PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ ESCOLA POLITÉCNICA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO E SISTEMAS

RICARDO MASSAO KAGAMI

Análise de Algoritmos Evolucionários na Parametrização de Controladores

Aplicados a Sistemas Térmicos Através de Procedimentos da Otimização

Multiobjetivo

RICARDO MASSAO KAGAMI

Análise de Algoritmos Evolucionários na Parametrização de Controladores Aplicados a Sistemas Térmicos Através de Procedimentos da Otimização Multiobjetivo

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas Área de concentração: Otimização, Modelagem e Controle de Sistemas, da Escola Politécnica, da Pontifícia Universidade Católica do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: Prof. Dr. Roberto Zanetti Freire Coorientador: Prof. Dr. Eduardo Alves Portela Santos

CURITIBA 2019

Dados da Catalogação na Publicação Pontifícia Universidade Católica do Paraná Sistema Integrado de Bibliotecas – SIBI/PUCPR Biblioteca Central Luci Eduarda Wielganczuk – CRB 9/1118

Kagami, Ricardo Massao

K11a Análise de algoritmos evolucionários na parametrização de controladores
 2019 aplicados a sistemas térmicos através de procedimentos da otimização multiobjeto / Ricardo Massao Kagami; orientador: Roberto Zanetti Freire; coorientador: Eduardo Alves Portela Santos. – 2019.

97 f.: il.; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Paraná,
Curitiba, 2019
Bibliografia: f. 89-97

Controladores PID. 2. Otimização. 3. Algoritmos. I. Freire, Roberto
 Zanetti. II. Santos, Eduardo Alves Portela. III. Pontifícia Universidade Católica
 do Paraná. Programa de Pós-Graduação em Engenharia de Produção e
 Sistemas. VI. Título.

CDD 22. ed. - 629.8

GRUPO MARISTA

TERMO DE APROVAÇÃO

Ricardo Massao Kagami Zanotto

ANÁLISE DE ALGORITMOS EVOLUCIONÁRIOS NA PARAMETRIZAÇÃO DE CONTROLADORES APLICADOS A SISTEMAS TÉRMICOS ATRAVÉS DE PROCEDIMENTOS DA OTIMIZAÇÃO MULTIOBJETIVO.

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Curso de Mestrado em Engenharia de Produção e Sistemas, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, da Escola Politécnica da Pontifícia Universidade Católica do Paraná, pela seguinte banca examinadora:

Presidente da Banca Prof. Dr. Roberto Zanetti Freire (Orientador)

Prof. Dr. Eduardo Alves Portela Santos (Coorientador)

Prof. Dr. Gilberto Reynoso-Meza (Membro Interno)

Prof. Dr. Emerson D**ø**naisky

(Membro Externo / Dep. Eng. Controle e Automação / PUCPR)

Prof. Dr. Gustavo Henrique da Costa Oliveira (Membro Externo / PPGEE / UFPR)

Curitiba, 31 de julho de 2019.

Dedico este trabalho às senhoras Elena
Tizuko Kagami, Emilia Nobuko Kagami e
Eva Mieko Kagami.
Dedico este trabalho especialmente ao
Professor Salmo Pustilnick, uma das
pessoas mais incríveis que conheci.

AGRADECIMENTOS

Agradeço ao Professor Roberto Zanetti Freire, meu orientador, pela dedicação e auxílio aplicados a mim, fazendo de mim uma pessoa mais madura, ao Professor Eduardo Alves Portela Santos que me acompanhou e aconselhou, tornando a mim uma pessoa mais prudente, ao Professor Gilberto Reynoso-Meza, pela boa vontade e paciência, transformando a mim em uma pessoa mais sensata, à Professora Maria Angela Moscalewski Roveredo pela boa vontade e apoio, ensinando a mim, a felicidade de ensinar.

A todos os professores e professoras que aqui não citei, mas contribuíram para minha formação, meus mais sinceros agradecimentos.

Notavelmente, meus agradecimentos às senhoras Elena Tizuko Kagami, Emilia Nobuko Kagami, Eva Mieko Kagami, Eliza Tiyoka Kagami e Célia Sadako Kagami, aos senhores Pedro Kagami Kraft e Emilio Kraft e a todos os parentes e amigos que aqui não citei, mas que guardam lugar especial em minha vida.

Meu agradecimento especial a Renan Muniz Franco, Thauan Cesar, Marlon Oliveira e Felipe Gobatto, meus irmãos perpétuos.

The emphasis on the different factors depends on the particular problem.

Robustness is important for all applications.

(Åström & Hägglund, 2006, p.122)

RESUMO

Controladores do tipo Proporcional-Integral-Derivativo (PID) são amplamente utilizados nos mais diversos tipos de sistemas. A sintonia de controladores deste tipo é uma área de interesse tanto da indústria quanto acadêmica, uma vez que a parametrização dos ganhos, quando feita de forma eficiente, pode trazer vantagens. Dentre as vantagens relacionadas a correta parametrização dos ganhos de um controlador PID, podem ser citadas a redução do consumo de energia referente a operação de uma máquina ou equipamento e a redução do desgaste de seus componentes. O procedimento de parametrização pode ser realizado através de métodos clássicos ou por meio de procedimentos de otimização. O presente trabalho visa a parametrização de controladores PID através de procedimentos utilizados na resolução de problemas multiobjetivo, todavia, considera-se neste trabalho algoritmos evolucionários mono-objetivo para resolver o problema relacionado à sintonia de controladores. Tais problemas são tidos como multiobjetivo, pois usualmente consideram-se critérios que apresentam conflitos como a capacidade de redução de erros de referência e a rejeição de ruídos provenientes do processo, uma vez que ambos visam a minimização desses critérios. De modo a obter uma solução factível a análise sobre a Fronteira de Pareto pode ser realizada, ou ainda, técnicas de agregação das funções custo, através da ponderação, ou pelo uso de métodos de tomada de decisão multicritério, como a Técnica de Ordenação de Preferência de Alternativas pela Semelhança com a Solução Ideal (TOPSIS), podem ser aplicadas no algoritmo de otimização, obtendo, portanto, uma única solução que baseia-se nos interesses do avaliador. As metaheurísticas selecionadas neste estudo foram a Evolução Diferencial (DE), Evolução Diferencial Ponderada (WDE), Algoritmo Genético (GA), Algoritmo Genético com Crossover Multi-Precursores (GA-MPC) e Competição por Recursos (COR), aplicados em três benchmarks de controle. O primeiro estudo de caso diz respeito a um aquecedor elétrico, o segundo a um trocador de calor e o terceiro a um sistema de refrigeração. Os principais resultados deram-se pela aplicação das metaheurísticas selecionadas para a solução dos problemas propostos e posteriormente a comparação de soluções medianas encontradas para dois dos benchmarks descritos, sendo que os resultados obtidos pelos algoritmos DE, GA-MPC e COR obtiveram desempenho superior aos controladores de referência, o algoritmo GA obteve solução que não atendeu ao critério de robustez de controle e o WDE apresentou resultados dominados para todo o conjunto de métricas avaliadas. Por fim, para o terceiro benchmark, o método proposto foi utilizado na parametrização de dois controladores com estrutura descentralizada, tendo os algoritmos WDE e COR juntos ao método TOPSIS resultado em soluções com melhor desempenho quando comparado aos controladores referência e a outros propostos na literatura, estes utilizando estruturas diversas e métodos de otimização multiobjetivo com análise da Fronteira de Pareto.

Palavras-chave: Controladores PID. Otimização. Algoritmos Evolucionários.

ABSTRACT

Proportional-Integral-Derivative (PID) controllers are available in a vast quantity of systems. The tuning methodology of this type of controller is a matter of interest of both industrial and academic areas, given that the efficient parametrization of gains can provide interesting benefits. Some advantages related to the correct tuning of PID controllers are the reduction of both energy consumption of the aforementioned machines and equipment degradation. The parametrization process can be achieved through classical methods or by means of optimization procedures. This work encompasses the parametrization of PID controllers by using procedures applied to solve multi-objective problems. In this study, evolutionary algorithms for singleobjective applications are considered for solving distinct controller tuning problems. These problems were approached as multi-objective, because usually they involve conflicting objective functions, like de reduction capability of reference errors and the rejection of interference from the process, since both aim for minimization of these criteria. In order to obtain a feasible solution, a Pareto Frontier analyses can be realized, or the use of a cost function aggregation procedures through weighting methods, or additionally by the use of a multicriteria decision making strategies. In this work, the Technique for Order Preference by Similarity to Ideal Solution (TOPSIS) was assumed as a way to obtain a single solution based on the appraiser interests. The selected metaheuristics that were evaluated in this study are Differential Evolution (DE), Weighted Differential Evolution (WDE), Genetic Algorithm (GA), Genetic Algorithm with Multiparent Crossover (GA-MPC) and Competition Over Resources (COR), those applied to three control benchmarks. The first one refers to an electrical heater, the second is a heater exchanger and the last a refrigeration system. After the application of the selected metaheuristics to solve the proposed problems, a comparison based on the median solutions for two benchmarks were described, where the results obtained by the algorithms DE, GA-MPC and COR showed a better performance of the proposed method when compared to the reference controller. The GA algorithm provided a solution that did not attend the criterion of control robustness. and the WDE showed dominated results in all metrics. Finally, in the third benchmark, the proposed approach was used to tune two controllers in a decentralized structure, where WDE and COR algorithms with TOPSIS method provided better solutions in terms of performance criteria when compared to both the reference controller and other control strategies proposed in the specialized literature, even considering multiobjective optimization with Pareto Frontier analyses.

Keywords: PID Controllers. Optimization. Evolucionary Algorithms.

LISTA DE ILUSTRAÇÕES

Figura 1 - Controle em malha aberta
Figura 2 - Controle em malha fechada
Figura 3 - Controle em malha fechada completo
Figura 4 - Diagrama de blocos Controle PID11
Figura 5 - Malha de controle generalista12
Figura 6 - Fronteira de Pareto
Figura 7 - Procedimentos para otimização de controladores19
Figura 8 - Busca do caminho mínimo
Figura 9 - Esquemático do sistema de controle Aquecedor Elétrico27
Figura 10 - Diagrama de Controle Aquecedor Elétrico
Figura 11 – Esquemático do sistema de controle Trocador de Calor29
Figura 12 - Diagrama de controle Trocador de Calor30
Figura 13 - Representação do sistema de refrigeração32
Figura 14 - Diagrama genérico de controle51
Figura 15 - Metodologia de otimização multiobjetivo por algoritmo mono-objetivo54
Figura 16 - Conceito do método TOPSIS55
Figura 17 - Melhor de 5 experimentos aquecedor elétrico: (a) resposta ao degrau; (b)
sinal de controle58
Figura 18 – Análise estatística do algoritmo DE para o benchmark I - aquecedor
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS60
Figura 19 - Análise estatística do algoritmo WDE para o benchmark I - aquecedor
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS61
Figura 20 - Análise estatística do algoritmo GA para o benchmark I - aquecedor
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS62
Figura 21 - Análise estatística do algoritmo GA-MPC para o benchmark I - aquecedor
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS63
Figura 22 - Análise estatística do algoritmo COR para o benchmark I - aquecedor
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS64
Figura 23 – Controladores da mediana – aquecedor elétrico: (a) resposta ao degrau;
(b) sinal de controle65
Figura 24 - Métricas de desempenho aquecedor elétrico

Figura 25 - Análise estatística do algoritmo GA-MPC para o benchmark II -	
aquecedor elétrico: (a) IAE; (b) IAUV; (c) TOPSIS	.68
Figura 26 - Análise estatística do algoritmo DE para o benchmark II - aquecedor	
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS	.69
Figura 27 - Análise estatística do algoritmo WDE para o benchmark II - aquecedor	
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS	.70
Figura 28 - Análise estatística do algoritmo COR para o benchmark II - aquecedor	
elétrico: (a) IAE; (b) IAUV; (c) TOPSIS	.71
Figura 29 - Controladores da mediana – trocador de calor: (a) resposta ao degrau;	ı
(b) sinal de controle	.72
Figura 30 - Métricas de desempenho trocador de calor	.74
Figura 31 - Controladores da mediana – trocador de calor sujeito a distúrbios: (a)	
resposta ao degrau; (b) sinal de controle	.74
Figura 32 - Modelo paramétrico para o sistema de refrigeração	.76
Figura 33 – Controlador de WDE: (a) temperatura do fluxo secundário do	
evaporador; (b) grau de superaquecimento	.78
Figura 34 – Controlador de WDE: (a) velocidade do compressor; (b) abertura da	
válvula de expansão	.78
Figura 35 - Controlador de WDE: (a) pressão no condensador; (b) pressão no	
evaporador	.79
Figura 36 – Controlador de WDE desempenho térmico: (a) potência refrigerante no	O
evaporador; (b) potência mecânica no compressor; (c) potência térmica no	
condensador; (d) fluxo mássico refrigerante	.80
Figura 37 – Controlador de WDE: (a) eficiência do compressor; (b) coeficiente de	
desempenho	.80
Figura 38 – Controlador de COR: (a) temperatura do fluxo secundário do	
evaporador; (b) grau de superaquecimento	.81
Figura 39 – Controlador de COR: (a) velocidade do compressor; (b) abertura da	
válvula de expansão	.82
Figura 40 – Controlador de COR: (a) pressão no condensador; (b) pressão no	
evaporador	.83
Figura 41 – Controlador de COR desempenho térmico: (a) potência refrigerante no)
evaporador; (b) potência mecânica no compressor; (c) potência térmica no	
condensador: (d) fluxo mássico refrigerante.	.83

Figura 42 – Controlador de COR: (a) eficiência do compressor; (b) coeficiente de	
desempenho8	84

LISTA DE ALGORITMOS E TABELAS

Algoritmo 1 - Pseudocódigo da DE	38
Algoritmo 2 - Pseudocódigo da WDE	42
Algoritmo 3 - Pseudocódigo do GA	44
Algoritmo 4 - Pseudocódigo do GA-MPC	47
Algoritmo 5 - Pseudocódigo da COR	50
Tabela 1 - Variáveis manipuladas, distúrbios e variáveis de saída do sistema	de
refrigeração	33
Tabela 2 - DE aquecedor elétrico 5 experimentos	56
Tabela 3 - WDE aquecedor elétrico 5 experimentos	56
Tabela 4 - GA aquecedor elétrico 5 experimentos	57
Tabela 5 - GA-MPC aquecedor elétrico 5 experimentos	57
Tabela 6 - COR aquecedor elétrico 5 experimentos	57
Tabela 7 - Testes de estabilidade e robustez melhor de 5	58
Tabela 8 - DE análise quantitativa aquecedor elétrico	60
Tabela 9 - WDE análise quantitativa aquecedor elétrico	61
Tabela 10 - GA análise quantitativa aquecedor elétrico	62
Tabela 11 - GA-MPC análise quantitativa aquecedor elétrico	63
Tabela 12 - COR análise quantitativa aquecedor elétrico	64
Tabela 13 - Critérios de estabilidade e robustez aquecedor elétrico	66
Tabela 14 - Métricas de desempenho aquecedor elétrico	66
Tabela 15 - GA-MPC análise quantitativa trocador de calor	69
Tabela 16 - DE análise quantitativa trocador de calor	70
Tabela 17 - WDE análise quantitativa trocador de calor	71
Tabela 18 - COR análise quantitativa trocador de calor	72
Tabela 19 - Critérios de estabilidade e robustez trocador de calor	73
Tabela 20 - Métricas de desempenho trocador de calor	73
Tabela 21 - Índices de desempenho WDE sistema de refrigeração	85
Tabela 22 - Índices de desempenho COR sistema de refrigeração	85
Tabela 23 - Índices agregados das soluções propostas para o sistema de	
refrigeração	86

LISTA DE ABREVIATURAS E SIGLAS

C-H-R Chien-Hrone-Reswick

CEC Congresso de Computação Evolucionária – Congress on Evolutionary

Computation

COP Coeficiente de Desempenho – Coefficient of Performance

COR Competição por Recursos – Competition Over Resources

DE Evolução Diferencial – Differential Evolution

GA Algoritmo Genético – Genetic Algorithm

GA-MPC Algoritmo Genético com Crossover Multi-Precursores - Genetic

Algorithm with Multiparent Crossover

IFAC Federação Internacional de Controle Automático - International

Federation of Automatic Control

IMC Método do Modelo Interno – Internal Model Control

MOEAs Algoritmos Evolucionários Multiobjetivo – *Multiobjective Evolutionary*

Algorithms

PID Proporcional-Integral-Derivativo

TOPSIS Técnica de Ordenação de Preferência de Alternativas pela

Semelhança com a Solução Ideal – *Technique for Order Preference*

by Similarity to Ideal Solution

WDE Evolução Diferencial Ponderada – Weighted Differential Evolution

Z-N Ziegler-Nichols

SUMÁRIO

RESU	JMO	7
ABST	RACT	8
LISTA	A DE ILUSTRAÇÕES	9
LISTA	A DE ALGORITMOS E TABELAS	12
LISTA	A DE ABREVIATURAS E SIGLAS	13
SUMA	ÁRIO	14
1	INTRODUÇÃO	1
1.1	PROBLEMATIZAÇÃO	3
1.2	JUSTIFICATIVA	4
1.3	OBJETIVOS	4
1.3.1	Objetivo Geral	4
1.3.2	Objetivos Específicos	4
1.4	PROCEDIMENTOS METODOLÓGICOS	5
1.5	ORGANIZAÇÃO DA DISSERTAÇÃO	5
2	REVISÃO DE LITERATURA	7
2.1	SISTEMAS DE CONTROLE	7
2.1.1	Controle PID	10
2.1.2	Métricas de comparação e avaliação de controladores	11
2.2	PROBLEMAS DE OTIMIZAÇÃO	14
2.2.1	Otimização Mono-objetivo	14
2.2.2	Otimização Multiobjetivo	15
2.2.3	Procedimentos para projetos de otimização multiobjetivo	19
2.2.3.	1 Definição do Problema Multiobjetivo	19
2.2.3.	2 Processo de Otimização Multiobjetivo	20
2.2.3.	3 Tomada de Decisão Multicritério	21
2.3	COMPUTAÇÃO EVOLUCIONÁRIA	22
2.3.1	Algoritmos Evolucionários	22
2.3.1.	1 Principais Algoritmos	24
2.3.1.	2 Mecanismos de Evolução	24
3	ESTUDOS DE CASO	26
3.1	BENCHMARKS DE CONTROLE	26
3.1.1	Aquecedor Elétrico	26

3.1.2	Trocador de Calor	28
3.1.3	Sistema de Refrigeração	31
3.2	ALGORITMOS DE OTIMIZAÇÃO EVOLUCIONÁRIOS	36
3.2.1	Evolução Diferencial	36
3.2.2	Evolução Diferencial Ponderada	39
3.2.3	Algoritmo Genético	43
3.2.4	Algoritmo Genético com Crossover Multi-Precursores	44
3.2.5	Competição por Recursos	47
3.3	CRITÉRIOS DE OTIMIZAÇÃO COM RESTRIÇÕES	50
4	RESULTADOS	53
4.1	BENCHMARK I: AQUECEDOR ELÉTRICO	
4.1.1	Análises Qualitativa e Quantitativa de Convergência dos Algoritmos.	59
	Análise de Sensibilidade e Robustez dos Controladores	
4.1.2		65
4.1.2	Análise de Sensibilidade e Robustez dos Controladores	65 66
4.1.2 4.1.3	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções	65 66 67
4.1.2 4.1.3 4.2 4.2.1	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções BENCHMARK II: TROCADOR DE CALOR	65 66 67
4.1.2 4.1.3 4.2 4.2.1 4.2.2	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções BENCHMARK II: TROCADOR DE CALOR Análises Estatísticas e de Convergência Análise das Restrições de Sensibilidade e Robustez	65 66 67 68
4.1.2 4.1.3 4.2 4.2.1 4.2.2	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções BENCHMARK II: TROCADOR DE CALOR Análises Estatísticas e de Convergência	65 66 67 68 72
4.1.2 4.1.3 4.2 4.2.1 4.2.2 4.2.3 4.3	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções BENCHMARK II: TROCADOR DE CALOR Análises Estatísticas e de Convergência Análise das Restrições de Sensibilidade e Robustez Comparação entre os Algoritmos	65 66 67 68 72 73
4.1.2 4.1.3 4.2 4.2.1 4.2.2 4.2.3 4.3	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções BENCHMARK II: TROCADOR DE CALOR Análises Estatísticas e de Convergência Análise das Restrições de Sensibilidade e Robustez Comparação entre os Algoritmos BENCHMARK III: SISTEMA DE REFRIGERAÇÃO.	65 67 68 72 73
4.1.2 4.1.3 4.2 4.2.1 4.2.2 4.2.3 4.3	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções BENCHMARK II: TROCADOR DE CALOR Análises Estatísticas e de Convergência Análise das Restrições de Sensibilidade e Robustez Comparação entre os Algoritmos BENCHMARK III: SISTEMA DE REFRIGERAÇÃO. Análise Qualitativa das Soluções Factíveis	65 67 68 72 75 75
4.1.2 4.1.3 4.2 4.2.1 4.2.2 4.2.3 4.3 4.3.1 4.3.2 5	Análise de Sensibilidade e Robustez dos Controladores Comparação das Soluções BENCHMARK II: TROCADOR DE CALOR Análises Estatísticas e de Convergência Análise das Restrições de Sensibilidade e Robustez Comparação entre os Algoritmos BENCHMARK III: SISTEMA DE REFRIGERAÇÃO Análise Qualitativa das Soluções Factíveis Análise Quantitativa de Índices Agregados	65 67 68 72 75 75 75

1 INTRODUÇÃO

Os sistemas de controle estão presentes nas mais diversas situações de nosso cotidiano, como nas máquinas capazes de regular suas condições de funcionamento, desde geladeiras e sistemas de climatização que buscam manter a temperatura constante em um espaço, até em veículos autônomos que seguem de uma rota prédeterminada. Contudo, estes sistemas estão presentes também no mundo biológico, da capacidade de regulação de açúcar no sangue, através do pâncreas, à constância da temperatura corpórea pela queima de calorias (NISE, 2014).

Para o mundo contemporâneo, os sistemas de controle automático tornaramse uma ferramenta essencial, provendo a precisão das máquinas cirúrgicas e a agilidade dos processos de manufatura. Para tanto, diversas estruturas de controle, das mecânicas, hidráulicas e pneumáticas às eletrônicas foram estudadas e aperfeiçoadas (OGATA, 2010).

Dentre os diversos tipos de controladores, os do tipo Proporcional-Integral-Derivativo (PID) apresentam uma abordagem consistente na resolução de problemas de controle industriais, devido principalmente à sua simplicidade de projeto, eficiência, usabilidade e robustez (CASTRUCCI; BITTAR; SALES, 2011). A ação de controle PID baseia-se na combinação dos erros atuante, passado e futuro, obtido pela diferença de uma referência passada para o sistema e a resposta apresentada por este, de modo a calcular o sinal de controle e a satisfazer os requerimentos de projeto e restrições associadas ao problema de controle (ADHEEM; IBRAHEEM, 2017).

Diversas técnicas foram propostas para o ajuste de ganhos de controladores PID, fazendo com que a evolução das estratégias de parametrização estejam constantemente em evidência, tanto em âmbito acadêmico quanto na área industrial (ÅSTRÖM, K. J.; HÄGGLUND, 2001; RASMUSSEN, 2002; SHAHROKHI; ZOMORRODI, 2010; SEN *et al.*, 2015; CHIDAMBARAM; SAXENA, 2018).

A parametrização de controladores PID segue de uma longa história, desde o método de Ziegler-Nichols (Z-N) proposto por Ziegler e Nichols (1942), passando por várias técnica de sintonia direta de ganhos. Alguns exemplos comumente aplicados para esta função são os métodos: C-H-R (CHIEN; HRONS; RESWICK, 1952), Cohen-Coon (COHEN; COON, 1953), Método do Modelo Interno (IMC – *Internal Model Control*) (MORARI; ZAFIRIOU, 1989), Ciancone & Marlin (MARLIN, 1992) e Tyreus-Luyben (LUYBEN; LUYBEN, 1997).

Devido à grande quantidade de métodos existentes e a dificuldade de identificação e seleção de um único método que melhor se adaptasse a diferentes tipos de processos e dinâmicas, estudos foram realizados objetivando comparar critérios de desempenho de diferentes técnicas. Como o trabalho apresentado por Tan, Liu, Chen, & Marquez (2006), que avaliou critérios de erro dos métodos Ziegler-Nichols, Cohen-Coon, IMC, Margem de Ganho de Fase e Erro Integral Ótimo na parametrização de um controlador PID para um processo de primeira ordem com atraso de transporte. No trabalho proposto por Youney (2007), as técnicas de Ziegler-Nichols em malha aberta e fechada, C-H-R e o método da regra da experiência foram aplicados em três sistemas, o primeiro um sistema defasado de segunda ordem com integrador, o segundo um sistema de ordem elevada e o terceiro um sistema de ordem elevada com defasagens variadas em série. A análise proposta foi feita com o objetivo de verificar se os quatro métodos seriam capazes de obter controladores capazes de estabilizar as plantas.

No trabalho de Foley, Julien e Copeland (2010), onze diferentes métodos de sintonia de controladores PID foram testados em modelos de primeira, segunda e terceira ordens com atraso de transporte, avaliando-se os critérios de erro, de capacidade em seguir a referência e de rejeição a perturbações de carga. No artigo de Sen *et al.* (2015), os métodos de Z-N, C-H-R e Cohen-Coon foram testados quanto à capacidade de controlar a posição de um sistema metrológico de alta precisão.

