industry Applications. Disponível em: <<http://www.controleng.com/article/CA6378136.html>>. Acesso em: 02 nov. 2016. Citado na página 32.

WANG, J. et al. Arma model identification using particle swarm optimization algorithm. *Proceedings of the International Conference on Computer Science and Information Technology*, p. 223–227, 2008. Citado na página 58.

WICKRAMASINGHE, W.; LI, X. Choosing leaders for multi-objective pso algorithms using differential evolution. *Lecture Notes in Artificial Intelligence*, v. 5361, p. 249–258, 2008. Citado na página 58.

WILSON, E. O. *Sociobiology: The new synthesis*. Belknap Press, Cambridge, MA, p. 1942–1948, 1975. Citado na página 55.

WINSTON, P. H.; BROWN, R. H. Review of "artificial intelligence: An mit perspective, volume 1: Expert problem solving, natural language understanding, intelligent computer coaches, representation and learning. *The MIT Press, Cambridge, Massachusetts*, v. 1, p. 24–26, 1979. Citado na página 41.

WRIGHT, S. J.; NOCEDAL, J. *Numerical optimization*. 2. ed. New York, USA: Springer-Verlag, 1999. Citado 2 vezes nas páginas 43 e 44.

XENERGY. *Final Report: Commercial Lighting Market Effects Study*. San Diego, EUA: San Diego Gas and Electric Company and Pacific Gas, 1998. Citado na página 20.

XU, G.; GAO, J. Weak signal detection based on a new matching pursuit method. *Proceedings of the 7th International Conference on Machine Learning and Cybernetics*, v. 17, p. 406–413, 2008. Citado na página 58.

ZIEGLER, J. G.; NICHOLS, N. Optimum settings for automatic controllers. *Transactions ASME*, v. 64, p. 759–768, 1942. Citado 4 vezes nas páginas 17, 33, 35 e 61.

ZUBEN, F. V.; CASTRO, L. *Computação Evolutiva: Uma “Nova” Forma de Resolver Problemas*. Dissertação (Tese de Doutorado) — DCA/FEEC/Unicamp, São Paulo, Brasil, 2004. Citado na página 50.