Ainda que as mais diversas técnicas de sintonia PID estejam disponíveis e estudos exaustivos tenham sido realizados de modo a avaliar o desempenho desses métodos quando aplicados ao controle de diferentes processos, uma grande quantidade de controladores existentes, aproximadamente 66% dos controladores usados na indústria norte americana no ano de 2011, segundo Desborough e Miller (2011), estavam operando em condições insatisfatórias de desempenho, sendo que no ano de 2016, o valor típico de controladores nestas condições saltou para 75% segundo Starr, Petersen e Bauer (2016) gerando efeitos indesejados na qualidade da operação e/ou produto e, ainda assim, sendo negligenciados em muitas plantas industriais (HUGO, 2001).

As mudanças recentes da tecnologia, tais como o incremento da capacidade de processamento computacional, velocidade de comunicação e sensoriamento proveram a possibilidade de utilização de técnicas mais avançadas de sintonia de controladores, possibilitando a utilização da computação evolucionária como uma

ferramenta acessível na parametrização dos mesmos, os quais apresentam quando sintonizados a partir destas técnicas, em linhas gerais, melhor desempenho quando comparados aos métodos clássicos (RIBEIRO *et al.*, 2017).

A computação evolucionária como uma ferramenta de parametrização de controladores está sujeita à essência de um problema de otimização multiobjetivo, tornando-se uma ferramenta valiosa para a engenharia de controle (REYNOSO-MEZA; SÁNCHEZ; *et al.*, 2014); uma vez que sua utilização não limita-se à obtenção de uma única solução, possibilitando a exploração de um conjunto amplo de soluções condicionadas a diferentes restrições e/ou objetivos.

Sendo a computação evolucionária aplicável a problemas de controle, tem-se que uma das definições de controle inteligente refere-se à utilização de ferramentas de inteligência computacional para propósitos da engenharia de controle (REYNOSO-MEZA et al., 2016), de forma que uma das tarefas fundamentais do controle inteligente relaciona-se ao problema da sintonia de controladores (JIMÉNEZ et al., 2015; SABZI et al., 2016). Tal problema consiste na obtenção de parâmetros que satisfaçam as especificações de projeto em uma solução factível a partir de uma estrutura de controle estabelecida.

1.1 PROBLEMATIZAÇÃO

Levando em conta a possibilidade de utilização de algoritmos de inteligência computacional na parametrização de controladores, a seleção do algoritmo adequado para aplicação na otimização é, muitas vezes, um processo pouco explorado.

Uma vez que muitas são as possibilidades, cada qual com diferentes mecanismos de evolução e de análise do espaço de busca, fazendo com que nem todos sejam adequados para esta aplicação. De tal forma, não são definidos padrões quanto à escolha de algoritmos adequados para a utilização na parametrização de controladores PID.

Selecionar um algoritmo apropriado, que satisfaça as necessidades quanto à parametrização de controladores PID, requer um esforço relacionado à realização de testes exaustivos de convergência e análise da distribuição dos resultados(REYNOSO-MEZA; SÁNCHEZ; et al., 2014), tal seleção deve relevar os mecanismos de exploração global e local realizados no processo de otimização, fato tal, por vezes, não considerado.

1.2 JUSTIFICATIVA

A justificativa do desenvolvimento deste trabalho dá-se pela formalização de procedimentos para a análise de desempenho na parametrização de controladores PID, este realizado através de algoritmos evolucionários com avaliação dos critérios de estabilidade e robustez. Diversas variações de algoritmos, bem como as diferentes estratégias de análise do espaço de busca, podem resultar em soluções aplicáveis ao modelo identificado, não capazes de atenuar distúrbios e não robustas às variações no processo, em relação ao desempenho dinâmico em função do tempo.

Desta forma, a contribuição deste trabalho visa fornecer um benefício quanto ao tempo e esforço aplicados na seleção do algoritmo mais adequado, quando em face a problemas de maior complexidade.

1.3 OBJETIVOS

Esta seção descreve os objetivos geral e específicos deste trabalho de dissertação de mestrado.

1.3.1 Objetivo Geral

O objetivo geral deste trabalho consiste na avaliação de procedimentos de otimização multiobjetivo auxiliado por metaheurísticas mono-objetivo, aplicadas a problemas de controle de sistemas.

1.3.2 Objetivos Específicos

Os objetivos específicos são:

- Identificar um conjunto de processos de sistemas térmicos para definir um benchmark de avaliação de controladores;
- Selecionar um conjunto de metaheurísticas que possuam relevância de estudo quanto aos processos de parametrização de controladores para validação quanto aos benchmarks propostos;
- Verificar estatisticamente a convergência e distribuição de soluções dos resultados dos controladores otimizados perante as superfícies de funções custo para cada um dos algoritmos estudados;

 Confrontar as soluções obtidas quanto à factibilidade dos critérios de estabilidade e robustez e/ou outros controladores apresentados na literatura, de modo a limitar o espaço de seleção para sistemas mais complexos.

1.4 PROCEDIMENTOS METODOLÓGICOS

A realização do presente trabalho deu-se inicialmente pela revisão de literatura sobre os tópicos de otimização e seus formalismos, estes referentes à otimização mono e multiobjetivo e procedimentos sistemáticos para a aplicação em projetos de otimização multiobjetivo. Além disso, a teoria sobre computação evolucionária, seus conceitos e mecanismos de funcionamento, sistemas de controle, aplicações e métricas para avaliação de desempenho também foram abordadas.

Posteriormente, foram apresentados benchmarks de controle, tais quais seus detalhamentos e relevância para o estudo, seguido pela descrição de cinco algoritmos evolucionários e a explanação de seus respectivos métodos de funcionamento e critérios de avaliação de estabilidade e robustez de controladores, tais algoritmos foram selecionados baseando-se em sua visibilidade na área de estudo, para os algoritmos clássicos, Evolução Diferencial e Algoritmo Genético, e uma versão recente dos mesmos, com modificações que, segundo os autores, melhoram a convergência dos mesmos e, o último algoritmo selecionado, por apresentar uma interessante abordagem de exploração local em torno das melhores soluções.

Os algoritmos foram aplicados para a parametrização dos controladores, utilizando-se de uma técnica de agregação das funções custo por meio de um método de auxílio à tomada de decisão multicritério, sendo realizados testes estatísticos para análise da tendência de soluções obtidas.

1.5 ORGANIZAÇÃO DA DISSERTAÇÃO

No capítulo 2 é apresentada uma breve revisão da literatura, a qual apresenta os conceitos básicos necessários ao entendimento dos tópicos de problemas de otimização, computação evolucionária e sistemas de controle. Os problemas de otimização são definidos a partir da otimização mono-objetivo e posteriormente generalizados para problemas multiobjetivo, descrevendo assim as características de respostas obtidas para condições na qual os objetivos a serem atendidos apresentam,

ao menos, conflitos parciais entre si, introduzindo, portanto, o conceito de Fronteira de Pareto.

O capítulo 3 apresenta o embasamento direto deste trabalho, tal qual, a descrição dos *benchmarks* de controle selecionados, suas especificações, relevância de estudo e detalhamentos. Os algoritmos evolucionários selecionados para a realização do processo de otimização quanto ao controle dos referidos *benchmarks*, sendo os algoritmos a Evolução Diferencial (DE – *Differential Evolution*), Evolução Diferencial Ponderada (WDE – *Weighted Differential Evolution*), Algoritmo Genético (GA – *Genetic Algorithm*), Algoritmo Genético com *Crossover* Multi-Precursores (GA-MPC - *Genetic Algorithm with Multiparent Crossover*) e Competição por Recursos (COR - *Competition Over Resources*). Em seguida são apresentados os critérios de otimização com restrições, que condicionam a solução à usabilidade, pela análise de estabilidade e robustez do controlador.

Os resultados obtidos por este trabalho são descritos no capítulo 4 para cada um dos *benchmarks* selecionados, sendo apresentadas análises estatísticas e de desempenho. Por fim, o capítulo 5 apresenta a conclusão deste trabalho.

2 REVISÃO DE LITERATURA

Neste capítulo serão apresentados uma base sintetizada da teoria de controle e métricas comumente utilizadas para avaliação de desempenho, os principais conceitos referentes aos processos de otimização mono e multiobjetivo bem como os procedimentos para seus projetos, por fim, a base da computação evolucionária e os fundamentos que caracterizam um algoritmo evolucionário.

2.1 SISTEMAS DE CONTROLE

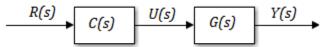
Diversas aplicações, tanto industriais quanto cotidianas, envolvem a teoria de controle de sistemas, sendo esta considerada uma relevante área de pesquisa. Alguns exemplos de aplicação estão nas áreas: automotiva, aeroespacial, robótica e manufatura. O uso do controle linear para solucionar muitos dos problemas nessas áreas é uma solução amplamente utilizada, uma vez que muitos desses sistemas podem ser aproximados por modelos lineares, o que reduz a complexidade do problema e das soluções aplicadas (SIDDIQUE, 2014).

A teoria de controle consiste no desenvolvimento de uma estratégia de controle a ser exercida na entrada do sistema, de maneira a garantir que sua saída aproximese ao máximo do sinal de referência apresentado (BACCIOTTI, 2019), sendo duas as estratégias principais de controle:

- Controle em malha aberta: o controle é realizado através de uma função no tempo e seu sinal é diretamente aplicado ao sistema;
- Controle em malha fechada: o controle é implementado através da construção de um segundo sistema e estabelece-se uma conexão de realimentação do sinal de saída.

O controle em malha aberta é assim chamado devido à sua estrutura simples e sequencial, no qual a saída do sistema não apresenta influência na ação de controle da entrada do sistema, sua estrutura básica é apresentada na Fig. 1, no domínio da frequência de Laplace (s), onde R(s) representa a referência do sistema, C(s) a função de transferência do controlador, U(s) o sinal de controle, utilizado pela função de transferência G(s) que modela o sistema para cálculo da saída Y(s).

Figura 1 - Controle em malha aberta

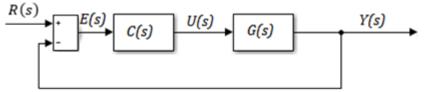


De maneira geral, um sistema em malha aberta segue fielmente os comandos de entrada, ou referência, independentemente do resultado final, não possuindo conhecimento sobre as condições de saída. Neste sentido, esta estrutura de controle não é capaz de prover autocorreções quanto a erros ou desvios na operação do sistema (BAI; ROTH, 2019), sua equação em formas gerais é dada por:

$$H_{FTMA}(s) = \frac{Y(s)}{R(s)} = C(s)G(s). \tag{1}$$

O controle em malha fechada, também denominado controle com realimentação, diverge da estrutura de controle em malha aberta por apresentar pelo menos um ramo de realimentação no sistema, ou seja, as informações da saída do sistema são utilizadas na operação do controlador, sua estrutura fundamental é apresentada na Fig. 2.

Figura 2 - Controle em malha fechada



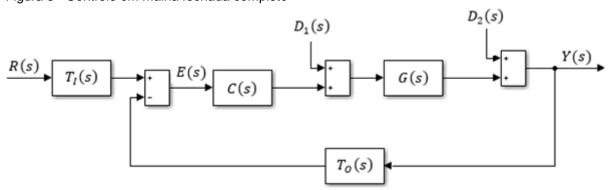
A dinâmica de realimentação da informação proveniente da saída do sistema é utilizada na correção do erro E(s), de tal forma que o controle em malha fechada possui a capacidade de corrigir erros provenientes da atuação do sistema ou quanto a distúrbios advindos de condições externas (BAI; ROTH, 2019), sua equação é dada por:

$$H_{FTMF}(s) = \frac{Y(s)}{R(s)} = \frac{C(s)G(s)}{1 + C(s)G(s)}.$$
 (2)

A estratégia de controle em malha fechada é também nomeada como controle automático, e provê vantagens quando comparado ao controle em malha aberta, sendo a principal a capacidade de autorregularão, na qual o sistema, quando na presença de perturbações não previsíveis, realiza a compensação do erro e mantémse, ou busca manter-se, no sinal de referência sem a intervenção humana (BACCIOTTI, 2019).

Uma arquitetura generalista apresentando todas as condições ao qual um sistema está sujeito é apresentada na Fig. 3. Os elementos adicionais contidos no diagrama referem-se a $T_I(s)$, o transdutor de entrada que converte a referência ou entrada R(s) em um sinal com forma utilizada pelo controlador, $T_O(s)$ o sensor ou transdutor que realiza a medição do sinal de saída Y(s) e os distúrbios $D_1(s)$ e $D_2(s)$, o primeiro referente a distúrbios provenientes do controlador, de baixa frequência ou de carga, e o segundo referente a ruídos da saída do processo ou distúrbios de alta frequência (NISE, 2014).

Figura 3 - Controle em malha fechada completo



De maneira a garantir o sucesso do projeto de implementação de um controlador para um sistema de controle linear qualquer, dois fatores são críticos segundo Bai e Roth (2019):

- 1. O modelo matemático ou dinâmico do objeto de controle (planta);
- 2. As especificações de controle do objetivo de controle.

O primeiro elemento provê um conhecimento detalhado e estruturado sobre o sistema a ser controlado. O quão mais detalhado e preciso o modelo, melhor o projeto do controlador a ser aplicado e consequente melhor desempenho pode ser obtido por este.

O segundo elemento provê os objetivos de controle, representando um conjunto de parâmetros concretos ou atuais, tais quais tempo de subida, tempo de acomodação, sobressinal e erro de estado estacionário.

2.1.1 Controle PID

Entre os métodos de controle existentes, o controlador tipo Proporcional-Integral-Derivativo (PID), como já mencionado anteriormente neste trabalho, é certamente o mais conhecido e utilizado (ÅSTRÖM, K.; HÄGGLUND, 2006). Entre as diversas vantagens de sua utilização, ressaltam-se sua simplicidade, fácil aplicação, baixo custo de implementação e robustez na modelagem de erros (KHALORE, 2012).

Os controladores PIDs têm apresentado relevante eficácia e praticidade no controle de processos industriais, podendo ser implementados em controladores lógico programáveis, computadores industriais, entre outros. Seu nome advêm da relação apresentada em sua função de transferência, a qual relaciona, através da soma, as ações proporcional, integral e derivativa do erro, calculada pela diferença entre a referência e a resposta do sistema (CASTRUCCI; BITTAR; SALES, 2011).

A equação geral de um controlador PID no domínio do tempo é apresentada como:

$$u(t) = K_p \left(e(t) + \frac{1}{T_i} \int_0^t e(t)dt + T_d \frac{de(t)}{dt} \right), \tag{3}$$

onde u(t) é a variável manipulada ou sinal de controle, e(t) o erro atuante ou sinal de entrada do controlador e K_p , T_i e T_d os parâmetros de ajuste do controlador.

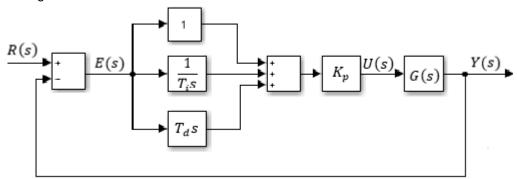
Sendo K_p o ganho proporcional, K_p/T_i (ou K_i) o ganho da integral e K_pT_d (ou K_d) o ganho derivativo, a função de transferência correspondente do controlador PID no domínio da frequência (s) pode ser escrita como:

$$\frac{U(s)}{E(s)} = K_p \left(1 + \frac{1}{T_i s} + T_d s \right) = K_p + K_i \frac{1}{s} + K_d s . \tag{4}$$

O diagrama de blocos de controle em malha fechada de um controlador PID genérico, considerando os ganhos em paralelo, é apresentado na Fig. 4. Onde R(s) é

o sinal de referência, E(s) é o erro atuante, Y(s) é a saída do sistema, U(s) é o sinal de controle e G(s) é a planta a ser controlada.

Figura 4 - Diagrama de blocos Controle PID



A utilização de controladores PID em aplicações com presença de ruídos é muito comum quando estes saem do domínio da simulação computacional para aplicações reais, de forma que o termo derivativo do controlador gera um ganho que tende ao infinito quando exposto a altas frequências. Nestes casos, tais ganhos levam os elementos finais de controle, como atuadores e amplificadores, à saturação (CASTRUCCI; BITTAR; SALES, 2011). Desta forma, a função de transferência do controlador é modificada com a inserção de um filtro passa-baixa (N_d) associada à derivada possuindo então a forma:

$$U(s) = K_p + K_i \frac{1}{s} + K_d s \frac{N_d}{s + N_d}.$$
 (5)

Algumas variantes em relação ao esquema de controle PID tradicional podem ser consideradas para casos específicos, mais informações podem ser obtidas em (OGATA, 2010).

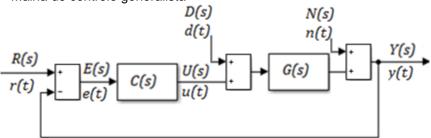
2.1.2 Métricas de comparação e avaliação de controladores

No que diz respeito à avaliação do desempenho de um sistema de controle, diversas métricas foram propostas com o objetivo de comparar o desempenho de diferentes controladores em malha fechada. De modo geral, critérios são selecionados de maneira a mensurar a capacidade de um controlador em seguir a referência (r(t)), sua capacidade de rejeição de perturbações de carga (d(t)), sua robustez a incertezas

em relação a perturbações de medição (n(t)) e referente à robustez e incertezas do modelo utilizado ao longo da fase de projeto (REYNOSO-MEZA *et al.*, 2017).

Os mais comuns objetivos básicos de projetos de controladores no domínio da frequência e do tempo foram sumarizados por Reynoso-Meza (2014) e Reynoso-Meza et al. (2017) e são apresentados baseados em uma malha de controle generalista apresentada na Fig. 5.

Figura 5 - Malha de controle generalista



Assim, podem ser descritos os seguintes objetivos no domínio do tempo (t), onde t_0 e t_f são os instantes de tempo inicial e final do experimento, durante o projeto de um sistema de controle:

Integral do erro absoluto:

$$J_{IAE}(\boldsymbol{\theta}) = \int_{t=t_0}^{t_f} |r(t) - y(t)| dt;$$
 (6)

Integral do erro absoluto vezes o tempo:

$$J_{ITAE}(\boldsymbol{\theta}) = \int_{t=t_0}^{t_f} t |r(t) - y(t)| dt ; \qquad (7)$$

• Integral do erro quadrático:

$$J_{ISE}(\boldsymbol{\theta}) = \int_{t=t_0}^{t_f} (r(t) - y(t))^2 dt; \qquad (8)$$

Integral do erro quadrático vezes o tempo:

$$J_{ITSE}(\boldsymbol{\theta}) = \int_{t=t_0}^{t_f} t \left(r(t) - y(t) \right)^2 dt ; \qquad (9)$$

- Tempo de estabilização: tempo decorrido a partir de uma mudança na referência para que a saída do sistema se mantenha em uma faixa de erro $\Delta[\%]$ para $J_{t(100-\Delta)\%}(\theta)$;
- Máximo pico, referente a uma mudança positiva da entrada:

$$J_{over}(\boldsymbol{\theta}) = \max \left[\max \left(\frac{y(t) - r(t)}{r(t)} \right), 0 \right], t \in [t_0, t_f];$$
 (10)

Desvio máximo, para uma perturbação de carga:

$$J_{overd}(\boldsymbol{\theta}) = \max\left(\left|\frac{y(t) - r(t)}{r(t)}\right|\right), t \in [t_0, t_f];$$
(11)

• Integral do quadrado da ação de controle:

$$J_{ISU}(\theta) = \int_{t=t_0}^{t_f} u(t)^2 dt \; ; \tag{12}$$

Integral do valor absoluto da ação de controle:

$$J_{IAU}(\boldsymbol{\theta}) = \int_{t=t_0}^{t_f} |u(t)|dt ; \qquad (13)$$

Variação total da ação de controle:

$$J_{IAVU}(\boldsymbol{\theta}) = \int_{t=t_0}^{t_f} \left| \frac{du(t)}{dt} \right| dt ; \qquad (14)$$

Valor máximo da ação de controle:

$$J_{maxU}(\boldsymbol{\theta}) = \max(u(t)), t \in [t_0, t_f]; \tag{15}$$

A combinação ponderada de diversos dos objetivos apresentados também pode ser considerada, na qual a preferência do avaliador é fator relevante.

2.2 PROBLEMAS DE OTIMIZAÇÃO

A maior parte das teorias envolvendo a computação evolucionária está concentrada na área de otimização, sendo assim, intrínseco ao seu desenvolvimento, as aplicações de otimização tornam-se intuitivamente relacionadas àquela. Problemas, na ciência da computação, são ao mesmo tempo, tanto precisos, quanto abstratos. Abstratos por tratarem-se de descrever uma classe inteira de instâncias, mas precisos por embasarem-se em conjuntos matematicamente bem definidos de entradas e soluções para cada instância (KNOWLES; CORNE; DEB, 2008).

Um problema pode ser caracterizado ainda segundo Knowles et al. (2008) por duas informações:

- 1. Um conjunto de instâncias que lista de maneira exaustiva as especificações e dados que definem a forma de uma instância;
- 2. Um conjunto de soluções através das entidades que compreendem uma solução válida e um critério de aceitação para esta.

Tem-se, portanto, um problema de otimização, no qual parte de sua solução é definida em termos de uma função (função objetivo), que deve ser minimizada ou maximizada.

Os problemas de engenharia, em geral, podem ser expressos como problemas de otimização, tendo-se como foco o embasamento para uma tomada de decisão a partir de informações limitadas.

2.2.1 Otimização Mono-objetivo

Um problema de otimização mono-objetivo pode ser descrito genericamente como a minimização ou maximização (que pode ser reescrita como uma função de minimização), de uma função $\mathcal{F}(x)$ sujeita às restrições $g_i(x)$ e $h_j(x)$ conforme apresentado:

$$\min_{\mathbf{x}} \mathcal{F}(\mathbf{x}), \qquad \mathbf{x} = [x_1, \dots, x_p] \quad | \quad \mathbf{x} \in \Omega, \tag{16}$$

sujeito a:

$$g_i(x) \le 0,$$
 $i = [1, ..., m]$
 $h_j(x) = 0,$ $j = [1, ..., n].$ (17)

De tal forma, sendo x um vetor de variáveis p-dimensional pertencente a um universo Ω , que abrange todo o conjunto de soluções factíveis de x em $\mathcal{F}(x)$, este deve convergir para uma solução que minimize $\mathcal{F}(x)$ mediante suas restrições. Sendo que ambos, x e $\mathcal{F}(x)$, podem ser discretos ou contínuos (COELLO; LAMONT; VELDHUIZEN, 2007).

O processo de busca por uma solução ótima global de uma função qualquer é definida como Otimização Global, sendo que o mínimo global \mathcal{F}^* pode ser definido como:

$$\mathcal{F}: \Omega \subseteq \mathbb{R}^n \to \mathbb{R}, \qquad \Omega \neq \emptyset \quad | \quad x \in \Omega$$

$$\mathcal{F}^* \triangleq \mathcal{F}(x^*) > -\infty, \tag{18}$$

sendo que x^* é a solução mínima global

sse
$$\forall x \in \Omega$$
: $\mathcal{F}(x^*) \leq \mathcal{F}(x)$. (19)

Podendo o problema possuir apenas um único mínimo global.

2.2.2 Otimização Multiobjetivo

De maneira análoga à otimização mono-objetivo, pode-se definir um problema de otimização multiobjetivo como sendo a minimização simultânea para $k \geq 2$ de $J_k(\theta)$ funções objetivo:

$$\min_{\boldsymbol{\theta}} \boldsymbol{J}(\boldsymbol{\theta}) = [J_1(\boldsymbol{\theta}), \dots, J_k(\boldsymbol{\theta})], \tag{20}$$

de um vetor de variáveis (ou vetor de otimização) θ p-dimensional,

$$\boldsymbol{\theta} = [x_1, \dots, x_p],\tag{21}$$

restrito a um universo U de soluções factíveis:

$$U = \begin{cases} \frac{\underline{x_1} < x_1 < \overline{x_1}}{\underline{x_2} < x_2 < \overline{x_2}} \\ \dots \\ \underline{x_p} < x_p < \overline{x_p} \end{cases}, \tag{22}$$

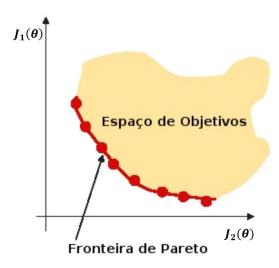
sendo $\underline{x_p}$ e $\overline{x_p}$ os limites inferior e superior do espaço de busca da variável x_p , respectivamente.

Caso não ocorram conflitos entre as funções objetivo, uma única solução pode ser considerada como ótima, neste caso, não é necessário a utilização de método(s) adicional(is) para a análise do conjunto de soluções. Entretanto, em aplicações gerais, as funções objetivo são, ao menos, parcialmente conflitantes, justificando a utilização da abordagem multiobjetivo, pois um conjunto de soluções "ótimas em seu contexto" são obtidas. Neste caso, tal conjunto de soluções ótimas é definida como Fronteira de Pareto.

Expressando de maneira genérica um problema de otimização multiobjetivo, o qual possui muitas soluções potenciais, um conjunto particular de soluções é classificado como Fronteira de Pareto ou conjunto ótimo de Pareto (Fig. 6). Por definição, um conjunto de soluções de Pareto são consideradas ótimas devido à sua característica de, quando comparados a soluções não pertencente à Fronteira de Pareto, apresentarem desempenho superior para todos os valores de função objetivo (MATTSON; MESSAC, 2005; MIETTINEN, 1998; PARETO, 1964).

Algumas definições quanto às soluções pertencentes à Fronteira de Pareto são descritas por Sawaragi, Nakayama e Tanino (1985) e Miettinen (1998), estas apresentadas na sequência.

Figura 6 - Fronteira de Pareto



Fonte: Adaptado de Farias (2008).

Solução Pareto Ótima: tendo-se um vetor de parâmetros $x^* \in U$ este será Pareto ótimo

sse
$$\nexists x \in U \mid J_i(x) \leq J_i(x^*) \, \forall i = [1, ..., k] \, e$$

$$\not\exists x \in U \mid J_j(x) < J_j(x^*) \, \exists j = [1, ..., k],$$
(23)

sendo z os vetores de objetivos e ainda z^* um vetor de objetivos particular tal que z, $z^* \in J$, z^* será Pareto ótimo no espaço de objetivos J

sse
$$\nexists \mathbf{z} \in \mathbf{J} \mid \mathbf{z}_i \leq \mathbf{z}_i^* \ \forall \ i = [1, ..., k] \ e$$

$$\nexists \mathbf{z} \in \mathbf{J} \mid \mathbf{z}_i < \mathbf{z}_i^* \ \exists \ j = [1, ..., k],$$
(24)

ou seja, o vetor de objetivos z^* será Pareto ótimo apenas se seu vetor de parâmetros x^* correspondente for Pareto ótimo, este conceito é replicável às outras definições apresentadas na sequência.

Solução Dominante: um vetor de objetivos z^* domina outro vetor z^+

sse
$$\mathbf{z}_{i}^{*} \leq \mathbf{z}_{i}^{+} \ \forall \ i = [1, ..., k] \ e$$

 $\mathbf{z}_{i}^{*} < \mathbf{z}_{i}^{+} \ \exists \ j = [1, ..., k].$ (25)

<u>Solução Fracamente Dominante</u>: um vetor de objetivos z^* domina fracamente outro vetor z^+

sse
$$\mathbf{z}_{i}^{*} \le \mathbf{z}_{i}^{+} \ \forall \ i = [1, ..., k].$$
 (26)

 $\underline{\textbf{Solução Estritamente Dominante}}\text{: um vetor de objetivos } \mathbf{z}^* \text{ será dominado}$ por outro vetor \mathbf{z}^+

sse
$$\mathbf{z}_{i}^{+} \leq \mathbf{z}_{i}^{*} \ \forall \ i = [1, ..., k].$$
 (27)

As técnicas de otimização multiobjetivo são, em geral, estratégias que buscam um conjunto de soluções que se aproximem da Fronteira de Pareto, tais técnicas podem ser classificadas em dois tipos básicos, os métodos de busca direta e os baseados em algoritmos evolucionários multiobjetivo (MOEAs – *Multiobjective Evolutionary Algorithms*).

Algumas estratégias comumente usadas para a aproximações da Fronteira de Pareto através de métodos de busca direta são: a Interseção de Limite-Normal (NBI – Normal-Boundary Intersection) (DAS; DENNIS, 1996), a Programação Física (Physical Programming) (MESSAC; MATTSON, 2002), o método de Restrição Normal Normalizada (NNC – Normalized Normal Constraint) (MESSAC; ISMAIL-YAHAYA; MATTSON, 2003), o método de Perseguição do Conjunto de Pareto (PSP – Pareto Set Pursuing) (WANG; SHAN, 2005), aproximação algébrica (algebraic approach) (GEILEN et al., 2007) e o método de busca múltipla direta (DMS – Direct Multisearch) (CUSTÓDIO et al., 2011).

O uso de algoritmos evolucionários para a obtenção da Fronteira de Pareto é motivado pela sua característica de basear-se em uma população, possibilitando a obtenção de múltiplas soluções Pareto ótimas em uma única execução, reduzindo a complexidade apresentada por diversos problemas multiobjetivo ou métodos diretos (COELLO; LAMONT; VELDHUIZEN, 2007).

Algumas metaheurísticas que consideram modificações e aprimoramentos em relação aos algoritmos originalmente propostos e que são comumente utilizadas em problemas de otimização multiobjetivo são os Algoritmos Genéticos (GA) (SRINIVAS; PATNAIK, 1994), a busca tabu (GLOVER; LAGUNA, 1989), a Otimização por Enxame de Partículas (PSO – *Particle Swarm Optimization*) (KENNEDY; EBERHART, 1995),

a Evolução Diferencial (DE) (STORN; PRICE, 1997a), os Sistemas Imunológicos Artificiais (AIS – Artificial Immune Systems) (DE CASTRO; TIMMIS, 2002), a Otimização por Colônia de Formigas (ACO – Ant Colony Optimization) (DORIGO; STÜTZLE, 2004) e a Colônia de Abelhas Artificial (ABC - Artificial Bee Colony) (KARABOGA et al., 2014).

2.2.3 Procedimentos para projetos de otimização multiobjetivo

Os procedimentos descritos para o projeto de otimização multiobjetivo descritos e que orientam o desenvolvimento deste trabalho seguem os conceitos e normativas estabelecidas por Reynoso-Meza (2014) para a utilização de algoritmos evolucionários no processo de otimização de parâmetros de controladores, conforme apresentado na Fig. 7, todavia tais procedimentos são aplicáveis não apenas no projeto destes, mas também para a identificação de sistemas, pré-requisito para a definição da estratégia de controle.



Partindo-se da premissa de que se tem um problema de otimização multiobjetivo para um sistema a ser controlado, seguem-se os conceitos.

2.2.3.1 Definição do Problema Multiobjetivo

De modo a definir um problema multiobjetivo, partindo de uma aplicação para controle, duas perspectivas devem ser consideradas, uma que visa a descrição do modelo paramétrico do problema e outra que abrange as funções custos que serão

utilizadas para a avaliação da solução sobre tal modelo (REYNOSO-MEZA; BLASCO; et al., 2014).

O modelo paramétrico utilizado no processo de otimização multiobjetivo caracteriza o comportamento do sistema. Em geral, são considerados como parâmetros do vetor de variáveis todos os valores mutáveis de forma que suas manipulações sejam condizentes com a aplicação.

Durante este estágio, define-se como o problema deve ser abordado, levantando-se em conta os requisitos de engenharia, tais como quais os critérios que devem ser otimizados e os limiares nos quais as soluções propostas apresentem condições factíveis de aplicação (REYNOSO-MEZA, 2014). Uma solução factível em um problema de engenharia, por exemplo, diz respeito à possibilidade de aplicação de uma solução para um caso real, sem que sejam necessárias alterações de estrutura ou operação do sistema e que a solução proposta seja palpável em termos financeiros e de capacidades físicas e tecnológicas.

A escolha das funções custo utilizadas no processo de otimização deve ser condizente com o contexto de aplicação do problema, de modo que um grau de conhecimento prévio se faz necessário.

2.2.3.2 Processo de Otimização Multiobjetivo

Durante a etapa de otimização multiobjetivo, tem-se a aplicação direta do método escolhido, seja através do uso de técnicas que realizem a busca direta pela Fronteira de Pareto, ou ainda apoiado por um algoritmo evolucionário.

O processo de otimização através de algoritmos evolucionários, como descrito na seção 2.2.2, possibilita a obtenção de múltiplos conjuntos de soluções Pareto ótimas de maneira, muitas vezes, mais simples e rápidas quando comparado com um método de busca direto (COELLO; LAMONT; VELDHUIZEN, 2007), como por exemplo o método Nelder-Mead, proposto por Nelder e Mead (1965). Contudo, a escolha de algoritmos que apresentem estratégias de evolução condizentes com o problema ou superfície de decisão impactam diretamente na qualidade da resposta, como apresentado nos trabalhos de Patil e Bhende (2014) e Soni e Kumar (2014).

2.2.3.3 Tomada de Decisão Multicritério

A definição de uma metodologia para tomada de decisão multicritério (MCDM – *Multi-Criteria Decision Making*) faz-se necessária, uma vez o conjunto de soluções obtidas pelo método de otimização multiobjetivo não é facilmente interpretável.

A utilização de um MCDM em problemas com múltiplos objetivos visa auxiliar na seleção, de uma possível solução, que satisfaça uma determinada estrutura de preferências do tomador de decisão sob o qual está envolvido um juízo de valores (ALMEIDA *et al.*, 2015). De tal forma, as preferências do tomador de decisão são incorporadas no modelo de decisão, de modo a suportar a escolha da alternativa, sendo os múltiplos critérios, ou objetivos, analisados simultaneamente.

O conhecimento que provê a noção fundamental de solução preferível é obtida através das circunstâncias e conhecimento *a priori* acometidas ao tomador de decisão, em experiências e percepções obtidas pelo estudo de problemas semelhantes, contudo, a dificuldade dá-se por, tais conhecimentos, não serem completamente elucidados pelo tomador de decisão antes de o processo de decisão se iniciar (KALISZEWSKI; MIROFORIDIS; PODKOPAEV, 2016).

Problemas reais estão sujeitos a incertezas e conflitos entre as diferentes possibilidades de soluções factíveis, desta forma Yano (2017) propõe que o processo de modelagem para estes problemas, quanto ao MCDM seja realizada através de três etapas, a primeira consiste na formulação matemática de um modelo multicritério que reflita adequadamente a situação a ser tomada a decisão. Neste passo, o grande problema relaciona-se às numerosas alternativas existentes de MCDMs, segundo o qual existem divergências quanto às suas estruturas matemáticas.

O segundo passo descrito por Yano (2017) consiste na resolução do modelo e obtenção do conjunto de soluções que refletem as preferências do tomador de decisão, e por fim, o terceiro passo consiste na seleção de uma solução para o problema real, através de um único ou ainda por múltiplos MCDM.

Alguns métodos de tomada de decisão para problemas multiobjetivo são baseados na agregação dos resultados obtidos pelas funções custo calculadas, obtendo-se uma única solução que satisfaça determinado critério. Um exemplo é o método da Técnica de Ordenação de Preferência de Alternativas pela Semelhança com a Solução Ideal (TOPSIS – *Technique for Order Preference by Similarity to Ideal*

Solution) (LAI; LIU; HWANG, 1994), que é amplamente utilizado para o auxílio na tomada de decisão em problemas complexos (ZAVADSKAS *et al.*, 2016).

2.3 COMPUTAÇÃO EVOLUCIONÁRIA

A computação evolucionária é um campo da inteligência computacional caracterizado por uma coleção de paradigmas de busca global aleatória com objetivo de encontrar uma solução ótima para dado problema (PALIT; POPOVIC, 2005). O termo evolucionário proveio da terminologia apresentada por Darwin (1859), que descreve o processo de adaptação das capacidades de sobrevivência e aptidões das diferentes espécies através da seleção natural.

Desta forma, a computação evolucionária almeja modelar os processos de evolução natural, onde a reprodução e as aptidões dos indivíduos melhor adaptados são transferidas para seus sucessores. Assim, o processo evolucionário caracterizase por genes de descendência provindos dos antecessores, ou seja, indivíduos com genes de pior qualidade não são capazes de vencer as "batalhas" de sobrevivência.

Provavelmente uma das primeiras menções ao que se tornaria a computação evolucionária foi apresentada por Fraser (1957), na qual apresenta-se um método para representação de sequências de genes e a utilização de aritmética binária para a computação automática, na simulação de sistemas genéticos. Outros trabalhos precursores na aplicação de processos evolucionários, estes voltados para a resolução de problemas computacionais, foram os de Friedberg (1958) e Friedberg, Dunham e North (1959), representando também um dos primeiros trabalhos envolvendo aprendizado de máquinas e descrevendo o uso de um algoritmo evolucionário para a programação automática.

2.3.1 Algoritmos Evolucionários

A principal utilização da computação evolucionária relaciona-se com sua aplicação na solução de problemas de otimização. De maneira geral, os algoritmos evolucionários tendenciam sua busca a uma solução ótima global, em um curto espaço de tempo, sendo aplicáveis em diversas áreas do conhecimento, tais como a engenharia, economia e agricultura.

Os algoritmos pertencentes à classe da computação evolucionária baseiam-se na criação de um conjunto aleatório de potenciais soluções (população) para o

problema, sendo as potenciais soluções deste conjunto iterativamente modificados através das técnicas de evolução empregadas pelo algoritmo. Este processo estocástico descarta as piores soluções e aprimora as melhores, esta característica tendência à obtenção de melhores conjuntos de soluções a cada iteração (BANSAL; PAL, 2019). Um exemplo de aplicação de um algoritmo evolucionário pode ser observado na Fig. 8, na qual a solução busca a menor distância entre a "Posição" Inicial" e o "Destino", evitando-se os "Obstáculos" no caminho.

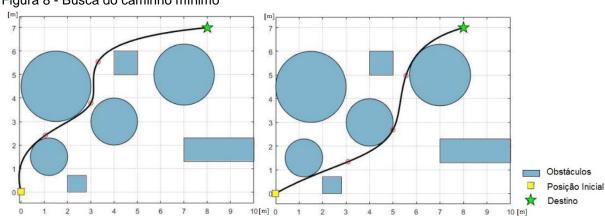


Figura 8 - Busca do caminho mínimo

Uma das principais desvantagem na utilização de algoritmos evolucionários em problemas de otimização relacionam-se ao tamanho da população necessária para a convergência do algoritmo (PIOTROWSKI, 2017), uma vez que as condições iniciais de tamanho da população a serem adotadas pelo algoritmo são sugeridas por Piotrowski (2017) de três a cinco vezes a dimensão do problema, para vetores de variáveis com alta dimensão em problemas artificiais, e dez vezes para problemas de alta dimensão reais, impactando na velocidade de convergência do algoritmo.

Contudo, algoritmos evolucionários específicos, aprimorados e aplicados em casos de problemas multidimensionais foram propostos, possibilitando a solução de problemas com um bilhão de variáveis como apresentado por Deb e Myburgh (2016).

2.3.1.1 Principais Algoritmos

Os algoritmos evolucionários foram desenvolvidos com o objetivo de solucionar problemas específicos em suas áreas de aplicação, alguns dos mais reconhecidos algoritmos são:

- Algoritmos Genéticos (HOLLAND, 1975), que modela diretamente o processo de evolução genética em uma geração de indivíduos;
- Programação Genética (KOZA, 1992), uma extensão dos algoritmo genéticos para a população, na qual cada indivíduo é, por si, um programa computacional;
- Estratégias Evolucionárias (RECHENBERG, 1973), lida com a "evolução da evolução", através da modelagem de parâmetros estratégicos que controlam as variações no processo evolucionário;
- Programação Evolucionária (FOGEL; OWENS; WALSH, 1966), que modela o fenômeno de evolução adaptativa;
- Evolução Diferencial (STORN; PRICE, 1997a), que baseia-se em uma população sob uma estratégia de busca para a otimização de funções objetivo com valores reais.

Sendo assim, os algoritmos evolucionários podem ser classificados como uma categoria especial de algoritmos de busca aleatória, contrastando com os algoritmos de busca tradicionais, como os métodos gradientes que tornam-se ineficientes ou ainda impraticáveis quando se considera um incremento na dimensão do espaço de busca, pois aqueles são baseados em conceitos populacionais, operados por termos e operadores genéticos, mantendo aproximadamente o mesmo tamanho da população através das gerações e permanecendo matematicamente gerenciável (PALIT; POPOVIC, 2005).

2.3.1.2 Mecanismos de Evolução

Alguns dos mecanismos de evolução comumente utilizados por algoritmos evolucionários envolvem a atuação sobre os genes da população, esta armazenando

múltiplas soluções para um dado problema e cada solução sendo um membro da população (ou indivíduo).

Para cada indivíduo calcula-se seu *fitness*, que é uma métrica que representa quão bem uma determinada solução resolve o problema. Buscando-se uma solução ótima para o espaço de busca, um procedimento de "sobrevivência por *fitness*" é aplicado, ou seja, uma solução com maior *fitness* é escolhida em detrimento de uma com menor *fitness*. A principal diferença entre os algoritmos evolucionários dá-se pela forma na qual novos indivíduos são gerados a partir dos membros pré-existentes (PALIT; POPOVIC, 2005).

Alguns dos principais operadores de evolução utilizados na geração de novos indivíduos são a mutação, o *crossover* e a seleção.

A mutação possui diversas variações quanto à sua maneira de implementação, sendo que os operadores genéticos atuam diretamente na alteração dos genes de um indivíduo, as mais usuais são o "apagamento", onde parte do código genético do indivíduo é apagado, usualmente apagar parte dos genes causa desastres genéticos, "duplicação", uma parte do código é duplicada, também podendo ocasionar diversos problemas e a "reprodução", tida como a mais importante entre as operações genéticas, sendo classificada em dois tipos: a assexuada na qual dois novos indivíduos são gerados a partir da divisão de um único, reproduzindo o material genético do indivíduo original e a sexuada ou *crossover*, na qual um descendente é gerado através da troca, ou combinação, do material genético de dois indivíduos distintos. Embora sendo uma forma de mutação, o *crossover* é muitas vezes tratado como um fenômeno genético a parte.

3 ESTUDOS DE CASO

Serão apresentados neste capítulo os *benchmarks* de controle escolhidos para a realização deste trabalho, bem como suas descrições e relevância para este estudo. Posteriormente, cinco algoritmos evolucionários foram selecionados e serão detalhados quanto a alguns dos principais estudos relacionados e seus processos de funcionamento. Por fim, são descritos critérios de avaliação de estabilidade e robustez para controladores, que condicionam a solução à usabilidade.

3.1 BENCHMARKS DE CONTROLE

No estudo da teoria de controle o uso de *benchmarks* possibilita a realização de testes de hipóteses e comparação de soluções propostas e/ou alternativas, permitindo avanços na área através de experimentos e simulações que descrevem em detalhes sistemas e situações reais. Neste contexto, são apresentados três diferentes *benchmarks*, o primeiro um aquecedor elétrico de um sistema soprador de ar, o segundo um trocador de calor do tipo casco e tubos e o terceiro um sistema de refrigeração baseado em compressão de vapor.

3.1.1 Aquecedor Elétrico

A regulação de sistemas térmicos é considerada uma das principais problemáticas de controle, visto que a regulação de temperatura é condicionada a não-linearidades e possui comportamentos, muitas vezes, imprevisíveis, o ajuste preciso de temperatura pode ser considerado como um dos fatores mais importantes na obtenção de um desempenho ótimo em sistemas deste tipo (GUO; SONG; CAI, 2007; JUANG *et al.*, 2008; SWANN; KAMALASADAN, 2008).

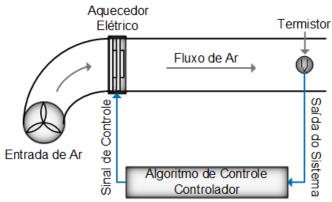
O processo apresentado nesta seção refere-se a um *benchmark* de controle para um sistema de regulação de temperatura de um aquecedor elétrico proposto por Khan e Rahman (2010), o qual consiste de um sistema soprador de ar quente.

O ar é provindo do ambiente atmosférico e regulado por um sistema fixo, o qual é aquecido através de uma grade de aquecimento elétrica. Assim, o problema de controle refere-se ao condicionamento da temperatura em um fluxo de saída através de um cano. O controle do sistema é realizado através da alimentação em tensão, que

produz uma corrente fornecida ao aquecedor elétrico de forma que o sinal de controle possua uma faixa de operação de 0 a 10 V.

A temperatura é mensurada através de um termistor posicionado dentro do cano a uma distância de 28 mm do aquecedor elétrico, de forma que o sinal de saída do sistema é linearizado pela relação à qual uma mudança na temperatura de saída de 30°C para 60°C representa uma alteração na tensão de saída de 0 para 10 V (KHAN; RAHMAN, 2010), o esquemático do sistema de controle de temperatura do aquecedor elétrico é apresentado na Fig. 9.

Figura 9 - Esquemático do sistema de controle Aquecedor Elétrico

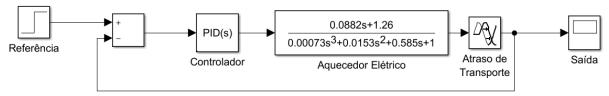


A função de transferência em malha aberta que representa o sistema é dada por Khan e Rahman (2010):

$$G_{Elet}(s) = \frac{0,0882s + 1,26}{0,00073s^3 + 0,0153s^2 + 0,585s + 1}e^{-0,2s}$$
 (28)

de tal forma, a representação em diagrama de blocos da malha de controle pode ser vista na Fig. 10.

Figura 10 - Diagrama de Controle Aquecedor Elétrico



Os ganhos do controlador PID apresentados por Khan e Rahman (2010) como referência são $K_p=1,44,\,K_i=4,6$ e $K_d=0,113$.

3.1.2 Trocador de Calor

Trocadores de calor são amplamente utilizados em plantas químicas, pois seus processos, em geral, envolvem a absorção da energia em forma de calor. Tais processos transferem o calor provindo de um fluido quente, através de uma parede sólida, para um fluido refrigerante. Dentre os diversos tipos de trocadores de calor existentes, o mais comuns é o tipo casco e tubos, devido à sua ampla capacidade de aplicação em diferentes condições de temperatura e pressão (DURAN; RODRIGUEZ; CONSALTER, 2008).

O benchmark de controle apresentado por Padhee, Khare e Singh (2011) consiste em um sistema composto de um trocador de calor tipo casco e tubos, no qual um fluido é aquecido até determinado ponto de operação utilizando-se de um fluxo de vapor superaquecido a 180°C suprido por uma caldeira, onde o vapor flui através dos tubos de maneira a aquecer o fluido do processo.

São determinadas por Padhee, Khare e Singh (2011) algumas premissas para o problema, sendo elas:

- o fluxos de entrada e saída de fluido do processo são constantes durante todo o período de operação;
- ii) a capacidade de armazenamento de calor da parede isolante é desprezível;
- iii) a válvula de controle de valor é acionada por uma linha de pressão e é do tipo normalmente fechada.

Levando todos esses fatores em conta, o diagrama de controle do sistema trocador de calor é apresentado na Fig. 11.

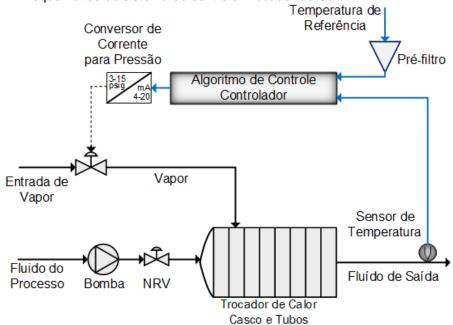


Figura 11 – Esquemático do sistema de controle Trocador de Calor

O modelo matemático do processo considera:

- Resposta do trocador em relação ao ganho de fluxo de vapor: 50°C/(Kg/s);
- Constante de Tempo: 30 s;
- Resposta do trocador em relação à variação do ganho de fluxo do fluido do processo: 1ºC/(Kg/s);
- Resposta do trocador à variação do ganho da temperatura do processo:
 3°C/°C;
- Constante de tempo da válvula de controle: 3 s;
- Faixa de operação do sensor de temperatura: 50~150°C;
- Constante de tempo do sensor de temperatura: 10 s.

A função de transferência do processo é dada por:

$$G(s) = \frac{50}{30s+1}e^{-s},\tag{29}$$

enquanto que o ganho da válvula de controle é de 0,13 e sua função de transferência é, portanto:

$$V(s) = \frac{0.13}{3s+1},\tag{30}$$

o ganho do conversor de corrente para pressão é de 0,75 e a função de transferência do sensor de temperatura é dada por:

$$H(s) = \frac{0.16}{10s + 1}. (31)$$

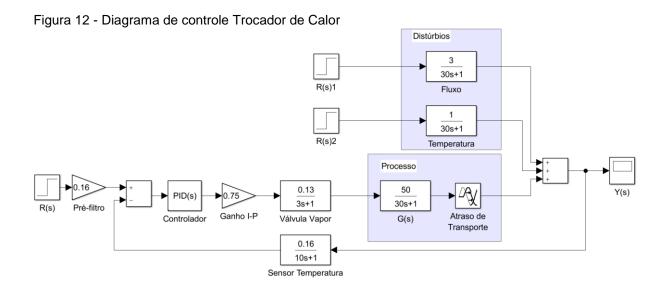
O processo é sujeito a dois tipos de distúrbio, o primeiro em relação ao fluxo de entrada do fluido do processo cuja função de transferência é:

$$R_1(s) = \frac{1}{30s+1},\tag{32}$$

e o segundo distúrbio em relação à variação de temperatura do fluido de entrada:

$$R_2(s) = \frac{3}{30s+1}. (33)$$

A representação em diagrama de blocos da malha de controle é apresentada na Fig. 12.



Os ganhos do controlador PID apresentados por Padhee, Khare e Singh (2011) como referência são $K_p=14,28,\,T_i=14,395$ e $T_d=3,59$.

3.1.3 Sistema de Refrigeração

Com o objetivo de testar e comparar diferentes estratégias de controle, diversos benchmarks são disponibilizados na literatura especializada, um destes benchmarks foi descrito por Bejarano et al. (2018) para a terceira Conferência sobre Avanços em Controle Proporcional-Integral-Derivativo (3rd IFAC Conference on Advances in Proportional-Integral-Derivative Control). Este caso consiste em um problema de controle para um sistema de refrigeração baseado em compressão de vapor, cujas principais motivações dão-se na eficiência energética através de estruturas de controle eficientes e na dificuldade de otimização do sistema com muitas variáveis (DONG; HAN, 2016).

O ciclo fechado do sistema de refrigeração considera como os principais componentes: condensador, válvula de expansão, evaporador e compressor, sendo estes conectados através de diversos canos e válvulas, resultam em um sistema multivariável não-linear e com variáveis altamente acopladas (SARABIA *et al.*, 2009).

O ciclo de operação é baseado na remoção de calor do fluxo secundário do evaporador e transferência para o condensador, também pelo fluxo secundário. O compressor provê a pressão requerida no suprimento do fluido refrigerante e a válvula de expansão mantém a diferença de pressão dentro da linha, sendo uma representação do sistema apresentado na Fig. 13, os arquivos e a documentação referente ao sistema são disponibilizados ao acesso através de (CIC, 2018).

De maneira a solucionar o problema descrito, diversos trabalhos foram apresentados considerando diferentes estratégias de controle, e estudos recentes são apresentados buscando ilustrar as melhores soluções em termos de desempenho de controle apresentados na literatura, utilizando-se de um índice de desempenho relativo geral que será descrito em detalhes posteriormente.

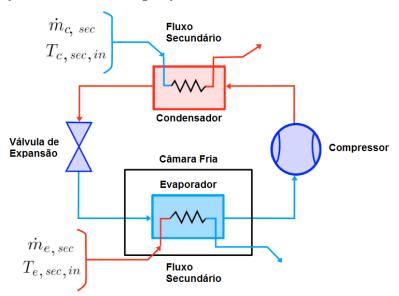


Figura 13 - Representação do sistema de refrigeração

Fonte: Adaptado de Bejarano et al. (2018).

Focando em solucionar o *benchmark* de controle do sistema de refrigeração mencionado anteriormente, o trabalho apresentado por Soto, López e Hernández-Riveros (2018) assumiu um controlador do tipo Proporcional-Integral (PI) com estrutura descentralizada, sob o qual os ganhos são otimizados pelo algoritmo multidinâmico para otimização global (MAGO – *Multidynamic Algorithm for Global Optimization*), um algoritmo evolucionário auto-organizável (HERNÁNDEZ; OSPINA, 2010). No trabalho proposto por Cajo *et al.* (2018), duas alternativas baseadas em controladores PID descentralizados são consideradas, ambas baseadas em métodos diretos de sintonia. A primeira através da estratégia de controle de Modelo interno (IMC – *Internal Model Control*) (GARCIA; MORARI, 1982), e a outra um PID com filtro derivativo e um PID simplificado baseados na ferramenta de resposta em frequência do *software* MATLAB (FRtool).

Adicionalmente, em Reynoso-Meza, Sánches e Ribeiro (2018), uma estrutura descentralizada com um controlador PI e um PID foi proposta, considerando as diretrizes dos procedimentos para sistemas de controle do projeto de otimização multiobjectivo (MOOD – *Multiobjective Optimization Design*) descrito em Reynoso-Meza *et al.* (2017). Os ganhos dos controladores foram otimizados utilizando-se do algoritmo evolução diferencial multiobjetivo estendido com poda esférica (sp-MODEx – *eXtended Multiobjective Differential Evolution with Spherical Pruning*) (REYNOSO-MEZA, 2014).

No trabalho apresentado por Bordignon e Campestrini (2018), dois conjuntos de controladores PID foram apresentados, um com estrutura centralizada e outro com estrutura descentralizada para a solução do problema de controle do sistema de refrigeração, ambos utilizando-se do ajuste por realimentação de referência virtual (VRFT – *Virtual Reference Feedback Tuning*) (CAMPI; LECCHINI, 2002), sendo que tal estratégia não considera a compensação de antecipação no projeto de controle.

A descrição das variáveis manipuladas, distúrbios e variáveis de saída, bem como seus respectivos intervalos de operação e condições iniciais são apresentados na tabela 1.

Tabela 1 - Variáveis manipuladas, distúrbios e variáveis de saída do sistema de refrigeração

l abela 1 - Variaveis manipuladas, disturbios e variaveis de saida do sistema de refrigeração							
Descrição	Símbolo	Faixa de Operação	Condição Inicial	Unidade			
Variáveis Manipuladas							
Abertura da válvula de expansão	A_v	[10, 100]	≅48,79	%			
Velocidade do compressor	N	[30, 50]	≅36,45	Hz			
	Distúrbios						
Temperatura de entrada do fluxo secundário do condensador	$T_{c,sec,in}$	[27, 33]	30	°C			
Fluxo mássico do fluxo secundário do condensador	$\dot{m}_{c,sec}$	[125, 175]	150	g/s			
Pressão de entrada do fluxo secundário do condensador	$P_{c,sec,in}$	Não especificado	1	bar			
Temperatura de entrada do fluxo secundário do evaporador	$T_{e,sec,in}$	[-22, -18]	-20	°C			
Fluxo mássico do fluxo secundário do evaporador	$\dot{m}_{e,sec}$	Não especificado	64,503	g/s			
Pressão de entrada do fluxo secundário do evaporador	$P_{e,sec,in}$	Não especificado	1	bar			
Temperatura ambiente do compressor	T_{surr}	[20, 30]	25	°C			
Variáveis de Saída							
Temperatura de saída do fluxo secundário do evaporador	$T_{e,sec,out}$	Não especificado	≅-22,15	°C			
Grau de superaquecimento	T_{SH}	Não especificado	≅14,65	°C			

Um dos objetivos de controle mais importantes refere-se à capacidade de prover potência refrigerante $\dot{Q}_e[W]$ com menor grau de superaquecimento T_{SH} através do coeficiente de desempenho (COP – coefficient of performance) definido como:

$$COP = \frac{\dot{Q}_e}{\dot{W}_{comp}} = \frac{\dot{m}(h_{e,out} - h_{e,in})}{\dot{m}(h_{c,in} - h_{e,out})} = \frac{h_{e,out} - h_{e,in}}{h_{c,in} - h_{e,out}},$$
(34)

onde \dot{W}_{comp} [W] refere-se à potência de compressão, considerando que o fluxo mássico refrigerante \dot{m} [g/s] é o mesmo para ambos componentes. Neste caso, o COP depende das variáveis que especificam a entropia h [J/K] do ciclo (BEJARANO *et al.*, 2018).

Os controladores de referência (C_{ref}) definidos pelo *benchmark* em uma estrutura de controle descentralizada são apresentados:

$$C_{1,ref}(z) = \frac{-1,0136 - 0,0626z^{-1} + 0,9988z^{-2}}{1 - 1.9853z^{-1} + 0.9853z^{-2}}$$
(35)

$$C_{2,ref}(z) = \frac{0.42 - 0.02z^{-1}}{1 - z^{-1}}$$
 (36)

onde $C_{1,ref}(z)$ é utilizado para controlar a temperatura do fluxo secundário do evaporador $T_{e,sec,out}$ através da taxa de abertura da válvula de expansão A_v , e $C_{2,ref}(z)$ é considerado no controle da temperatura de superaquecimento T_{SH} através da velocidade do compressor N.

Em relação às análises quantitativa e qualitativa, *scripts* são fornecidos por Bejarano *et al.* (2018) para a comparação do *benchmark*, onde C_{ref} denota o controlador de referência e C_{op} o controlador otimizado proposto.

Para a análise quantitativa, oito índices de desempenho são calculados e combinados em um índice agregado J_R . As bases destes índices são a integral do erro absoluto (IAE), a integral do erro absoluto multiplicado pelo tempo (ITAE) e a integral do valor absoluto da variação do sinal de controle (IAVU).

O primeiro e segundo índices são associados pela razão da integral do erro absoluto (*RIAE*), Eq. (39), que é utilizado na validação da capacidade de seguir a

referência para ambos, a temperatura do fluxo do secundário do evaporador ($T_{e,sec,out}$) e o grau de superaquecimento (T_{SH}).

$$RIAE_{i}(C_{op}, C_{ref}) = \frac{IAE_{i}(C_{op})}{IAE_{i}(C_{ref})}$$
(37)

Do terceiro ao sexto índice, a razão da integral do erro absoluto multiplicado pelo tempo (RITAE) é considerado, Eq. (40), cujo cálculo é dado para cada uma das variações do sinal de referência (um para $T_{e.sec.out}$ e três para T_{SH}).

$$RITAE_i(C_{op}, C_{ref}, t_c, t_s) = \frac{ITAE_i(C_{op}, t_c, t_s)}{ITAE_i(C_{ref}, t_c, t_s)}$$
(38)

Os dois últimos índices (sete e oito) estão associados ao esforço de controle, através da razão da integral do valor absoluto da variação do sinal de controle (RIAVU) das variáveis manipuladas, Eq. (41), sendo elas a abertura da válvula A_{ν} e a velocidade do compressor N.

$$RIAVU_i(C_{op}, C_{ref}) = \frac{IAVU_i(C_{op})}{IAVU_i(C_{ref})}$$
(39)

O índice de desempenho agregado J_R é apresentado na Eq. (42), cujo o qual utiliza-se de oito fatores ponderantes individuais (w_i , i = [1,8]) para obtenção do valor médio, que representa o índice de desempenho relativo geral dos controladores.

$$w_{1}RIAE_{1}(C_{op}, C_{ref}) + w_{2}RIAE_{2}(C_{op}, C_{ref}) + w_{3}RITAE_{1}(C_{op}, C_{ref}, t_{c1}, t_{s1}) + w_{4}RITAE_{2}(C_{op}, C_{ref}, t_{c2}, t_{s2}) + w_{5}RITAE_{2}(C_{op}, C_{ref}, t_{c3}, t_{s3}) + w_{6}RITAE_{2}(C_{op}, C_{ref}, t_{c4}, t_{s4}) + w_{7}RIAVU_{1}(C_{op}, C_{ref}) + w_{8}RIAVU_{2}(C_{op}, C_{ref}) - \frac{w_{7}RIAVU_{1}(C_{op}, C_{ref}) + w_{8}RIAVU_{2}(C_{op}, C_{ref})}{\sum_{1}^{8} w_{i}}$$

$$(40)$$

3.2 ALGORITMOS DE OTIMIZAÇÃO EVOLUCIONÁRIOS

Diversos algoritmos de otimização têm sido propostos para a estimação de soluções em problemas complexos de otimização. De maneira generalista, algoritmos evolucionários simulam, a partir de algum nível de abstração, sistemas sociais, biológicos ou naturais e possuem como princípio a obtenção de resultados com melhor desempenho a cada iteração (geração) do algoritmo (CUEVAS; OSUNA; OLIVA, 2017).

A seguir serão apresentados os algoritmos Evolução Diferencial, Evolução Diferencial Ponderada, Algoritmo Genético, Algoritmo Genético com *Crossover* Multi-Precursores e Competição por Recursos, todos eles adotados neste trabalho.

3.2.1 Evolução Diferencial

O algoritmo de Evolução Diferencial (DE – *Differential Evolution*) proposto inicialmente por Storn e Price (1997a) apresenta por base uma estratégia de seleção aleatória de dois vetores de parâmetros na qual um terceiro vetor é gerado baseado na diferença entre eles como uma fonte de variação aleatória.

Diversos trabalhos utilizando a DE foram apresentados e alguns considerados relevantes para esta pesquisa referem-se ao uso da DE em problemas de otimização com restrições mono-objetivo. No trabalho proposto por Zielinski e Laur (2006), uma alternativa à utilização de funções de penalização foi apresentada. Neste caso, as penalizações foram substituídas por um método modificado de seleção de indivíduos. Além disso, Piotrowski (2017) apresentou um estudo sobre a influência do tamanho da população no desempenho da DE e relata que, para problemas com menos que 30 dimensões, a definição de, ao menos, 100 indivíduos é recomendável, para casos com mais dimensões, em problemas artificiais, sugere-se entre três e cinco vezes a dimensão do problema e em problemas reais, pelo menos 200 indivíduos ou então 10 vezes a dimensão do problema.

Trabalhos relacionados à definição de parâmetros de controladores também foram apresentados, como o de Lianghong *et al.* (2008), no qual três estudos de caso foram realizados na parametrização de controladores PID, sendo eles um sistema de terceira ordem, um sistema com atraso de transporte e um sistema com fase não mínima. Os autores Mohanty, Panda e Hota (2014), utilizaram a DE na parametrização

de múltiplos controladores PI-PID para o controle de carga-frequência de um sistema multi-gerador (térmico, hidráulico e gás), apresentando resultados relevantes quando o controlador parametrizado foi comparado a outros métodos de sintonia. Por fim, no trabalho de Pedro, Dangor e Kala (2016), a DE foi utilizada para obter os ganhos do controlador PID para o controle de posição e altitude de um veículo aéreo quadrotor, melhorando e desempenho e reduzindo a potência consumida. A seguir, descreve-se o funcionamento do algoritmo de evolução diferencial.

A DE inicializa a população P com TP indivíduos $P_G = [x_{1,G}, x_{2,G}, ..., x_{TP,G}]$, sendo G a geração, com $x_{i,G} = [x_{1i,G}, x_{2i,G}, ..., x_{Di,G}]$, com indivíduos aleatórios uniformemente distribuídos no intervalo $[x_{min}, x_{max}]$, sendo:

$$\mathbf{x}_{min} = [x_{1,min}, x_{2,min}, \dots, x_{D,min}] e$$

$$\mathbf{x}_{max} = [x_{1,max}, x_{2,max}, \dots, x_{D,max}] \mid i = [1, 2, \dots, TP].$$
(41)

No algoritmo original da Evolução Diferencial, três estratégias de evolução são utilizadas (STORN; PRICE, 1997b). A primeira estratégia é a mutação, onde para cada vetor objetivo $x_{i,G}$, i=1,...,p (indivíduo) de uma geração G e da população P é utilizado na criação de um vetor mutante V_i para a próxima geração G e da cordo com a expressão:

$$v_{i,G+1} = x_{r1,G} + F(x_{r2,G} - x_{r3,G}), \tag{42}$$

onde r1, r2 e $r3 \in \{1, ..., p\}$ são índices aleatórios inteiros, mutuamente diferentes e F > 0. Os valores de r1, r2 e r3 são selecionados de maneira a serem diferentes do índice corrente i, sendo necessário que a população p seja maior ou igual a quatro para que esta condição seja satisfeita e F um fator constante real $\in [0,2]$ que controla a amplificação da variação diferencial $(x_{r2,G} - x_{r3,G})$.

A segunda estratégia é o *crossover*, que é utilizado de modo a aumentar a diversidade do vetor de parâmetros e cria um vetor de testes:

$$\mathbf{u}_{i,G+1} = [u_{1i,G+1}, u_{2i,G+1}, \dots, u_{Di,G+1}], \tag{43}$$

formado através da condição:

$$u_{ji,G+1} = \begin{cases} v_{ji,G+1} \text{ se } (randb(j) \le CR) \text{ ou } j = rnbr(i) \\ x_{ji,G} \text{ se } (randb(j) > CR) \text{ e } j \ne rnbr(i)' \end{cases}$$

$$j = 1, \dots, D.$$

$$(44)$$

onde D é a quantidade de parâmetros (genes) dos indivíduos, randb(j) é a j-ésima avaliação de um gerador de números aleatórios com distribuição uniforme $\in [0,1]$, CR é uma constante de $crossover \in [0,1]$ definida pelo usuário e rnbr(i) é um índice escolhido aleatoriamente $\in [1,...,D]$ que garante ao vetor teste $\boldsymbol{u}_{i,G+1}$ possuir ao menos um parâmetro advindo do vetor mutante $\boldsymbol{v}_{i,G+1}$.

Por fim, a terceira e última estratégia do algoritmo é a seleção, que é aplicada através da "sobrevivência por *fitness*", onde os vetores objetivo $x_{i,G+1}$ serão substituídos pelo vetores de teste $u_{i,G+1}$ caso estes apresentem menores valores no cálculo da função custo ou serão mantidos $x_{i,G}$ caso contrário.

O pseudocódigo da DE é apresentado no Algoritmo 1:

Algoritmo 1 - Pseudocódigo da DE

```
Definição dos parâmetros de controle
      Fator de Escala: F
      Probabilidade de crossover. CR
      Tamanho da População: TP
      Inicializa a população P com TP indivíduos
      Para G = 1 até Máximo de Ciclos
2
              Para i = 1 até TP
3
                      Gera o vetor mutante v_{i,G} = [v_{1i,G}, v_{2i,G}, ..., v_{Di,G}]
4
                      Cria o vetor de testes \boldsymbol{u}_{i,G} = [u_{1i,G}, u_{2i,G}, ..., u_{Di,G}]
5
                      Calcula J(\boldsymbol{u}_{i,G})
6
                      Compara os resultados de J(\mathbf{u}_{i,G}) e J(\mathbf{x}_{i,G}) e mantém-se o melhor
                               entre eles
              Fim para
      Fim para
```

3.2.2 Evolução Diferencial Ponderada

A Evolução Diferencial Ponderada (WDE – Weighted Differential Evolution) é um algoritmo evolucionário bipopulacional focado na solução de problemas de otimização numérica de valores reais, proposto por Civicioglu *et al.* (2018), podendo ser executado com ou sem a definição dos intervalos das variáveis de decisão.

Seu desempenho foi comprovado pela aplicação na solução de problemas do Congresso de Computação Evolucionária (CEC – Congress on Evolutionary Computation) 2013 (LIANG et al., 2013) e comparado estatisticamente a quatro diferentes algoritmos evolucionários, apresentado resultados melhores e com rápida convergência e execução (CIVICIOGLU et al., 2018).

O processo de inicialização do WDE inclui a definição de uma população inicial P aleatória contínua uniformemente distribuída a partir do universo U nos limites das variáveis de decisão definidas, na forma:

$$\boldsymbol{P}_{i_0,j_0} = rand\left(U(low_{j_0}, up_{j_0})\right) \mid (2N, D) \leftarrow tamanho(\boldsymbol{P}), \tag{45}$$

onde, $i_0 = [1:2N]$, $j_0 = [1:D] \mid i_0, j_0 \in \mathbb{Z}^+$, sendo N o total de vetores de variáveis de decisão (tamanho da população) e D a dimensão do problema (tamanho do vetor das variáveis de decisão), de forma que low_{j_0} e up_{j_0} são os limites inferior e superior do espaço de busca para o j_0 -ésimo parâmetro.

Sendo $\mathcal F$ a função objetivo, seu cálculo é representado para uma potencial solução $\pmb P_{i_0}$ como:

$$fitP_{i_0} = \mathcal{F}(P_{i_0}). \tag{46}$$

O primeiro processo de seleção do WDE gera uma matriz de sub-parâmetros SubP a partir de P selecionando-se aleatoriamente N vetores de parâmetros de P em cada iteração de forma que:

$$SubP = P_k \mid \{k = j_{(1:N)} \mid j = permuta(1:2N),$$
 (47)

sendo a dimensão de SubP equivalente ao tamanho tamanho(SubP), onde permuta(.) representa a função de permutação.

O processo de mutação visa a geração de novos vetores de parâmetros TempP, sendo:

$$TempP_{indice=1:N} = \begin{bmatrix} TempP_1 \\ \dots \\ TempP_N \end{bmatrix}, \tag{48}$$

para cada iteração através da equação:

$$TempP_{indice} = \sum (w \circ P_l) \mid l = j \setminus k$$

$$indice = 1: N \quad e \quad indice \in \mathbb{Z}^+,$$
(49)

onde "\" denota o complementar de k em j e " \circ " é o operador de Hadamard, operação de multiplicação entre os elementos (linha, coluna) das matrizes w e P_l , sendo:

$$\mathbf{w}^* = \mathbf{k}_{(N)}^3 \mid (N, 1) \leftarrow tamanho(\mathbf{w}^*), \tag{50}$$

de forma que:

$$\boldsymbol{w}^* \coloneqq \frac{\boldsymbol{w}^*}{\sum \boldsymbol{w}^*} \quad e \quad \boldsymbol{w} = \boldsymbol{w}^* \Delta , \quad \Delta = [1]_{(1,D)}. \tag{51}$$

O processo de mutação do WDE é controlado pela matriz de zeros $M_{(1:N,1:D)}$, sendo que a cada iteração atualiza-se o índice:

$$\mathbf{M}_{(indice,J)} \coloneqq 1$$

$$\mathbf{J} = \mathbf{V}(1: [\mathbf{K} \times \mathbf{D}]) \mid \mathbf{V} = permuta(\mathbf{j}_0),$$
(52)

onde [.] é a função de teto, converte o valor (.) para o menor inteiro maior ou igual a (.), sendo K definido pela condição:

$$\mathbf{K} = \begin{cases} \mathbf{k}_{(1)}^3 & \text{se } \alpha < \beta \\ 1 - \mathbf{k}_{(1)}^3 & \text{se } \alpha \ge \beta \end{cases}$$
 (53)

onde α , β e k são valores aleatórios uniformemente distribuídos $\in [0,1]$.

O fator de escala de evolução *F* da WDE é computado por:

$$F = \begin{cases} \left[\lambda_{(D)}^{3}\right]' \mid (1, D) \leftarrow tamanho(F) \text{ se } \alpha < \beta \\ \left(\lambda_{(D)}^{3} \times \Delta\right) \mid (N, D) \leftarrow tamanho(F) \text{ se } \alpha \ge \beta \end{cases}$$
 (54)

sendo λ valores aleatórios normalmente distribuídos \in [0,1]. O vetor de testes T é gerado por:

$$T = SubP + F \times M \circ (TempP - SubP_{(m)}) \mid m = permuta(i) \mid m \neq [1:N]$$

$$i = 1:N \mid i \in \mathbb{Z}^+,$$
(55)

caso $T \notin [low, up]$ seu valor é atualizado por:

$$T_{(i,j_0)} = \begin{cases} low_{(j_0)} + k_{(1)}^3 \left(up_{(j_0)} - low_{(j_0)} \right) & \text{se } T_{(i,j_0)} < low_{(j_0)} \\ up_{(j_0)} + k_{(1)}^3 \left(low_{(j_0)} - up_{(j_0)} \right) & \text{se } T_{(i,j_0)} > up_{(j_0)} \end{cases}.$$
(56)

O processo de atualização mais importante da WDE é dado pela regra de seleção por ganância do algoritmo:

$$\begin{cases}
SubP_{(i^*)} \coloneqq T_{(i^*)} \\
fitSubP_{(i^*)} \coloneqq fitT_{(i^*)}
\end{cases} se fitT_{(i^*)} < fitSubP_{(i^*)} \mid i^* \in i, \tag{57}$$

sendo então atualizados os valores:

$$P_{(l)} := SubP$$
 e $fitP_{(l)} := fitSubP$, (58)

a melhor solução global encontrada pela WDE é dada por:

$$gmin = fitP_{(\gamma)} \ e \ gbest = P_{(\gamma)} \mid fitP_{(\gamma)} = \min(fitP), \ \gamma \in i.$$
 (59)

O pseudocódigo da WDE é apresentado no Algoritmo 2:

Algoritmo 2 - Pseudocódigo da WDE

```
Definição dos parâmetros de controle
      Tamanho da População: N
      Dimensão do Problema: D
      Inicializa a população P com N indivíduos
      Para G = 1 até Máximo de Ciclos
2
              \mathbf{j} = permuta(\mathbf{i_0})
3
               k = j(1:N)
4
               \boldsymbol{l} = \boldsymbol{j}(N+1:2N)
5
               Gera a subpopulação SubP = P(k)
6
               Calcula fitSubP = \mathcal{F}(k)
7
                Para indice = 1 até N
8
                       Calcula TempP_{(indice)} = \sum (w \circ P_{(l)})
               Fim para
9
               Gera o mapa binário M_{(1:N,1:D)} = 0
10
               Para indice = 1 até N
11
                       Calcula \mathbf{J} = \mathbf{V}(1: [\mathbf{K} \times \mathbf{D}]) \mid \mathbf{V} = permuta(\mathbf{j}_0)
12
                       M_{(indice,I)} := 1
               Fim para
               Calcula \Gamma = Temp - SubP_{(m)}
13
               Gera o vetor de testes T = SubP + F \times M \circ \Gamma
14
               Calcula fitT = \mathcal{F}(T)
15
16
               Se fitT_{(i^*)} < fitSubP_{(i^*)} então
17
                        [SubP_{(i^*)}, fitSubP_{(i^*)}] = [T_{(i^*)}, fitT_{(i^*)}]
               Fim se
               Atribui [P_{(l)}, fitP_{(l)}] = [SubP, fitSubP]
18
                                                     [gmin, gbest] = [fitP_{(\gamma)}, P_{(\gamma)}] | fitP_{(\gamma)} =
               Escolhe
                                      solução
19
                          \min(fitP)|\gamma \in i
      Fim para
```

3.2.3 Algoritmo Genético

Os algoritmos genéticos (GAs – *Genetic Algorithms*) tiveram seus primeiros conceitos apresentados por Holland (1975) e foram formalmente introduzidos como algoritmos de otimização no trabalho apresentado por Goldberg (1989), baseando-se na evolução biológica dos genes.

Os algoritmos genéticos basicamente utilizam de estratégias para resolução de problemas através da busca por uma solução ótima na qual se tem pouco conhecimento do problema, apresentando bons resultados, em qualquer espaço de busca, devido à sua estrutura genérica (SRINIVAS; PATNAIK, 1994).

Alguns estudos relevantes considerando GAs relativos à análise de diferentes estratégias de mutação adotadas de modo a aprimorar o desempenho dos algoritmos em determinadas aplicações podem ser encontrados em (PATIL; BHENDE, 2014; SONI; KUMAR, 2014).

Estudos aplicados à obtenção de parâmetros de controladores tipo PID foram propostos em diversos trabalhos, como no de Malhotra, Singh e Singh (2011) onde foram discutidos os conceitos e *design* a serem adotados quanto à aplicação de GAs na otimização de controladores. Neste caso, considerou-se o controle direto de torque em motores e compressores de turbina. No artigo de Bindu e Namboothiripad (2012), o problema apresentado refere-se ao controle de posição de um sistema servo motor elétrico de corrente contínua (CC), através de um controlador PID. A descrição geral de um GA é apresentada a seguir.

O GA inicia a população P com tam_pop indivíduos aleatórios normalmente distribuídos em um conjunto universo U nos intervalos definidos para cada variável:

$$\mathbf{P}_{i_0,j_0} = rand\left(U(low_{i_0,j_0}, up_{i_0,j_0})\right)$$
 (60)

e calcula seus respectivos custos a partir da função custo $\mathcal{F}(\mathbf{P}_{i_0})$.

Indivíduos descendentes são gerados a partir da população inicial, e em cada iteração, realizam-se os procedimentos de *crossover* e mutação. O tipo mais comum de *crossover* utilizado nos GAs é baseado na recombinação dos cromossomos ou variáveis do vetor de decisão, desta forma, a partir de dois indivíduos precursores,

dois sucessores são gerados, os quais são compostos por uma seção dos cromossomos de cada indivíduo precursor.

Na mutação, define-se uma probabilidade Pm, gera-se um valor aleatório uniformemente distribuído $r \in [0,1]$ e realiza-se um teste em cada cromossomo do indivíduo descendente. Caso r < Pm, o valor contido no cromossomo é alterado de forma a diversificar o conjunto de testes.

O pseudocódigo do GA é apresentado no Algoritmo 3:

	Algoritmo 3 - Pseudocódigo do GA Definição dos Parâmetros de Controle					
	Tamanho da População: tam_pop					
	Probabilidade de <i>Crossover</i> . Pc					
	Probabilidade de Mutação: Pm					
	Inicia a População P com tam_pop indivíduos					
1	Para $G = 1$ até Máximo de ciclos					
2	Calcula a função custo $\mathcal{F}(\pmb{P}_i)$					
3	Seleciona os indivíduos com melhor custo					
4	Recombina os indivíduos (crossover)					
5	Realiza a Mutação					
	Para $i = 1$ até tam_pop					
6	Gera o vetor derivado $oldsymbol{s}_i$					
7	Atribui a $m{m}$ todos os indivíduos não cobertos em $m{s}_i$					
8	Concatena $oldsymbol{s}_i$ e $oldsymbol{m}$ em $oldsymbol{s}_i'$					
9	Fim para					
	Fim para					

3.2.4 Algoritmo Genético com Crossover Multi-Precursores

Os GAs são amplamente utilizados para a resolução de diversos problemas práticos de otimização (BAKER; AYECHEW, 2003; KAVITHA, 2019), entretanto tais algoritmos apresentam, em geral, um longo tempo de execução (ABRAMSON; ABELA, 1992). Posteriormente, foram desenvolvidos soluções para computação em paralelo (ABRAMSON; ABELA, 1992). Além disso, os GAs, muitas vezes, podem ficar presos em soluções ótimas locais, não convergindo para um ótimo global (DEB, 1998).

O algoritmo genético com *crossover* multi-precursores (GA-MPC – *Genetic Algorithm with Multiparent Crossover*), apresentado inicialmente por Elsayed, Sarker e Essam (2011a), possui uma estrutura de *crossover* com um operador aleatório na substituição da mutação tradicional, gerando três novas possíveis soluções, duas com objetivo de auxiliar o entendimento do problema e a terceira para promover a exploração da superfície de decisão de forma que o operador aleatório seja utilizado para evitar a convergência prematura do algoritmo, ajudando-o a escapar de soluções ótimas locais.

Seu desempenho fora comprovado na solução dos problemas de otimização apresentados no CEC 2010 (ELSAYED; SARKER; ESSAM, 2011a) e CEC 2011 (ELSAYED; SARKER; ESSAM, 2011b), onde apresentou bons resultados quando comparado a outros algoritmos do estado da arte. Neste contexto, a descrição do funcionamento do GA-MPC é apresentada a seguir.

A inicialização do GA-MPC dá-se com a geração da população inicial PS em um conjunto universo U com restrições [low, up] através da equação:

$$\mathbf{PS}_{i_0,j_0} = U(low_{j_0}) + \mathbf{u} \times \left(U(up_{j_0}) - U(low_{j_0})\right) \mid (N,D) \leftarrow tamanho(\mathbf{PS}), \tag{61}$$

sendo u um valor aleatório com distribuição uniforme $\in [0,1]$, N o tamanho da população e D a dimensão do problema.

Os melhores m indivíduos de PS obtidos através de um torneio TC entre dois ou três indivídos, quantidade e indivíduos selecionados aleatoriamente, são armazenados em arch baseado no desempenho apresentado no cálculo da função custo $\mathcal{F}(PS_{io})$,

A operação de *crossover* é realizada a partir de três indivíduos precursores, gerando três descendentes com taxa de *crossover* (*cr*). Tal operação considera que os três precursores sejam diferentes entre si e são ordenados conforme seus correspondentes cálculos da função custo:

$$\mathcal{F}(x_i) \le \mathcal{F}(x_{i+1}) \le \mathcal{F}(x_{i+2}),\tag{62}$$

um valor aleatório β , obtido a partir de uma distribuição normal (randn) com média μ e desvio padrão σ é utilizado na geração dos indivíduos descendentes (o_i) :

$$o_{1} = x_{1} + \beta(x_{2} - x_{3}),$$

$$o_{2} = x_{2} + \beta(x_{3} - x_{1}),$$

$$o_{3} = x_{3} + \beta(x_{1} - x_{2}).$$
(63)

Gerados os três indivíduos descendentes, um operador aleatório é utilizado de modo a diversificá-los considerando uma probabilidade p para cada o_i gerado na iteração, caso o teste de probabilidade seja satisfeito, um dos valores j do vetor de decisão o_i^j é substituído por um valor contido em uma das melhores soluções armazenada em arch escolhida de maneira aleatória, sendo por fim obtidos como indivíduos descendentes o_i' .

Considerando a população final (x) constituída por o'_i e arch, caso existam indivíduos idênticos, realiza-se a operação:

$$\mathbf{x}_i \coloneqq \mathbf{x}_i + randn(0.5u, 0.25u),\tag{64}$$

sendo u um valor aleatório com distribuição uniforme $\in [0,1]$.

O pseudocódigo do GA-MPC é apresentado no Algoritmo 4:

Algoritmo 4 - Pseudocódigo do GA-MPC

```
Definição dos Parâmetros de Controle
      Tamanho da População: PS
      Número das Variáveis de Decisão: D
      Inicia a população PS com N indivíduos
     Para G = 1 até Máximo de Ciclos
1
             Calcula \mathcal{F}(\mathbf{PS}_{i_0}) e ordena do melhor para o pior
2
             Aplica uma seleção por torneio de tamanho TC e ordena os indivíduos
3
             Salva os m melhores indivíduos em arch
4
             Para 3 indivíduos consecutivos até PS
5
                    Se u < cr então
6
                           Ordena os 3 indivíduos
7
                           Se x_i \equiv x_{i_0} então
8
                                   Substitui x_i := x_k
9
                           Fim se
                           Calcula \beta = randn(\mu, \sigma)
10
                           Gera 3 soluções o<sub>i</sub>
11
                           Se u < p então
12
                                   Substitui o_i^{\prime j} := x_{arch}^j \mid arch \in [1, m]
13
                           Fim se
                           Se x_i \equiv x_{i_0} então
14
                                   Substitui x_i := x_i + randn(0.5u, 0.25u)
15
                           Fim se
                    Fim se
             Fim para
      Fim para
```

3.2.5 Competição por Recursos

O algoritmo Competição por Recursos (COR – Competition Over Resources) proposto por Mohseni et al. (2014) baseia-se no comportamento de grupos de animais, na qual a competição por recursos é entendida como um efeito negativo ocasionado pela presença de diferentes grupos em uma mesma vizinhança, levando

à escassez de tais recursos, de forma que, a competição pode ser considerada, portanto, como um dos principais fatores de controle populacional existentes (BEGON; TOWNSEND; HARPER, 1986).

A proposta inicial do COR orientou-se pela tentativa de especificação de um algoritmo capaz de solucionar problemas de otimização, de maneira a obter a melhor solução, independentemente das condição de restrição (MOHSENI *et al.*, 2014).

O COR foi utilizado para em dois trabalhos distintos principais, garantindo sua relevância para diferentes condições de aplicação, o primeiro referente à minimização do custo computacional e demanda energética envolvido em sistemas de iluminação em construções apresentado por Mendes *et al.* (2017) na qual três modificações foram propostas, com intuito de incremento do desempenho do algoritmo, a segunda aplicação, esta apresentada por Bouchekara e Nahas (2017) deu-se na otimização de atuadores magnéticos, onde o COR mostrou-se eficiente e competitivo, quando comparado a outras metaheurísticas.

Em sua implementação, uma população P com nPop indivíduos é inicializada através de uma função geradora de valores aleatórios contínuos uniformemente distribuídos (rand), em um conjunto universo onde todas as variáveis de decisão estão sujeitas a um mesmo intervalo na forma:

$$\boldsymbol{P}_{i_0,j_0} = rand\big(U(low,up)\big) \mid (nPop,nVar) \leftarrow tamanho(\boldsymbol{P}). \tag{65}$$

A população é então dividida em uma quantidade especificada nGrp de grupos com quantidades iguais de indivíduos. Calculando-se a função custo $\mathcal{F}(\boldsymbol{P}_{i_0})$, o melhor indivíduo de cada grupo é nomeado como alfa, que sobrevive ao fim da iteração e gera novos indivíduos descendentes em seu próprio território.

O território (*neigh*) de cada grupo é dado através da distância Euclidiana entre os indivíduos *alfa* dos diferentes grupos:

$$neigh_{i_0} = \min\left(\frac{\sum_{i=1}^{nGrp} \left| \boldsymbol{P}_{i_0} - \boldsymbol{P}_i \right|}{nVar}\right),\tag{66}$$

sendo possível que alguns dos indivíduos pertencentes a um grupo realizem uma busca fora dos limites do território do grupo durante o processo, de modo a prover uma busca aleatória, desta forma, os limites de busca interna ao território são dados por:

$$interna = \left(\left(P_{i_0} - neigh_{i_0} \right), \left(P_{i_0} + neigh_{i_0} \right) \right), \tag{67}$$

a busca no espaço externo ao território do grupo é dependente de um valor especificado nos parâmetros do algoritmo $d_search \in [0,1]$, os limites de busca são dados por:

$$externa = ((P_{i_0} - d_{search(up-low)}), (P_{i_0} + d_{search(up-low)})).$$
(68)

O algoritmo COR possui duas especificações para cada grupo, a posição do indivíduo alfa e o número de indivíduos. Durante a primeira iteração, todos os grupos possuem a mesma quantidade de indivíduos, entretanto, durante a execução do algoritmo, a população dos grupos com piores resultados reduzirá e do melhor aumentará baseando-se na taxa de mortandade (d_rate) pré-definida para a próxima iteração.

O pseudocódigo do COR é apresentado no Algoritmo 5:

Algoritmo 5 - Pseudocódigo da COR Detalhes dos Parâmetros de Controle Número de variáveis de decisão: *nVar* Porcentagem de busca do espaço de decisão: *d_search* Relação da população da vizinhança interna/externa: p_search Tamanho da População: nPop Número de grupos: nGrp Taxa de morte: d_rate Inicia a população P com nPop indivíduos Calcula $\mathcal{F}(nPop)$ e identifica os nGrp indivíduos alfa Para G = 1 até Máximo de Ciclos 1 2 Calcula a distância Euclidiana entre os indivíduos alfa 3 Para i = 1 até n_group 4 Realiza a busca em cada território individualmente 5 Classifica os indivíduos de cada grupo $\mathcal{F}(\mathbf{P}_{i_0})$ e mantém o melhor Fim para 6 Remove d_rate agentes do pior grupo 7 Adiciona d_rate agentes ao melhor grupo 8 **Se** group_population < 2 então 9 Elimina o pior grupo 10 Divide o melhor grupo em dois Fim se Fim para

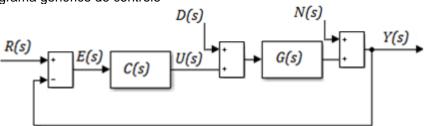
3.3 CRITÉRIOS DE OTIMIZAÇÃO COM RESTRIÇÕES

Considerando o diagrama genérico de um sistema de controle, apresentado na Fig. 14, Åström e Hägglund (2006) definiram critérios de estabilidade e robustez para controladores. O conceito de estabilidade provindo do trabalho de Maxwell (1868) refere-se ao comportamento do sistema após este sofrer uma perturbação, de tal forma, um controlador será instável se, quando o sistema controlado for sujeito a perturbações, o erro da variável de saída apresentar um incremento contínuo ou comportamento oscilatório crescente; e será estável se, o erro da variável de saída

reduzir continuamente ou o comportamento oscilatório decrementar em função do tempo.

A robustez do controlador relaciona-se quanto a variações do processo, na qual parâmetros da planta são modificados e geralmente decorrem de mudanças nas condições de operação.

Figura 14 - Diagrama genérico de controle



A estabilidade interna de um sistema, pode ser obtida através do cálculo de estabilidade das quatro funções de transferência:

$$\frac{Y(s)}{R(s)} = \frac{G(s)C(s)}{1 + G(s)C(s)}, \quad \frac{Y(s)}{D(s)} = \frac{G(s)}{1 + G(s)C(s)},
\frac{D(s)}{E(s)} = \frac{C(s)}{1 + G(s)C(s)}, \quad \frac{Y(s)}{N(s)} = \frac{1}{1 + G(s)C(s)}, \tag{69}$$

através do critério de Nyquist, por exemplo, ou simplesmente por:

$$Est = \Re(\lambda \{ H(s) \}) \tag{70}$$

na qual \Re denota a parte real dos autovalores (λ) da função de transferência de malha fechada com realimentação unitária:

$$H(s) = \frac{G(s)C(s)}{1 + G(s)C(s)}$$
(71)

de modo que o sistema será estável:

$$sse Est_i < 0 \mid i \in [1, ..., n(D_0)] \tag{72}$$

sendo $n(D_0)$ a ordem do maior denominador entre G(s) ou C(s).

O critério de robustez pode ser medido, sendo o sistema estável, para variações estáveis de $\Delta B(s)$ e $\Delta A(s)$ onde:

$$G(s) = \frac{B(s)}{A(s)} \tag{73}$$

desta forma, o cálculo da robustez pode ser feito por:

$$\max(|B(j\omega)|, |A(j\omega)|) = \bar{\sigma} \begin{pmatrix} \frac{1}{1 + G(j\omega)C(j\omega)} & \frac{G(j\omega)}{1 + G(j\omega)C(j\omega)} \\ \frac{C(j\omega)}{1 + G(j\omega)C(j\omega)} & \frac{G(j\omega)C(j\omega)}{1 + G(j\omega)C(j\omega)} \end{pmatrix} =$$

$$= \frac{\sqrt{(1 + |G(j\omega)|^2)(1 + |C(j\omega)|^2)}}{|1 + G(j\omega)C(j\omega)|} = \sum_{i=1}^{n} (\omega_i)^{i}$$

$$= \sum_{i=1}^{n} (\omega_i)^{i}$$

$$= \sum_{i=1}^{n} (\omega_i)^{i}$$

$$= \sum_{i=1}^{n} (\omega_i)^{i}$$

onde $\bar{\sigma}$ é o maior valor singular. Enquanto que o parâmetro M_{σ} pode ser definido como a medida de robustez do controlador, a qual engloba dinâmicas não modeladas do sistema e/ou perturbações que alterem sua dinâmica, matematicamente:

$$M_{\sigma} = \max_{\omega} \sum_{\omega} (\omega). \tag{75}$$

De acordo com Åström e Hägglund (2006), pode-se afirmar que o critério de robustez, para que determinado controlador seja considerado bom, este deve satisfazer a condição $M_{\sigma} < 3$. Entretanto, projetar controladores para sistemas complexos, com métricas de desempenho que satisfaçam a condição do projeto, podem tornar o controlador menos robusto, desta forma, Åström e Hägglund (2006) definem que deve ser satisfeito ao menos a condição $M_{\sigma} \ngeq 5$.

4 RESULTADOS

Inicialmente, para o sistema aquecedor elétrico, realizaram-se cinco repetições do experimento de parametrização do controlador PID, com funções custo $J_{IAE}(\theta)$, Eq. (20), e $J_{IAVU}(\theta)$, Eq. (28), tais funções custo foram consideradas para todos os testes dos três *benchmarks*, de modo a verificar a capacidade das soluções propostas pelos algoritmos, a partir da melhor solução proposta por cada um destes.

Para os *benchmarks* descritos em 3.1.1 e 3.1.2, referentes aos sistemas aquecedor elétrico e trocador de calor, os procedimentos realizados para avaliação de desempenho quanto à parametrização dos controladores seguiu as etapas descritas a seguir:

- i) Testes dos algoritmos através de 251 repetições para obtenção da função de densidade de probabilidade para as funções custo propostas e para o método agregador, bem como suas análises estatísticas;
- ii) Avaliação dos critérios de sensibilidade e robustez, descritos em 3.3, para as soluções medianas obtidas pelos algoritmos de modo a verificar a factibilidade da solução;
- iii) Comparação das soluções segundo algumas das métricas de desempenho apresentadas em 2.1.2 para verificação de possíveis soluções dominantes e dominadas, conforme definido em 2.2.2.

Para o terceiro *benchmark*, sistema de refrigeração, os algoritmos foram aplicados de maneira a obter uma única solução para comparação de desempenho com os controladores apresentados na literatura para a terceira Conferência sobre Avanços em Controle Proporcional-Integral-Derivativo.

De maneira que, sendo os algoritmos selecionados concebidos em função da otimização mono-objetivo, contudo, ao menos um critério de desempenho em relação ao erro e um critério de desempenho em relação à robustez do sinal de controle foram considerados, tem-se para todos os casos, problemas multiobjetivo.

A metodologia proposta para a otimização, a qual considerou algoritmos monoobjetivo, seguiu uma abordagem inversa à otimização através de algoritmos multiobjetivo apresentado em 2.2.3. Uma vez definidas as funções custo, um método de auxílio à tomada de decisão multicritério fora utilizado como função agregadora, conforme Fig. 15, em específico o método TOPSIS. Sendo o MOOD considerado e descrito de maneira a aproximar a fronteira de Pareto, na qual o MCDM é tido como ferramenta para seleção da melhor solução (REYNOSO-MEZA, 2014). Assim, o método proposto considera o MCDM como um caminho a suprimir a fronteira de Pareto, facilitando a seleção dos parâmetros, uma vez que sua análise requer um elevado nível de conhecimento a priori do problema.

Figura 15 - Metodologia de otimização multiobjetivo por algoritmo mono-objetivo



Originalmente proposto por Hwang e Yoon (1981) e posteriormente aplicado a tomada de decisão em problemas multiobjetivo por Lai, Liu e Hwang (1994), o conceito primordial do método TOPSIS, para um problema bidimensional de funções objetivo, é apresentado na Fig. 16. A ideia do método baseia-se na seleção da melhor alternativa (BestCost), baseada na proximidade (D_{ideal}) com a solução ideal (J_{IS}) e afastamento (D_{worst}) da solução indesejada (J_{WS}) ou pior solução (TZENG; HUANG, 2011). As Eqs. (76 – 78) definem D_{ideal} , D_{worst} e BestCost, utilizados no método TOPSIS.

$$D_{ideal} = \sqrt{\sum_{i=1}^{n} (J_i(\boldsymbol{\theta}) - J_{IS}(i))^2},$$
(76)

$$D_{worst} = \sqrt{\sum_{i=1}^{n} \left(J_i(\boldsymbol{\theta}) - J_{WS}(i)\right)^2},\tag{77}$$

$$BestCost = \min\left\{\frac{D_{worst} + D_{ideal}}{D_{worst}}\right\}. \tag{78}$$

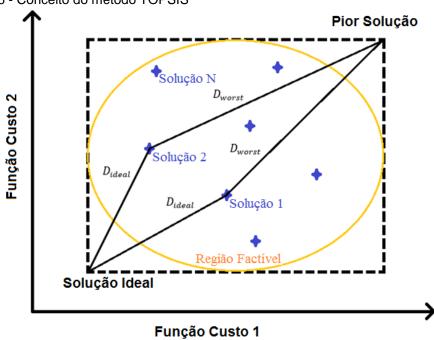


Figura 16 - Conceito do método TOPSIS

Uma das vantagens de utilização do método TOPSIS relaciona-se à possibilidade de definição dos pontos de função custo ideal e indesejada, baseando-se nas condições de: para o ponto ideal a condição utópica de erro zero e esforço de controle zero e para a solução indesejada o erro apresentado pelo sistema oscilante ou controle divergente e seu correlato esforço de controle.

Possuindo o tomador de decisão, conhecimento *a priori* do sistema de controle a ser otimizado, uma ponderação, quanto às funções custo, pode ser considerada de duas maneiras, a primeira, através da utilização de uma constante de ponderação associada às funções custo, de modo a penalizá-las proporcionalmente ao seu grau de relevância; a segunda através da alteração das coordenadas da solução ideal, desta forma, não estando o objetivo agregado sobre a condição utópica, as soluções são tendenciadas pelas preferências do avaliador.

A seguir são apresentados os resultados dos experimentos realizados para o benchmark I referente ao aquecedor elétrico, as análises estatísticas, a verificação dos critérios de estabilidade e robustez e a análise dos resultados dos valores das medianas do conjunto de soluções apresentadas pelos algoritmos. Na sequência, o benchmark II do trocador de calor é avaliado, sendo apresentadas as distribuições de probabilidade obtidas através dos resultados dos algoritmos, bem como a análise quanto à factibilidade segundo os critérios de estabilidade e robustez e a comparação dos resultados. Por fim, os controladores obtidos para o benchmark III, sistema de

refrigeração, são analisados qualitativamente e quantitativamente segundo os critérios apresentados em 3.1.3.

4.1 BENCHMARK I: AQUECEDOR ELÉTRICO

Para o sistema aquecedor elétrico descrito em 3.1.1, diversos testes de parametrização foram realizados e, para todos os casos, consideraram-se 30 indivíduos limitados a 6000 avaliações da função custo (BestCost), este calculado por $J_{IAE}(\theta)$ e $J_{IAVU}(\theta)$ onde $\theta = [K_p, K_i, K_d, N]$ restrito a $\underline{\theta} = [0, 0, 0, 0]$ e $\overline{\theta} = [10, 10, 10, 100]$. Adicionalmente, para todos os experimentos realizados com o sistema aquecedor elétrico, definiu-se para solução ideal e para a solução indesejada no cálculo do TOPSIS os pontos fixos $J_{IS} = [0, 0]$ e $J_{WS} = [3000, 3000]$, conforme descrito em 4, sendo o período de amostragem igual a 0,1s.

Inicialmente avaliou-se cinco repetições do experimento para cada um dos algoritmos propostos. Os conjuntos de soluções obtidas pelos algoritmos, bem como os valores das funções custo originais, foram apresentados na tabela 2 para o algoritmo DE, tabela 3 para a WDE, tabela 4 para o GA, na tabela 5 para o GA-MPC e, por fim, na tabela 6 para a COR, nas quais as melhores soluções quanto ao método TOPSIS são apresentadas em destaque.

Tabela 2 - DE aquecedor elétrico 5 experimentos

Experimento	K_p	K_i	K_d	N	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(\boldsymbol{\theta})$
1	1,3554	2,4193	0	0	23,3724	17,7225
2	1,3559	2,4176	0	0	23,3716	17,7279
3	1,4069	2,5118	0,0210	10	22,5082	19,3827
4	1,3832	2,4507	0,0157	10	22,7357	18,5773
5	1,3554	2,4192	0,0124	9,6940	22,9757	17,9013

Tabela 3 - WDE aquecedor elétrico 5 experimentos

Experimento	K_p	K_i	K_d	N	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(\boldsymbol{\theta})$
1	1,3982	4,9496	0,0650	18,8085	28,6818	32,9357
2	1,3734	3,5599	0,8225	0,5783	25,9703	31,6175
3	1,1973	3,3096	0,1518	8,7677	26,4417	34,6096
4	1,0843	3,3975	0,0395	25,1048	29,9705	23,9785
5	1,1700	2,2023	-0,1004	15,8013	33,7285	24,6941

Tabela 4 - GA aquecedor elétrico 5 experimentos

Experimento	K_p	K_i	K_d	N	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(\boldsymbol{\theta})$
1	1,5203	2,9944	0,2159	73,3211	37,7603	341,9114
2	0,2997	1,9336	8,3568	0,0504	36,2795	8,5798
3	1,1757	3,6403	0,0990	19,8672	27,2796	41,6373
4	1,8491	5,9051	0,0645	17,4182	27,4547	45,3572
5	0,9474	4,6841	1,0332	1,1398	29,4984	43,1091

Tabela 5 - GA-MPC aquecedor elétrico 5 experimentos

Experimento	K_p	K_i	K_d	N	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(\boldsymbol{\theta})$
1	1,6642	3,4517	0,0293	13,6141	23,5549	27,6542
2	1,5236	2,3150	0,0222	11,2151	23,9683	22,0757
3	1,4490	2,5190	0,0576	14,4014	22,5647	27,0590
4	1,6642	3,4517	0,0293	13,6141	23,5549	27,6542
5	1,5236	2,3150	0,0222	11,2151	23,9683	22,0757

Tabela 6 - COR aquecedor elétrico 5 experimentos

Experimento	K_p	K_i	K_d	N	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(\boldsymbol{\theta})$
1	0,5401	11,2510	99,9198	0,0151	152,5643	261,7592
2	1,3609	2,4206	0,0031	30,1561	23,1402	17,7440
3	1,6320	6,6323	0	0	39,8598	44,0772
4	1,7691	1,2084	0	0	42,6562	26,0536
5	1,8066	9,6283	98,6392	2,3e-10	78,8744	111,5569

Dos conjuntos de soluções apresentados, selecionou-se o melhor, baseado no critério TOPSIS, e aplicou-os no modelo para uma primeira análise quanto à capacidade da controlabilidade do sistema. Sendo os resultados apresentados na Fig. 17 (a) para a capacidade de seguir a referência (sendo 6 a temperatura relativa a 48°C) e Fig. 17 (b) o sinal de controle, nota-se que todos os controladores apresentados possuem a capacidade de controlar o sistema nas condições de operação descritas.

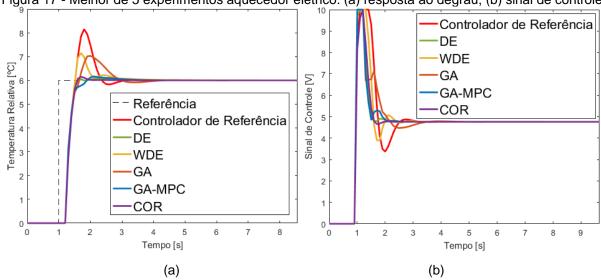


Figura 17 - Melhor de 5 experimentos aquecedor elétrico: (a) resposta ao degrau; (b) sinal de controle.

Para os resultados apresentados, os testes de estabilidade Eq. (70) e robustez Eq. (75) descritos em 3.3 foram realizados e são apresentados na tabela 7. Levandos em conta uma verificação prévia, todos os controladores são estáveis para distúrbios do sistema, entretanto os resultados obtidos pela WDE e GA não atendem o critério de robustez proposto por Åström e Hägglund (2006), enquanto que o controlador do algoritmo COR apresentou melhor desempenho.

Tabela 7 - Testes de estabilidade e robustez melhor de 5

Algoritmo	Controlador	Estável	(M_{σ})
Referência	$C(s) = 1,44 + \frac{4,6}{s} + 0,1130s$	Sim	112,60
DE	$C(s) = 1,4069 + \frac{2,5118}{s} + 0,021s + \frac{10}{s+10}$	Sim	3,5331
WDE	$C(s) = 1,3734 + \frac{3,5599}{s} + 0,8225s + \frac{0,5783}{s + 0,5783}$	Sim	5,4367
GA	$C(s) = 1,1757 + \frac{3,6403}{s} + 0,099s + \frac{19,8672}{s + 19,8672}$	Sim	5,2285
GA-MPC	$C(s) = 1,449 + \frac{2,519}{s} + 0,0576s + \frac{14,4014}{s + 14,4014}$	Sim	4,2763
COR	$C(s) = 1,3609 + \frac{2,4206}{s} + 0,0031s + \frac{30,1561}{s + 30,1561}$	Sim	3,1984

Faz-se necessário ressaltar que, para o critério de robustez definido por Åström e Hägglund (2006), a condição $M_{\sigma} > 5$, apresentada em 3.3 não é absoluta, uma vez

que tal critério possui um embasamento empírico, dado por testes sucessivos perante um conjunto de *benchmarks* estudados pelos autores.

Na sequência, foram realizadas 251 repetições do experimento para a análise estatística de tendência e de convergência dos algoritmos.

4.1.1 Análises Qualitativa e Quantitativa de Convergência dos Algoritmos

Para as análises qualitativas dos resultados das experimentações, expôs-se os conjuntos das funções custo obtidas, $J_{IAE}(\theta)$ e $J_{IAVU}(\theta)$ e do cálculo de TOPSIS através de diagramas de caixa e da função de densidade de probabilidade (pdf – probability density function) obtida pela estimativa de densidade de Kernel, este sendo um método não-paramétrico de estimação da distribuição com densidade desconhecida, ou seja, que não segue um padrão de distribuição convencional (PARZEN, 1962).

O estimador de densidade de Kernel para valores reais de x é dado por:

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K(\frac{x - x_i}{h})$$
 (79)

onde x_i , i = [1, ... n] são as amostras da distribuição, n é o tamanho da amostra, K(.) é a função de suavização do *kernel* e h a largura de banda.

Os resultados obtidos pela DE apresentaram um comportamento de agrupamento nos extremos do intervalo de custos para $J_{IAE}(\theta)$, Fig. 18 (a), e para o cálculo do TOPSIS, Fig. 18 (c), enquanto que, para $J_{IAVU}(\theta)$, Fig. 18 (b), a função de distribuição de probabilidade apresenta um comportamento menos esparso entre os dois extremos.

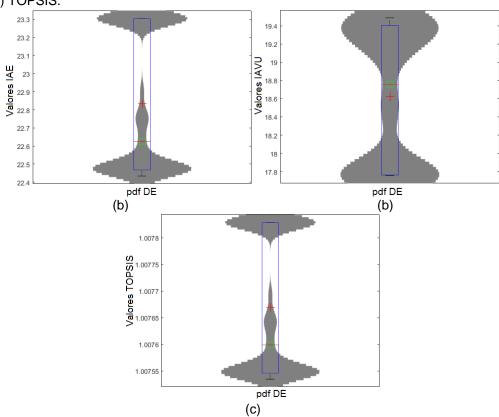


Figura 18 – Análise estatística do algoritmo DE para o *benchmark* I - aquecedor elétrico: (a) IAE; (b) IAUV; (c) TOPSIS.

Dos resultados obtidos, os valores máximos, mínimos, a mediana, a média e o desvio padrão para as funções custo originais e para o cálculo do TOPSIS são apresentados na tabela 8.

Tabela 8 - DE análise quantitativa aquecedor elétrico

	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(oldsymbol{ heta})$	TOPSIS
Máximo	23,3051	19,4865	1,0078
Mínimo	22,4345	17,7571	1,0075
Mediana	22,6238	18,7571	1,0076
Média	22,8332	18,6202	1,0077
Desvio Padrão	0,3882	0,7557	1,3140e-4

A análise qualitativa dos valores das funções custo Fig. 19 (a) e 19 (b), possibilita verificar que a WDE gerou resultados com menor agrupamento nos extremos para $J_{IAE}(\theta)$ quando comparado à DE e um conjunto mais centrado em torno da média para $J_{IAVU}(\theta)$, o conjunto de valores TOPSIS, Fig. 19(c), apresenta comportamento similar ao de $J_{IAE}(\theta)$.

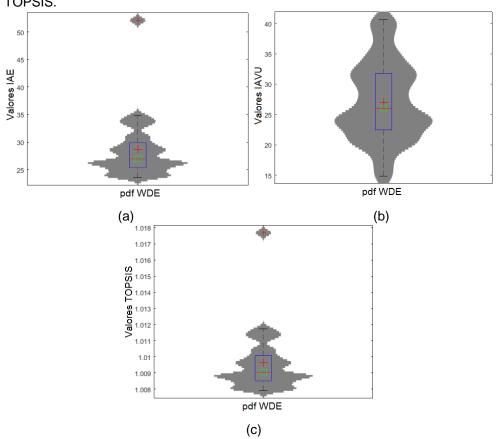


Figura 19 - Análise estatística do algoritmo WDE para o benchmark I - aquecedor elétrico: (a) IAE; (b) IAUV; (c) TOPSIS.

Para as soluções obtidas pela WDE, os valores máximos, mínimos, a mediana, a média e o desvio padrão para as funções custo originais e para o cálculo do TOPSIS são apresentados na tabela 9.

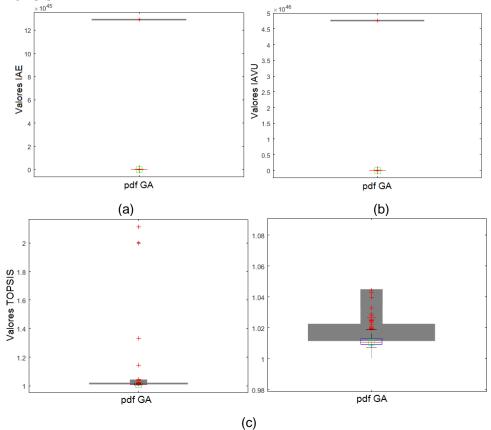
Tabela 9 - WDE análise quantitativa aquecedor elétrico

	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(\boldsymbol{\theta})$	TOPSIS
Máximo	52,1043	40,6611	1,0177
Mínimo	23,5691	14,8657	1,0079
Mediana	26,9157	26,0123	1,0091
Média	28,6596	27,0137	1,0096
Desvio Padrão	5,5454	6,4443	0,0019

Conforme apresentado nas Fig. 20 (a) e 20 (b), nota-se para ambas as funções custo uma divergência para um conjunto de soluções obtidas pelo GA, sendo estes controladores que divergiram da referência do sistema. Dois dos resultados apresentados pelo GA obtiveram o cálculo de IAVU zero, pois para ambos, o resultado

obtido pelo algoritmo foi a ausência de controlador. Devido a isso, pela Fig. 20 (c), pode-se observar uma série de *outliers* para o conjunto calculado do TOPSIS.

Figura 20 - Análise estatística do algoritmo GA para o benchmark I - aquecedor elétrico: (a) IAE; (b) IAUV; (c) TOPSIS.



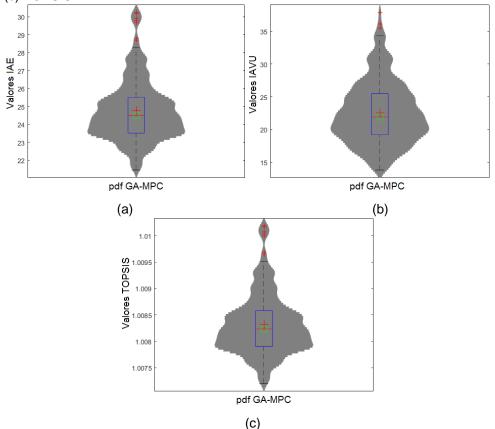
Os dados para análise quantitativa dos resultados para o cálculo das funções custo e TOPSIS, são apresentados na tabela 10. Nota-se que, devido às soluções divergentes apresentadas pelo algoritmo, os valores médios e o desvio padrão de $J_{IAE}(\theta)$ e $J_{IAVU}(\theta)$ apresentam valores de grandeza significativamente elevados.

Tabela 10 - GA análise quantitativa aquecedor elétrico

	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(\boldsymbol{\theta})$	TOPSIS
Máximo	1,2904e46	4,7647e46	2,1113
Mínimo	21,3624	0,0000	1,0072
Mediana	31,6618	35,0631	1,0107
Média	5,1412e43	1,8983e44	1,0268
Desvio Padrão	8,1451e44	3,0075e45	0,1177

Os resultados obtidos pelo GA-MPC geraram padrões similares para as funções custo $J_{IAE}(\theta)$, $J_{IAVU}(\theta)$ e para o cálculo de TOPSIS, conforme Fig. 21 (a), 21 (b) e 21 (c), respectivamente, apresentando para todas as distribuições, alguns *outliers* superiores, nota-se que a função distribuição de probabilidade apresenta o pico em torno do valor de primeiro quartil para os três casos.

Figura 21 - Análise estatística do algoritmo GA-MPC para o benchmark I - aquecedor elétrico: (a) IAE; (b) IAUV; (c) TOPSIS.



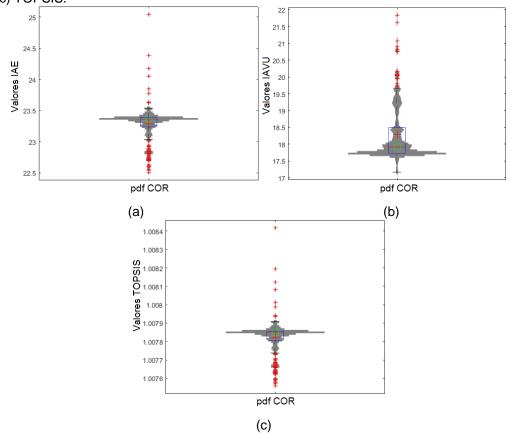
Os valores máximos, mínimos, a mediana, média e desvio padrão para ambas funções custo, bem como para o TOPSIS são apresentados na tabela 11, nota-se que o desvio padrão apresentado por $J_{IAVU}(\theta)$ é relativamente superior ao apresentado por $J_{IAE}(\theta)$.

Tabela 11 - GA-MPC análise quantitativa aquecedor elétrico

Tabela 11 - GA-IVIF C allalise qualititativa aquecedor eletrico					
	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(\boldsymbol{\theta})$	TOPSIS		
Máximo	30,2452	37,8877	1,0102		
Mínimo	21,4538	13,8237	1,0072		
Mediana	24,4955	21,9052	1,0082		
Média	24,7659	22,5540	1,0083		
Desvio Padrão	1,7018	4,7933	5,7705e-4		

Para os resultados obtidos pela COR, na Fig.22 (a – c), para $J_{IAE}(\theta)$, $J_{IAVU}(\theta)$ e TOPSIS, respectivamente, uma quantidade significativa de *outliers*, contudo para $J_{IAE}(\theta)$ e para o TOPSIS, é apresentada uma distribuição de soluções muito relevante próximo à mediana e para $J_{IAVU}(\theta)$ a distribuição de probabilidade se concentra sobre o primeiro quartil.

Figura 22 - Análise estatística do algoritmo COR para o benchmark I - aquecedor elétrico: (a) IAE; (b) IAUV; (c) TOPSIS.



Os valores para análise quantitativa dos resultados obtidos pelo COR são apresentados na tabela 12, na qual é possível observar que os valores, ainda que com *outliers* apresentados pela análise qualitativa, estão bem concentrados para o conjunto de soluções.

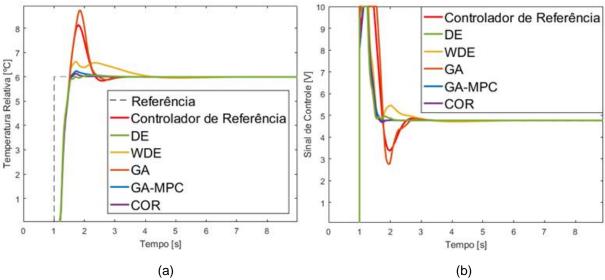
Tabela 12 - COR análise quantitativa aquecedor elétrico

	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(\boldsymbol{\theta})$	TOPSIS
Máximo	25,0420	21,8304	1,0084
Mínimo	22,5058	17,1699	1,0076
Mediana	23,3562	17,9147	1,0078
Média	23,2836	18,2823	1,0078
Desvio Padrão	0,2739	0,8303	9,2734e-5

4.1.2 Análise de Sensibilidade e Robustez dos Controladores

Dos resultados apresentados pelas 251 repetições dos cinco algoritmos, selecionou-se a solução da mediana para comparação e avaliação dos controladores sujeitos às restrições do sistema, aplicando-se um sinal degrau de amplitude 6, referente a 48°C, os controladores obtiveram as respostas apresentadas na Fig. 23 (a), com sinal de controle apresentado na Fig. 23 (b).

Figura 23 – Controladores da mediana – aquecedor elétrico: (a) resposta ao degrau; (b) sinal de controle.



De modo que todos os controladores obtidos pelos algoritmos foram capazes de seguir a referência, realizou-se a análise dos critérios de estabilidade e robustez (M_{σ}) , sendo seus valores obtidos e apresentados na tabela 13, bem como as equações dos controladores obtidos pelos respectivos algoritmos, em destaque o controlador apresentado pelo algoritmo GA-MPC que apresentou melhor desempenho segundo o critério de robustez.

Tabala 12	Critárias da	actabilidada a	robuctoz	aquecedor elétrico
Tabela 13 -	Unterios de	estabilidade e	robusiez	aquecegor eletrico

Algoritmo	Controlador	Estável	(M_{σ})
Referência	$C(s) = 1,44 + \frac{4,6}{s} + 0,1130s$	Sim	112,60
DE	$C(s) = 1,3835 + \frac{2,4818}{s} + 0,0189s \frac{10}{s+10}$	Sim	3,4278
WDE	$C(s) = -0.3269 + \frac{4,4065}{s} + 2,1276s + \frac{0.9912}{s + 0.9912}$	Sim	4,7111
GA	$C(s) = 1,9217 + \frac{6,2016}{s} + 0,0725s \frac{39,1379}{s + 39,1379}$	Sim	7,5181
GA-MPC	$C(s) = 0.9715 + \frac{2,5589}{s} + 6,6143s \frac{0,0551}{s + 0,0551}$	Sim	3,1678
COR	$C(s) = 1,3614 + \frac{2,4283}{s}$	Sim	3,2179

4.1.3 Comparação das Soluções

Sendo que todos os controladores atenderam ao critério de estabilidade, ainda que não ao critério de robustez, ambos de caráter excludente, realizou-se a verificação das métricas de desempenho para todos os controladores, apresentado na tabela 14, onde Mp[%] é o máximo pico, ou maior sobressinal de erro em relação à referência e Tst2%[s] é o tempo sob o qual o sistema esteve sujeito a condições de operação no qual a saída do sistema divergia em mais de 2% do sinal de referência, são destacados os melhores valores para cada uma das métricas consideradas.

Tabela 14 - Métricas de desempenho aquecedor elétrico

	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(\boldsymbol{\theta})$	TOPSIS	<i>Mp</i> [%]	<i>Tst</i> 2%[<i>s</i>]
Referência	33,2809	18,2562	1,0112	35,8228	2,8181
DE	23,2187	15,4208	1,0078	1,2184	1,5605
WDE	32,2915	16,6561	1,0109	10,6602	3,8382
GA	35,2742	19,5080	1,0119	45,75	2,8232
GA-MPC	24,8051	15,3702	1,0083	4,0759	2,0397
COR	23,6768	15,5044	1,0079	2,3554	1,8074

De modo a facilitar a análise das métricas de desempenho, estas foram normalizadas segundo:

$$J_i(\boldsymbol{\theta}) = \frac{J_i(\boldsymbol{\theta}) - \overline{J_i(\boldsymbol{\theta})}}{S_i}$$
 (80)

onde i=[1,...7] são os índices das funções custo, $\overline{J_i(\theta)}$ a média da função custo i para os seis controladores e S_i o desvio padrão, sendo portanto a distribuição em coordenadas paralelas, Fig. 24, com média zero e desvio padrão no intervalo [-1,1]. Podendo-se verificar que os controladores WDE e GA são dominados em todas as métricas de desempenho avaliadas, alguns trade-offs entre as soluções COR e DE para com GA-MPC implicam que, uma maior quantidade de análises, deve ser realizada.

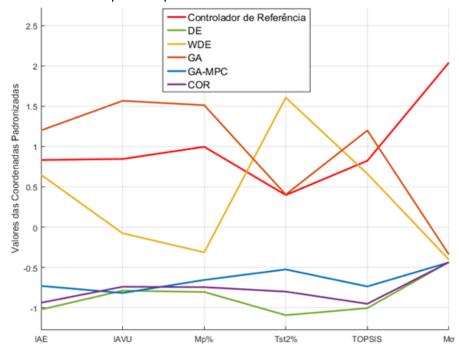


Figura 24 - Métricas de desempenho aquecedor elétrico

4.2 BENCHMARK II: TROCADOR DE CALOR

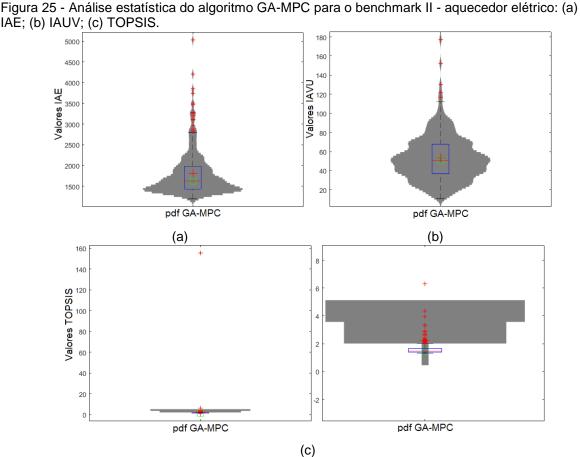
Conforme apresentado em 4.1.2 sendo o controlador obtido pela mediana do conjunto de soluções do algoritmo GA incapaz de satisfazer o critério de robustez (M_{σ}) para o sistema aquecedor elétrico, o mesmo fora desconsiderado para a avaliação do sistema trocador de calor descrito em 3.1.2.

Novamente consideraram-se para os 251 experimentos, 30 indivíduos limitados a 6000 avaliações da função custo calculado pelo método TOPSIS, agregando $J_{IAE}(\theta)$ e $J_{IAVU}(\theta)$ onde $\theta = \begin{bmatrix} K_p, K_i, K_d, N \end{bmatrix}$ restrito a $\underline{\theta} = [0, 0, 0, 0]$ e $\overline{\theta} = [10, 10, 10, 100]$,

definiu-se para solução ideal e para a solução indesejada, os pontos fixos $J_{IS} = [0, 0]$ e $J_{WS} = [5000, 5000]$, dos valores utópico e de não convergência, respectivamente, o período de amostragem considerado foi de 0,1s.

4.2.1 Análises Estatísticas e de Convergência

Os resultados obtidos pelo GA-MPC para as funções custo $J_{IAE}(\theta)$, $J_{IAVU}(\theta)$ e para o cálculo de TOPSIS, são apresentados nas Fig. 25 (a), 25 (b) e 25 (c), respectivamente, apresentando para todas as distribuições outliers superiores, para $J_{IAE}(m{ heta})$, nota-se que o pico de distribuição de probabilidade dos resultados dá-se sobre o primeiro quartil, possuindo ainda muitos outliers quando comparado à distribuição de $J_{IAVII}(\theta)$. A distribuição do TOPSIS apresentou um padrão peculiar, sugerindo uma não convergência para o método.

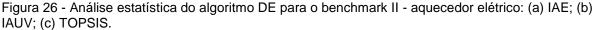


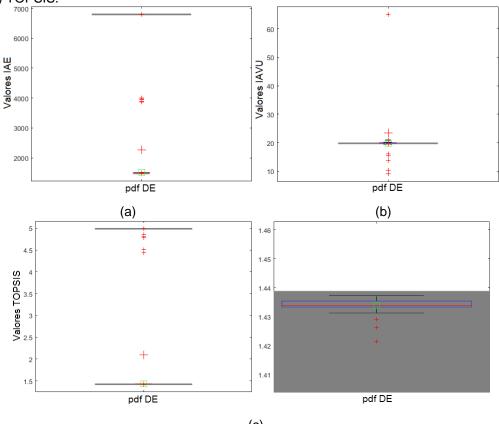
Os valores máximo, mínimo, a mediana, a média e o desvio padrão para as funções custo e para o cálculo do TOPSIS são apresentados na tabela 15, nota-se que o valor máximo para a função custo $J_{IAE}(\theta)$ é superior ao estabelecido como valor de divergência da solução $J_{WS,IAE}(\theta)$, sendo portanto que o GA-MPC não obteve soluções factíveis para todos os 251 experimentos.

Tabela 15 - GA-MPC análise quantitativa trocador de calor

	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(oldsymbol{ heta})$	TOPSIS
Máximo	5032,5947	177,3189	155,3990
Mínimo	1194,1120	10,6134	1,3138
Mediana	1626,4118	50,7893	1,4821
Média	1805,6824	53,2546	2,2442
Desvio Padrão	560,3427	24,2493	9,7184

Assim como apresentado pelo algoritmo no *benchmark* do aquecedor elétrico, o conjunto de soluções para $J_{IAE}(\theta)$ e TOPSIS, Fig. 26 (a) e 26 (c), apresentaram agrupamentos nos extremos, para aquele com *outliers* fora da região de convergência do sistema. Na Fig. 26(b) é apresentado $J_{IAVU}(\theta)$ com média de soluções além da região de distribuição de probabilidade.



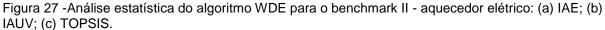


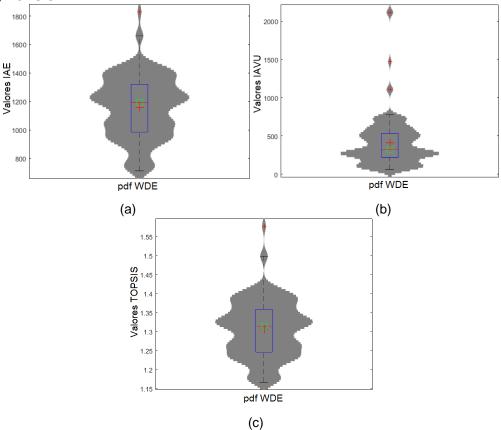
Os valores de $J_{IAE}(\theta)$, $J_{IAVU}(\theta)$ e do cálculo do método TOPSIS para análise quantitativa dos resultados é apresentado na tabela 16, onde o valor máximo de $J_{IAE}(\theta)$ apresenta um valor superior ao definido pela região de convergência.

Tabela 16 - DE análise quantitativa trocador de calor

	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(oldsymbol{ heta})$	TOPSIS
Máximo	6794,8036	65,0585	4,9866
Mínimo	1482,4377	9,0701	1,4214
Mediana	1512,8825	19,8656	1,4338
Média	2268,1699	23,4242	2,0955
Desvio Padrão	1648,9958	13,7881	1,3322

A Fig. 27 (a – c) apresenta os padrões do conjunto de soluções para $J_{IAE}(\theta)$, $J_{IAVU}(\theta)$ e TOPSIS, respectivamente. As três distribuições apresentam alguns *outliers* superiores, e padrões para a função de densidade de probabilidade bem distribuídos em relação aos intervalos.





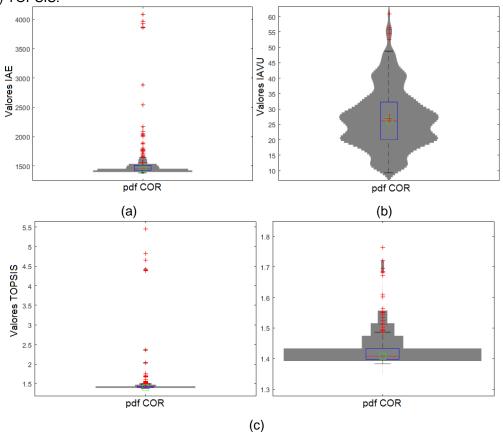
Os valores máximos, mínimos, a mediana, média e desvio padrão para ambas funções custo, bem como para o TOPSIS são apresentados na tabela 17, nota-se que os valores máximos de $J_{IAE}(\theta)$ e $J_{IAVU}(\theta)$ são inferiores a 50% dos valores máximos de convergência estabelecidos.

Tabela 17 - WDE análise quantitativa trocador de calor

'	rabela 17 WEE arialise quartitativa trocador de calor				
	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(oldsymbol{ heta})$	TOPSIS		
Máximo	1828,3920	2116,2982	1,5765		
Mínimo	713,0474	61,5695	1,1663		
Mediana	1191,6804	322,0710	1,3129		
Média	1158,9072	412,8123	1,3059		
Desvio Padrão	218,1582	323,0385	0,0749		

Para os resultados obtidos pela COR, nas Fig. 28 (a), 28 (b) e 28 (c), para $J_{IAE}(\theta), J_{IAVU}(\theta)$ e TOPSIS, respectivamente, uma quantidade significativa de *outliers*, contudo para as três análises, é apresentada uma distribuição de soluções muito relevante próximo à mediana, sendo portanto o comportamento similar ao apresentado pelo algoritmo para o *benchmark* do aquecedor elétrico.

Figura 28 - Análise estatística do algoritmo COR para o benchmark II - aquecedor elétrico: (a) IAE; (b) IAUV; (c) TOPSIS.



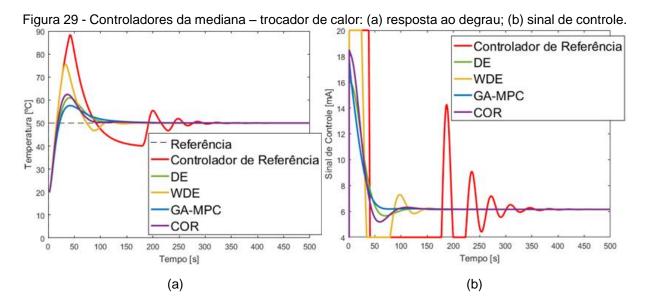
Os valores para análise quantitativa dos resultados obtidos pelo COR são apresentados na tabela 18, sendo possível observar que o valor máximo de $J_{IAE}(\theta)$, ainda que relativamente próximo à borda, encontra-se dentro da região de convergência.

Tabela 18 - COR análise quantitativa trocador de calor

	$J_{IAE}(oldsymbol{ heta})$	$J_{IAVU}(\boldsymbol{\theta})$	TOPSIS
Máximo	4082,0985	60,8510	5,4472
Mínimo	1382,6013	9,2764	1,3822
Mediana	1447,3950	26,0967	1,4074
Média	1561,3672	26,9732	1,5120
Desvio Padrão	406,3539	9,8187	0,5094

4.2.2 Análise das Restrições de Sensibilidade e Robustez

Dos resultados apresentados pelas 251 repetições dos quatro algoritmos, selecionou-se a solução da mediana para comparação e avaliação dos controladores sujeitos às restrições do sistema, aplicando-se um sinal degrau 50°C, os controladores obtiveram as respostas apresentadas na Fig. 29 (a), com sinal de controle apresentado na Fig. 29 (b).



Sendo que todos os controladores obtidos pelos algoritmos foram capazes de seguir a referência, realizou-se a análise dos critérios de estabilidade e robustez

 (M_{σ}) , sendo seus valores obtidos e apresentados na tabela 19, bem como as equações dos controladores obtidos pelos respectivos algoritmos.

Tabela 19 - (Critérios de	estabilidade	e robustez	trocador de calor

Algoritmo	Controlador	Estável	(M_{σ})
Referência	$C(s) = 14,28 + \frac{0,9920}{s} + 51,2652s$	Sim	600,79
DE	$C(s) = 1,5833 + \frac{0,0462}{s}$	Sim	4,7024
WDE	$C(s) = 6,1189 + \frac{0,1837}{s} + 18,0047s + \frac{2,1194}{s+2,1194}$	Sim	1,05e3
GA-MPC	$C(s) = 1,4734 + \frac{0,038}{s} + 2,6163s \frac{0,1502}{s + 0,1502}$	Sim	3,7549
COR	$C(s) = 1,885 + \frac{0,0501}{s}$	Sim	3,6459

Teve-se para o melhor desempenho segundo o critério de robustez o controlador obtido pelo algoritmo COR, em destaque.

4.2.3 Comparação entre os Algoritmos

De modo que todos os controladores atenderam ao critério de estabilidade, ainda que não ao critério de robustez, para o caso da WDE, ambos de caráter excludente, realizou-se a verificação das métricas de desempenho para todos os controladores, apresentado na tabela 20, sendo Mp[%] o máximo pico e Tst2%[s], o tempo de estabilização a 2% da referência. Foram realçados os melhores desempenhos para cada uma das métricas selecionadas para a avaliação.

Tabela 20 - Métricas de desempenho trocador de calor

	$J_{IAE}(\boldsymbol{\theta})$	$J_{IAVU}(oldsymbol{ heta})$	TOPSIS	<i>Mp</i> [%]	<i>Tst</i> 2% [s]
Referência	4167,9556	68,9650	6,0093	76,553	269,5
DE	1848,9634	23,3051	1,5868	21,925	96,20
WDE	2066,6667	37,3109	1,7045	50,911	102,4
GA-MPC	1792,2645	25,6160	1,5587	15,130	101,2
COR	1754,8647	29,0898	1,5408	24,885	81,60

Os valores das funções custo e das métricas de desempenho normalizados conforme Eq. (80), são apresentados em coordenadas paralelas na Fig. 30.

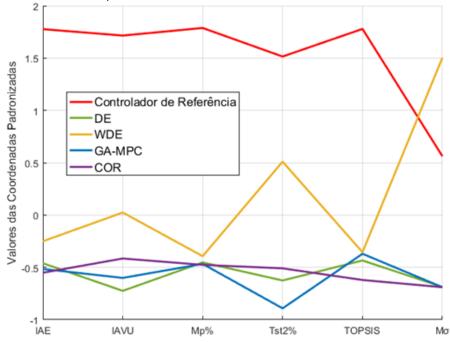


Figura 30 - Métricas de desempenho trocador de calor

Da mesma maneira que para o aquecedor elétrico, a solução apresentada por WDE para o sistema trocador de calor é dominada para todas as métricas de desempenho avaliadas. Possuindo as soluções de DE, GA-MPC e COR trade-offs, aplicou-se os distúrbios de fluxo e de temperatura no sistema para análise qualitativa.

O fluxo de entrada do fluido do processo foi submetido a uma redução de 5Kg/s a partir do instante 150 o qual, posteriormente sofreu um acréscimo de 2ºC na temperatura no instante 300, a resposta do sistema, bem como o sinal de controle são apresentados nas Fig. 31 (a) e 31 (b), respectivamente.

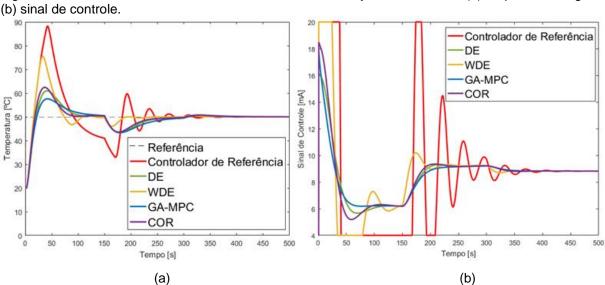


Figura 31 - Controladores da mediana – trocador de calor sujeito a distúrbios: (a) resposta ao degrau;

Nota-se que todos os controladores foram capazes de controlar o sistema, sendo o obtido pelo COR mais rápido na rejeição ao distúrbio quando comparado aos controladores da DE e do GA-MPC.

4.3 BENCHMARK III: SISTEMA DE REFRIGERAÇÃO

Considerando o *benchmark* descrito em 3.1.3, buscou-se a obtenção de um controlador que melhor controlasse o sistema e obtivesse melhor índice de desempenho J_R , contudo, sendo o sistema de múltiplas entradas e múltiplas saídas (MIMO – *Multiple-Input and Multiple-Output*), o desempenho dos algoritmos não pode ser embasado nos resultados obtidos para os *benchmarks* anteriores.

O modelo paramétrico adotado para a otimização dos controladores, foi obtido por (REYNOSO-MEZA; SÁNCHEZ; ALVES RIBEIRO, 2018) através do método de resposta ao degrau, aplicado diretamente ao modelo não-linear fornecido no benchmark. Sendo o processo previamente descrito em 3.1.3, um modelo MIMO considerando estruturas de primeira ordem foram obtidos.

Para o estudo, $Y_1(s)$ e $Y_2(s)$ representam, $T_{e,sec,out}$ e T_{SH} , respectivamente, e são relacionados às duas entradas A_v e N, conforme a Eq. (83), para o sistema em malha aberta.

$$\begin{bmatrix} Y_1(s) \\ Y_2(s) \end{bmatrix} = \begin{bmatrix} -0.020 \frac{1 + 49.690s}{1 + 25.988s} & -\frac{1.7545 \times 10^{-3}}{1 + 16.772s} \\ -0.309 \frac{1 + 33.468s}{1 + 24.933s} & 0.160 \frac{1 + 44.622s}{1 + 40.872s} \end{bmatrix} \begin{bmatrix} A_v \\ N \end{bmatrix}.$$
(81)

O modelo paramétrico utilizado considerou $C_1(s)$ e $C_2(s)$ controladores PID em uma estrutura de controle descentralizada, onde $C_1(s)$ controla $T_{e,sec,out}$ através da A_v , gerando um distúrbio em T_{SH} e $C_2(s)$ controla T_{SH} através de N, gerando um distúrbio em $T_{e,sec,out}$, conforme Fig. 32, sendo ainda que o período de amostragem, definido por Bejarano *et al.* (2018), para o sistema é de 1s.

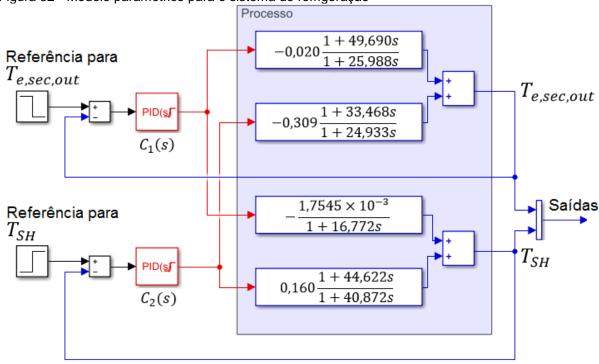


Figura 32 - Modelo paramétrico para o sistema de refrigeração

De maneira a obter os parâmetros dos controladores que otimizem seu desempenho, assumiu-se quatro funções custo na forma:

$$J_{1}(\boldsymbol{\theta}) = \int \left| e_{T_{e,sec,out}} \right| dt, \qquad J_{2}(\boldsymbol{\theta}) = \int \left| e_{T_{SH}} \right| dt,$$

$$J_{3}(\boldsymbol{\theta}) = \int \left| \frac{dU_{1,PID}}{dt} \right| dt, \qquad J_{4}(\boldsymbol{\theta}) = \int \left| \frac{dU_{2,PID}}{dt} \right| dt,$$
(82)

sendo o problema multiobjetivo definido por:

$$\min_{\boldsymbol{\theta}} \boldsymbol{J}_{m}(\boldsymbol{\theta}) = [J_{1}(\boldsymbol{\theta}), J_{2}(\boldsymbol{\theta}), J_{3}(\boldsymbol{\theta}), J_{4}(\boldsymbol{\theta})], \tag{83}$$

onde

$$\boldsymbol{\theta} = \left[-k_{p1}, -k_{i1}, -k_{d1}, f_1, k_{p2}, k_{i2}, k_{d2}, f_2 \right]. \tag{84}$$

Neste problema θ representa um vetor de decisão composto pelos ganhos proporcionais k_{p1} e k_{p2} , ganhos integrais k_{i1} e k_{i2} , ganhos derivativos k_{d1} e k_{d2} , e os filtros do derivativo f_1 e f_2 . Sendo a restrição considerada para os componentes do

vetor $0 \le \theta \le 50$, obtido através das análises de ganho crítico do lugar das raízes da função de transferência que relaciona A_v a $T_{e,sec,out}$.

As funções custo $J_1(\theta)$ e $J_2(\theta)$ representam a integral do erro absoluto (IAE), sendo a diferença entre o sinal de referência e a saída controlada da temperatura de saída do fluxo secundário do evaporador e o grau de superaquecimento. As funções custo $J_3(\theta)$ e $J_4(\theta)$ são as medidas de robustez, baseadas na variação total da ação de controle dos controladores PID $C_1(s)$ e $C_2(s)$, os valores das soluções ideal e indesejada para o cálculo do TOPSIS foram $J_{IS} = [0,0,0,0]$ e $J_{WS} = [3000,3000,3000,3000]$.

Dentre os algoritmos descritos, apenas o WDE e a COR foram capazes de obter os parâmetros dos controladores, de forma que estes fossem capazes de controlar o sistema, as soluções dos algoritmos DE, GA e GA-MPC resultaram em soluções infactíveis que divergiram para as condições de operação; sendo assim, as soluções obtidas são apresentadas e avaliadas.

4.3.1 Análise Qualitativa das Soluções Factíveis

Os controladores, segundo a estrutura descentralizada descrita, obtidos pela WDE são apresentados:

$$C_1(s) = -20,6037 - \frac{48,3598}{s} - 44.6074s \frac{47,2710}{s + 47,2710}$$
(85)

$$C_2(s) = 47,2710 + \frac{30,2194}{s} + 16,4584s \frac{16,0548}{s + 16,4257}.$$
 (86)

Os resultados das análises qualitativas para os controladores $C_1(s)$ e $C_2(s)$ WDE são apresentados nas Figs. 33 a 37. Nestas análises, as legendas "Controlador 1" e "Controlador 2" referem-se aos controlares de referência e ao otimizado pelo algoritmo WDE, respectivamente.

Pode-se analisar pela Fig. 33 (a), a temperatura do fluxo secundário do evaporador ($T_{e,sec,out}$) e, pela Fig. 33 (b) o grau de superaquecimento (T_{SH}), sendo estas as variáveis de saída do sistema de controle. Na Fig. 34 (a) é apresenta a variável manipulada da velocidade do compressor (N), que controla T_{SH} , e na Fig. 34

(b) a abertura da válvula de expansão (A_v) , variável controlada para controle de $T_{e,sec,out}$.

Figura 33 – Controlador de WDE: (a) temperatura do fluxo secundário do evaporador; (b) grau de superaquecimento.

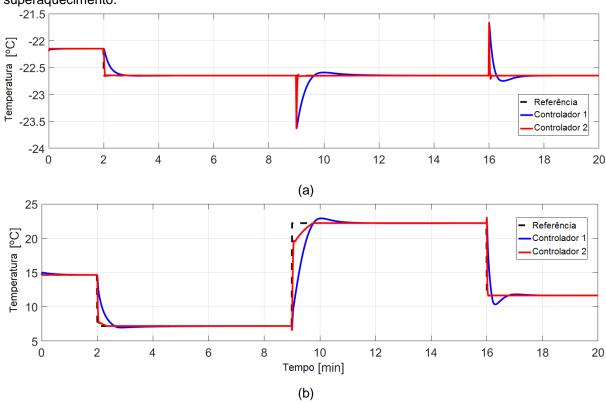
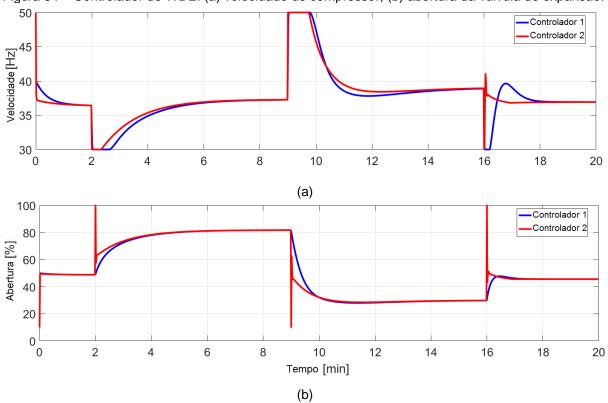


Figura 34 – Controlador de WDE: (a) velocidade do compressor; (b) abertura da válvula de expansão.



Na Fig. 35 (a – b) são apresentas a pressão no condensador e a pressão no evaporador, respectivamente. Na sequência, na Fig. 36 têm-se o desempenho térmico do sistema através da potência refrigerante no evaporador, Fig. 36 (a), e a potência térmica no condensador, Fig. 36 (c), a potência mecânica no compressor, Fig. 36 (b), e o fluxo mássico refrigerante, Fig. 36 (d), sendo este assumido na obtenção do coeficiente de desempenho (*COP*), apresentado na Fig. 37 (b) juntamente à eficiência do compressor durante o experimento, Fig. 37 (a).

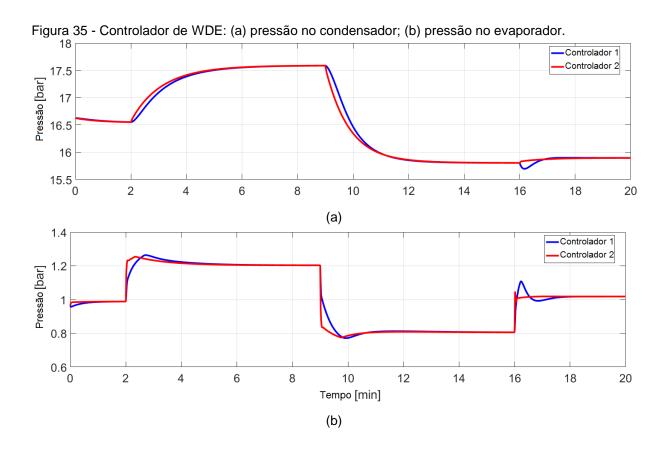
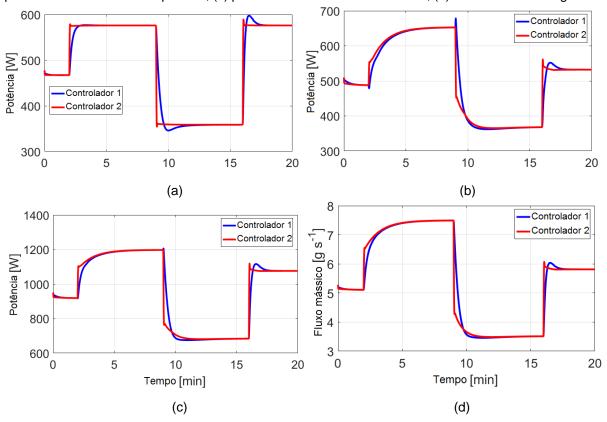
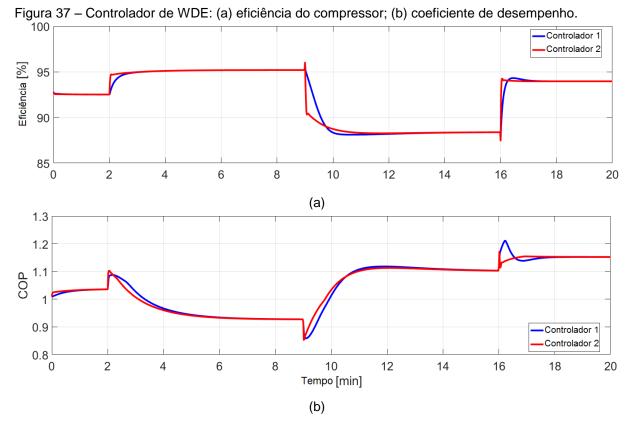


Figura 36 - Controlador de WDE desempenho térmico: (a) potência refrigerante no evaporador; (b) potência mecânica no compressor; (c) potência térmica no condensador; (d) fluxo mássico refrigerante.





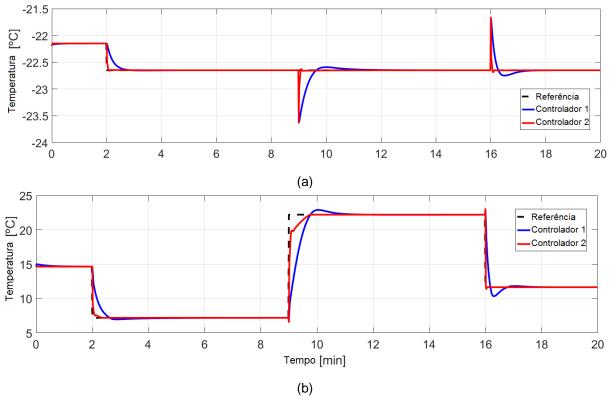
Os controladores, com estrutura descentralizada, obtidos pela COR são apresentados.

$$C_1(s) = -19,757 - \frac{47,422}{s} - 48,123s \frac{3,075}{s+3,075}$$
(87)

$$C_2(s) = 4{,}399 + \frac{45{,}544}{s} + 0{,}014s + \frac{3{,}507}{s + 3{,}507}$$
(88)

Os resultados das análises qualitativas são apresentados nas Fig. 38 a 42. Nestas análises, "Controlador 1" refere-se ao controlar de referência proposto no benchmark, e "Controlador 2" refere-se ao PID otimizado pela COR. Na Fig. 38 (a), a temperatura do fluxo secundário do evaporador ($T_{e,sec,out}$) é apresentada juntamente ao grau de superaquecimento (T_{SH}), Fig. 38 (b), sendo estas as variáveis de saída do sistema de controle.

Figura 38 – Controlador de COR: (a) temperatura do fluxo secundário do evaporador; (b) grau de superaquecimento.



A Fig. 39 (a) apresenta a variável manipulada da velocidade do compressor (N), que controla T_{SH} , a outra variável controlada é apresentada na Fig. 39 (b), sendo esta a abertura da válvula de expansão (A_v) que controla $T_{e,sec,out}$.

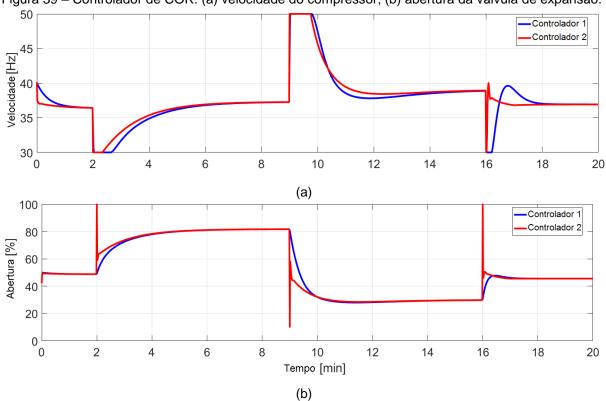


Figura 39 – Controlador de COR: (a) velocidade do compressor; (b) abertura da válvula de expansão.

A Fig. 40 (a) ilustra a pressão no condensador e a Fig. 40 (b) a pressão no evaporador. Adicionalmente, a Fig. 41(a – d) apresenta o desempenho térmico do sistema através da potência refrigerante no evaporador e a potência mecânica no compressor, apresentando também a potência térmica no condensador e o fluxo mássico refrigerante, respectivamente.

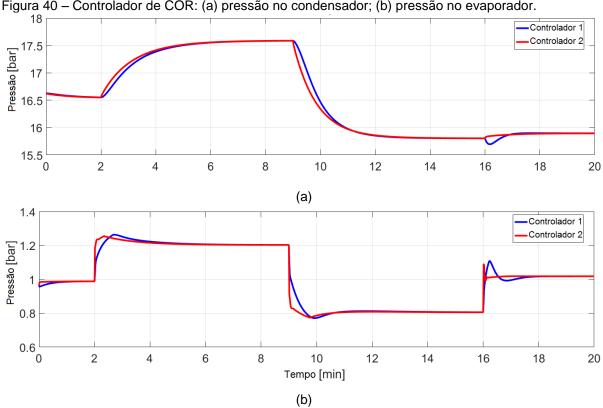
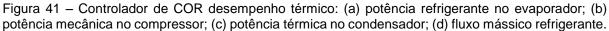
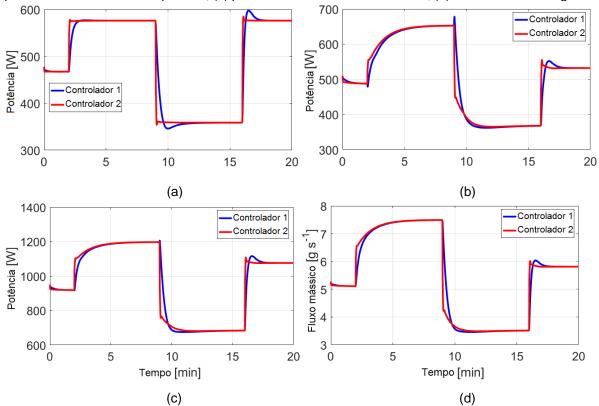


Figura 40 – Controlador de COR: (a) pressão no condensador; (b) pressão no evaporador.





A Fig. 42 (a) apresenta a eficiência do compressor durante o experimento, bem como o coeficiente de desempenho (*COP*) na Fig. 42 (b).

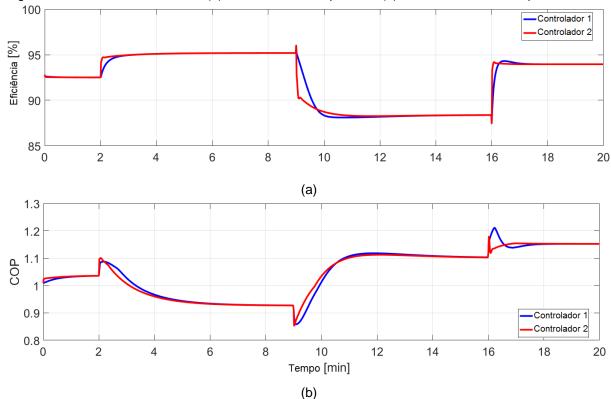


Figura 42 – Controlador de COR: (a) eficiência do compressor; (b) coeficiente de desempenho.

4.3.2 Análise Quantitativa de Índices Agregados

Para a análise quantitativa, os valores obtidos pelos índices de desempenho do *benchmark*, descritos em 3.1.3, estão sumarizados nas tabelas 21 e 22, para o controlador da WDE e para o controlador da COR, respectivamente.

Conforme o cálculo dos índices de desempenho que foram apresentados em 3.1.3, estes são relativos, calculados em função do controlador de referência, desta forma, valores abaixo de 1 (um), representam um melhor desempenho em relação ao critério, enquanto que valores superiores a 1 (um), representam desempenho pior em relação ao critério.

Desta forma, nota-se uma melhora significativa de ambos os controladores em relação aos critérios de erro, entretanto, para a solução obtida pela WDE, um maior esforço de controle é desempenhado pelos dois controladores, enquanto que, para a solução obtida pela COR, o esforço de controle realizado por $C_1(s)$ é

significativamente menor que o de $C_{1,ref}(s)$, com um incremento mínimo para $C_2(s)$ quando comparado a $C_{2,ref}(s)$.

Tabela 21 - Índices de desempenho WDE sistema de refrigeração

Índices de Desempenho	Valores Obtidos
$RIAE_1(C_{op}, C_{ref})$	0,1434
$RIAE_2(C_{op}, C_{ref})$	0,2452
$RITAE_1(C_{op}, C_{ref}, t_{c1}, t_{s1})$	0,3169
$RITAE_2(C_{op}, C_{ref}, t_{c2}, t_{s2})$	0,0254
$RITAE_2(C_{op}, C_{ref}, t_{c3}, t_{s3})$	0,1433
$RITAE_2(C_{op}, C_{ref}, t_{c4}, t_{s4})$	0,0040
$RIAVU_1(C_{op}, C_{ref})$	4,2071
$RIAVU_2(C_{op}, C_{ref})$	1,1918
$J_R(C_{op}, C_{ref})$	0,3413

Tabela 22 - Índices de desempenho COR sistema de refrigeração

Índices de Desempenho	Valores Obtidos
$RIAE_1(C_{op}, C_{ref})$	0,1411
$RIAE_2(C_{op}, C_{ref})$	0,2378
$RITAE_1(C_{op}, C_{ref}, t_{c1}, t_{s1})$	0,3237
$RITAE_2(C_{op}, C_{ref}, t_{c2}, t_{s2})$	0,0224
$RITAE_2(C_{op}, C_{ref}, t_{c3}, t_{s3})$	0,1397
$RITAE_2(C_{op}, C_{ref}, t_{c4}, t_{s4})$	0,0022
$RIAVU_1(C_{op}, C_{ref})$	0,37257
$RIAVU_2(C_{op}, C_{ref})$	1,0061
$J_R(C_{op}, C_{ref})$	0,3161

São apresentadas, na tabela 23, comparações com os valores dos índices agregados J_R obtidos pelas pesquisas realizadas sobre o *benchmark*, e mencionadas em 3.1.3, com soluções obtidas através dos diversos métodos de parametrização,

nota-se que a estratégia considerada obteve melhor desempenho para ambos os algoritmos que apresentaram soluções factíveis.

Tabela 23 - Índices agregados das soluções propostas para o sistema de refrigeração

Referência	Controle	Estratégia	Índice
Neierencia		Adotada	Agregado (J _R)
Soto et al. (2018)	PI / PI	MAGO	1,7472
Cajo <i>et al.</i> (2018)	PID / PID (com filtro)	IMC	0,8465
Cajo et al. (2018)	PID / PID	FRtool	0,6332
Reynoso-Meza et al.	PID/PI	Sp-MODEx	0,4028
(2018)	1 10/11	OP WODEX	0,4020
Bordignon e	PID / PID	VRFT	0,4134
Campestrini (2018)	1157115	VIXI	3,1101
Bordignon e	PID / PID / PID / PID	VRFT	0,3635
Campestrini (2018)		VIXI	0,000
Estratégia Proposta	PID / PID (com filtro)	WDE+TOPSIS	0,3413
Estratégia Proposta	PID / PID (com filtro)	COR+TOPSIS	0,3161

A solução apresentada por Bordignon e Campestrini (2018) assumiu uma estrutura de controle centralizada com plano *anti-windup*. Para o caso do método VRFT, o conjunto de dados de entrada e saída são obtidos considerando experimentos realizados diretamente sobre o processo, não considerando um modelo ou um processo de identificação do sistema, de forma que o controlador pode causar instabilidade no sistema devido a tais experimentos.

De outra forma, o método apresentado, é baseado em um modelo paramétrico, associado a uma estratégia de tomada de decisão para otimização através do algoritmo selecionado, permitindo que testes à exaustão sejam realizados, sem comprometer o funcionamento do sistema.

5 CONCLUSÕES

Tendo sido definidos os três benchmarks de controle a serem otimizados, estes relacionados a sistemas térmicos, sendo o primeiro referente a um sistema de regulação de temperatura de um aquecedor elétrico, o segundo a de um trocador de calor tipo casco e tubos e o terceiro a um sistema de refrigeração baseado em compressão de vapor, cada qual com dinâmicas únicas. Os dois primeiros, sistemas de uma entrada e uma (SISO) e o último com múltiplas entradas e múltiplas saídas (MIMO), pode-se verificar o comportamento de diversos algoritmos de otimização evolucionários para situações distintas.

Foram realizados testes de parametrização de controladores do tipo PID para um conjunto de cinco algoritmos evolucionários, a evolução diferencial (DE), a evolução diferencial ponderada (WDE), o algoritmo genético (GA), o algoritmo genético com *crossover* multi-precursores (GA-MPC) e a competição por recursos (COR).

Tendo sido considerados, para os dois primeiros *benchmark*s, 30 indivíduos para cada algoritmo, com limitação de 6000 avaliações da função custo, de tal forma, 251 experimentos foram realizados. A função custo definida para minimização baseou-se no método TOPSIS, sendo que os valores para as soluções ideal e indesejada foram mantidos fixas; para a solução ideal foram considerados os valores utópicos de erro e sinal de controle nulos, enquanto que para a solução indesejada foram definidos os valores de erro apresentado para uma solução divergente e seu correlato esforço de controle.

Tendo-se o método de auxílio à tomada de decisão TOPSIS sido definido como função agregadora, para a realização dos testes de desempenho quanto às métricas de comparação de controladores e dos critérios de sensibilidade e robustez, as soluções correlatas ao valor mediano do método TOPSIS, obtidos pelos diversos algoritmos, foram selecionadas.

Para o sistema aquecedor elétrico, a solução de controlador apresentada pelo algoritmo GA não obteve desempenho satisfatório, para o critério de robustez, sendo excluído do teste para o sistema trocador de calor, sendo ainda que o controlador da WDE apresentou todas as métricas de desempenho dominadas em relação aos controladores PID dos algoritmos DE, GA-MPC e COR; enquanto que a definição de

uma melhor solução dentre estes necessita de uma análise multicritério sobre os trade-offs apresentados por tais métricas.

Para o segundo *benchmark* o algoritmo WDE novamente apresentou uma solução dominada para todas as métricas de desempenho analisadas, não atendendo também o critério de robustez, considerado como fator excludente da solução, podese concluir então que, o algoritmo WDE não deve ser considerado como uma opção prioritária diante de problemas de otimização de controladores PID para sistemas térmicos SISO.

Quando comparados aos controladores de referência dos dois primeiros benchmarks, os controladores obtidos pelas quatro técnicas DE, WDE, GA-MPC e COR, apresentaram desempenho superior em todos os quesitos. De tal modo, podese afirmar que, com exceção dos algoritmos GA e WDE, os resultados obtidos pelos outros três algoritmos apresentam bons resultados e possíveis soluções para os casos de parametrização de controladores PID para sistemas SISO através da métrica de agregação das funções custo por um método de auxílio à tomada de decisão multicritério.

Quando avaliados quanto ao sistema de refrigeração MIMO, apenas os algoritmos COR e WDE convergiram para uma solução factível, apresentando ainda melhor desempenho em comparação, tanto para com o controlador de referência, quanto para com as abordagens apresentadas na terceira Conferência sobre Avanços em Controle Proporcional-Integral-Derivativo, ressalta-se que o método proposto, considerando algoritmos mono-objetivo, em contrapartida aos métodos apresentados na literatura, mostrou-se mais eficiente na parametrização dos controladores, eximindo a necessidade de avaliação das funções custo sobre a Fronteira de Pareto, esta apresentada por algoritmos multiobjetivo.

Dentre os trabalhos futuros relacionados a esta dissertação, ressalta-se o interesse sobre a análise de convergência de algoritmos mono-objetivo para a solução de problemas multiobjetivo pela agregação das funções custo a partir de outros métodos de auxílio à tomada de decisão multicritério. A extensão desta metodologia para outros tipos de sistemas, que não térmicos, também pode ser considerado como relevante para estudo.

REFERÊNCIAS

- ABRAMSON, D.; ABELA, J. A Parallel Genetic Algorithm for Solving the School Timetabling Problem. *Australian Computer Science Conference*, v. 15, p. 1–11, 1992.
- ALMEIDA, A. T. et al. Multicriteria and Multiobjective Models for Risk, Reliability and Maintenance Decision Analysis. [S.I: s.n.], 2015. v. 231. Disponível em: http://link.springer.com/10.1007/978-3-319-17969-8.
- ÅSTRÖM, K.; HÄGGLUND, T. Advanced PID Control. ISA Instrumentation, Systems, and Automation Societ, fev. 2006.
- ÅSTRÖM, K. J.; HÄGGLUND, T. The future of PID control. *Control Engineering Practice*, v. 9, n. 11, p. 1163–1175, 2001.
- BACCIOTTI, A. Control System Design. *Stability and Control of Linear Systems*. Cham, Switzerland: Springer Nature, 2019. p. 1–19. Disponível em: http://link.springer.com/10.1007/978-3-030-02405-5_1.
- BAI, Y.; ROTH, Z. S. *Classical and Modern Controls with Microcontrollers*. Cham: Springer International Publishing, 2019. Disponível em: http://link.springer.com/10.1007/978-3-030-01382-0. (Advances in Industrial Control).
- BAKER, B. M.; AYECHEW, M. A. A genetic algorithm for the vehicle routing problem. *Computers and Operations Research*, v. 30, n. 5, p. 787–800, 2003.
- BANSAL, J. C.; PAL, N. R. Swarm and Evolutionary Computation. *Evolutionary and Swarm Intelligence Algorithms*. [S.I.]: Springer, 2019. p. 1–9. Disponível em: http://link.springer.com/10.1007/978-3-319-91341-4_1.
- BEGON, M.; TOWNSEND, C. R.; HARPER, J. L. *Ecology: From Individuals to Ecosystems*. 4 Ed. 2006 ed. Malden: Blackwell Publishing, 1986.
- BEJARANO, G. *et al.* Benchmark for PID control of Refrigeration Systems based on Vapour Compression. *IFAC-PapersOnLine*, v. 51, n. 4, p. 497–502, 2018. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S2405896318304415.
- BINDU, R.; NAMBOOTHIRIPAD, M. K. Tuning of PID Controller for DC Servo Motor using Genetic Algorithm. *International Journal of Emerging Technology and Advanced Engineering*, v. 2, n. 3, p. 310–314, 2012. Disponível em: http://link.springer.com/10.1007/s00059-014-4196-9>.
- BORDIGNON, V.; CAMPESTRINI, L. Application of Multivariable Virtual Reference Feedback Tuning with Anti-Windup to the Benchmark PID 2018. *IFAC-PapersOnLine*,

- v. 51, n. 4, p. 515–520, 2018. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S240589631830507X.
- BOUCHEKARA, H. R. E. H.; NAHAS, M. Optimization of Magnetic Actuators Using Competition Over Resource Algorithm. 2017, [S.I: s.n.], 2017. p. 584–588.
- CAJO, R. et al. IMC based PID Control Applied to the Benchmark PID18. *IFAC-PapersOnLine*, v. 51, n. 4, p. 728–732, 2018. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S240589631830507X>.
- CAMPI, M. C.; LECCHINI, A. Virtual reference feedback tuning: a direct method for the design of feedback controllers. *Automatica*, v. 38, n. 8, p. 1337–1346, 2002. Disponível em:
- http://linkinghub.elsevier.com/retrieve/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/science/article/pii/S0005109802000328%5Cnhttp://www.sciencedirect.com/scienced
- CASTRUCCI, P. DE L.; BITTAR, A.; SALES, R. M. Controle Automático. Rio de Janeiro: LTC, 2011.
- CHIDAMBARAM, M.; SAXENA, N. *Relay Tuning of PID Controllers*. Singapore: Springer Singapore, 2018. Disponível em: http://link.springer.com/10.1007/978-981-10-7727-2. (Advances in Industrial Control).
- CHIEN, K. L.; HRONS, J. A.; RESWICK, J. B. On the Automatic Control of Generalized Passive Systems. *Transactions of the American Society of Mechanical Engineeing ASME*, v. 74, p. 175–185, 1952.
- CIC. Concurso en Ingeniería de Control 2018: Control de un sistema de refrigeración. Disponível em: http://www.dia.uned.es/~fmorilla/CIC2018/.
- CIVICIOGLU, P. et al. Weighted differential evolution algorithm for numerical function optimization: a comparative study with cuckoo search, artificial bee colony, adaptive differential evolution, and backtracking search optimization algorithms. *Neural Computing and Applications*, v. 5, 26 out. 2018. Disponível em: https://doi.org/10.1007/s00521-018-3822-5.
- COELLO, C. C. A.; LAMONT, G. B.; VELDHUIZEN, D. A. VAN. *Evolutionary Algorithms for Solving Multi-Objective Problems*. Boston, MA: Springer US, 2007. v. 139. Disponível em: http://link.springer.com/10.1007/978-0-387-36797-2. (Genetic and Evolutionary Computation Series).
- COHEN, G. H.; COON, G. A. Theoretical Consideration of Retarded Control. *Transactions of the American Society of Mechanical Engineeing ASME*, v. 75, p. 827–834, 1953.
- CUEVAS, E.; OSUNA, V.; OLIVA, D. *Evolutionary computation techniques: a comparative perspective*. [S.I.]: Springer Nature, 2017. Disponível em: .
- CUSTÓDIO, A. L. et al. Direct Multisearch for Multiobjective Optimization. SIAM

- Journal on Optimization, v. 21, n. 3, p. 1109–1140, 2011. Disponível em: http://epubs.siam.org/doi/10.1137/10079731X.
- DARWIN, C. On The Origin of Species. London: John Murray, Albemarle Street, 1859.
- DAS, I.; DENNIS, J. Normal-Boundary Intersection: an Alternate Method for Generating Pareto Optimal Points in Multicriteria Optimization. *Nasa Contractor Report* 201616 (ICASE), n. 96, p. 1–35, 1996.
- DE CASTRO, L. N.; TIMMIS, J. Artificial Immune Systems: A Novel Paradigm to Pattern Recognition. *Artificial Neural networks in pattern Recognition*, p. 67–84, 2002.
- DEB, K. Multi-objective Genetic Algorithms: Problem Difficulties and Construction of Test Problems. *Evolutionary Computation*, v. 7, n. 1995, p. 205–230, 1998.
- DEB, K.; MYBURGH, C. Breaking the Billion-Variable Barrier in Real-World Optimization Using a Customized Evolutionary Algorithm. p. 653–660, 2016.
- DESBOROUGH, L.; MILLER, R. Increasing Customer Value of Industrial Control Performance Monitoring Honeywell's Experience. *Honeywell Hi-Spec Solutions*, p. 153–186, 2011.
- DONG, N.; HAN, X. Model-free controller design for advanced energy-saving control of the refrigeration system. jul. 2016, [S.I.]: IEEE, jul. 2016. p. 3224–3228. Disponível em: http://ieeexplore.ieee.org/document/7553854/.
- DORIGO, M.; STÜTZLE, T. *Ant Colony Optimization*. Massachusetts: The MIT Press, 2004.
- DURAN, O.; RODRIGUEZ, N.; CONSALTER, L. A. Neural networks for cost estimation of shell and tube heat exchangers. 2008, Hong Kong: [s.n.], 2008.
- ELSAYED, S. M.; SARKER, R. A.; ESSAM, D. L. GA with a new multi-parent crossover for constrained optimization. 2011 IEEE Congress of Evolutionary Computation, CEC 2011, p. 857–864, 2011a.
- ELSAYED, S. M.; SARKER, R. A.; ESSAM, D. L. GA with a new multi-parent crossover for solving IEEE-CEC2011 competition problems. *2011 IEEE Congress of Evolutionary Computation*, *CEC 2011*, p. 1034–1040, 2011b.
- FARIAS, M. S. R. Algoritmos evolucionários aplicados ao problema do caixeiro viajante multiobjetivo. Maceió: Universidade Federal de Alagoas, 2008.
- FOGEL, L.; OWENS, A. J.; WALSH, M. J. *Artificial Intelligence through Simulated Evolution*. New York: Wiley, 1966.
- FRASER, A. S. Simulation of Genetic Systems by Automatic Digital Computers I. Introduction. *Australian Journal of Biological Sciences*, v. 10, n. 4, p. 484, 1957. Disponível em: http://www.publish.csiro.au/?paper=BI9570484.
- FRIEDBERG, R. M. A Learning Machine: Part I. *IBM Journal of Research and Development*, v. 2, n. 1, p. 2–13, jan. 1958. Disponível em:

- http://ieeexplore.ieee.org/document/5392654/>.
- FRIEDBERG, R. M.; DUNHAM, B.; NORTH, J. H. A Learning Machine: Part II. *IBM Journal of Research and Development*, v. 3, n. 3, p. 282–287, jul. 1959. Disponível em: http://ieeexplore.ieee.org/document/5392654/>.
- GARCIA, C. E.; MORARI, M. Internal model control. A unifying review and some new results. *Industrial & Engineering Chemistry Process Design and Development*, v. 21, n. 2, p. 308–323, abr. 1982. Disponível em: http://pubs.acs.org/doi/abs/10.1021/i200017a016.
- GEILEN, M. et al. An Algebra of Pareto Points. Fundamenta Informaticae The Fourth Special Issue on Applications of Concurrency to System Design, v. 78, n. 1, p. 35–74, 2007. Disponível em: http://iospress.metapress.com/content/e22q8630846272g7/%5Cnhttp://www.es.ele.tue.nl/pareto/.
- GLOVER, F.; LAGUNA, M. Tabu Search. *ORSA Journal on Computing*, v. 1, n. 3, p. 190–206, ago. 1989. Disponível em: http://pubsonline.informs.org/doi/abs/10.1287/ijoc.2.1.4.
- GOLDBERG, D. E. Genetic Algorithms in Search, Optimization, and Machine Learning. 2. ed. [S.I.]: Addison-Wesley, 1989. Disponível em: http://jama.jamanetwork.com/article.aspx?doi=10.1001/jama.1992.0349022006302 9>.
- GUO, C.; SONG, Q.; CAI, W. A neural network assisted cascade control system for air handling unit. *IEEE Transactions on Industrial Electronics*, v. 54, n. 1, p. 620–628, 2007.
- HERNÁNDEZ, J. A.; OSPINA, J. D. A multi dynamics algorithm for global optimization. *Mathematical and Computer Modelling*, v. 52, n. 7–8, p. 1271–1278, 2010. Disponível em: http://dx.doi.org/10.1016/j.mcm.2010.03.024.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. [S.I.]: The University of Michigan Press, 1975.
- HUGO, A. J. Process controller performance Monitoring and Assessment. *Control Arts Inc.*, 2001.
- HWANG, C.-L.; YOON, K. Methods for Multiple Attribute Decision Making. *Lecture Notes in Economics and Mathematical Systems*. [S.I.]: Springer, 1981. p. 58–191. Disponível em: http://link.springer.com/10.1007/978-3-642-48318-9_3.
- JIMÉNEZ, T. *et al.* An auto-tuning PID control system based on genetic algorithms to provide delay guarantees in Passive Optical Networks. *Expert Systems with Applications*, v. 42, n. 23, p. 9211–9220, dez. 2015. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S0957417415005424.
- JUANG, C. F. et al. Ant colony optimization algorithm for fuzzy controller design and its FPGA implementation. *IEEE Transactions on Industrial Electronics*, v. 55, n. 3, p. 1453–1462, 2008.

- KALISZEWSKI, I.; MIROFORIDIS, J.; PODKOPAEV, D. *Multiple Criteria Decision Making by Multiobjective Optimization*. Cham: Springer International Publishing, 2016. v. 242. Disponível em: http://link.springer.com/10.1007/978-3-319-32756-3. (International Series in Operations Research & Management Science).
- KARABOGA, D. et al. A comprehensive survey: Artificial bee colony (ABC) algorithm and applications. Artificial Intelligence Review, v. 42, n. 1, p. 21–57, 2014.
- KAVITHA, G. Masking Operator Based Genetic Algorithm Optimization for Edge Detection in Images. *Intelligent Automation Cybernetics and Systems in Control Theory*. [S.I.]: Springer Nature, 2019. p. 34–43. Disponível em: http://link.springer.com/10.1007/978-3-030-00184-1_4.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. dez. 1995, [S.I.]: IEEE, dez. 1995. p. 1942–1948. Disponível em: http://ieeexplore.ieee.org/document/488968/>.
- KHALORE, A. G. Relay Approach for tuning of PID controller. *Int.J.Computer Technology & Applications*, v. 3, n. 3, p. 1237–1242, 2012.
- KHAN, M. A. S. K.; RAHMAN, M. A. Implementation of a wavelet-based MRPID controller for benchmark thermal system. *IEEE Transactions on Industrial Electronics*, v. 57, n. 12, p. 4160–4169, 2010.
- KNOWLES, J.; CORNE, D.; DEB, K. *Multiobjective Problem Solving from Nature: From Convepts to Applications*. Pondicherry: Springer, 2008.
- KOZA, J. R. Genetic Programming: On the Programming of Computers by Means of Natural Selection. Cambridge: The MIT Press, 1992.
- LAI, Y.-J.; LIU, T.-Y.; HWANG, C.-L. Theory and Methodology TOPSIS for MODM. *European Journal of Operational Research*, v. 76, p. 486–500, 1994.
- LIANG, J. J. et al. Problem Definitions and Evaluation Criteria for the CEC 2006 Special Session on Constrained Real-Parameter Optimization. . Singapore: [s.n.]. , 2013
- LIANGHONG, W. et al. Design of PID controller with incomplete derivation based on differential evolution algorithm. *Journal of Systems Engineering and Electronics*, v. 19, n. 3, p. 578–583, 2008.
- LUYBEN, M. L.; LUYBEN, W. L. Essentials of Process Control. [S.I.]: McGraw-Hill, 1997.
- MALHOTRA, R.; SINGH, N.; SINGH, Y. Genetic Algorithms: Concepts, Design for Optimization of Process Controllers. *Computer and Information Science*, v. 4, n. 2, p. 39–54, 2011.
- MARLIN, T. Process Control: Designing Processes and Control Systems for Dynamic Performance. 2nd (2000) ed. [S.I.]: McGraw-Hill, 1992.
- MATTSON, C. A.; MESSAC, A. Pareto Frontier Based Concept Selection Under Uncertainty, with Visualization. *Optimization and Engineering*, v. 6, n. 1, p. 85–115,

mar. 2005. Disponível em: http://link.springer.com/10.1023/B:OPTE.0000048538.35456.45.

MAXWELL, J. C. On Governors. *Proc. R. Soc. London*, v. 16, p. 270–283, 1868.

MENDES, L. A. *et al.* Minimizing computational cost and energy demand of building lighting systems: A real time experiment using a modified competition over resources algorithm. *Energy and Buildings*, v. 139, p. 108–123, 2017. Disponível em: http://dx.doi.org/10.1016/j.enbuild.2016.12.072.

MESSAC, A.; ISMAIL-YAHAYA, A.; MATTSON, C. A. The normalized normal constraint method for generating the Pareto frontier. *Structural and Multidisciplinary Optimization*, v. 25, n. 2, p. 86–98, 2003.

MESSAC, A.; MATTSON, C. A. Generating well-distributed sets of pareto points for engineering design using physical programming. *Optimization and Engineering*, v. 3, n. 4, p. 431–450, 2002.

MIETTINEN, K. *Nonlinear Multiobjective Optimization*. Boston, MA: Springer US, 1998. v. 12. Disponível em: https://www.springer.com/la/book/9780792382782. (International Series in Operations Research & Management Science).

MOHANTY, B.; PANDA, S.; HOTA, P. K. Controller parameters tuning of differential evolution algorithm and its application to load frequency control of multi-source power system. *International Journal of Electrical Power and Energy Systems*, v. 54, p. 77–85, 2014. Disponível em: http://dx.doi.org/10.1016/j.ijepes.2013.06.029.

MOHSENI, S. et al. Competition over resources: A new optimization algorithm based on animals behavioral ecology. *Proceedings - 2014 International Conference on Intelligent Networking and Collaborative Systems, IEEE INCoS 2014*, p. 311–315, 2014.

MORARI, M.; ZAFIRIOU, E. *Robust process control*. Englewood Cliffs: Prentice-Hall, 1989.

NELDER, J. A.; MEAD, R. A Simplex Method for Function Minimization. *The Computer Journal*, v. 7, n. 4, p. 308–313, 1965. Disponível em: https://academic.oup.com/comjnl/article-lookup/doi/10.1093/comjnl/7.4.308.

NISE, N. S. Engenharia de Sistemas de Controle. 6. ed. Rio de Janeiro: LTC, 2014.

OGATA, K. Modern Control Engineering. 5. ed. [S.I.]: Pearson, 2010.

PADHEE, S.; KHARE, Y. B.; SINGH, Y. Internal model based PID control of shell and tube heat exchanger system. *TechSym2011 - Proceedings of the 2011 IEEE Students' Technology Symposium*, n. February, p. 297–302, 2011.

PALIT, A. K.; POPOVIC, D. *Computational Intelligence in Time Series Forecasting*. London: Springer-Verlag, 2005. Disponível em: http://www.amazon.com/Advances-PID-Control-

Industrial/dp/1447112199%3FSubscriptionId%3D0JYN1NVW651KCA56C102%26tag%3Dtechkie-

- 20%26linkCode%3Dxm2%26camp%3D2025%26creative%3D165953%26creativeAS IN%3D1447112199>.
- PARETO, V. Cours d'économie politique. [S.I.]: Librairie Droz, 1964. v. 9. Disponível em: http://journals.sagepub.com/doi/10.1177/000271629700900314.
- PARZEN, E. On the Estimation of Probability Density and Mode. *Annals of Mathematical Statistics*, v. 27, p. 1065–1076, 1962.
- PATIL, S.; BHENDE, M. Comparison and Analysis of Different Mutation Strategies to improve the Performance of Genetic Algorithm. *International Journal of Computer Science and Information Technologies*, v. 5, n. 3, p. 4669–4673, 2014. Disponível em: <www.ijcsit.com>.
- PEDRO, J. O.; DANGOR, M.; KALA, P. J. Differential evolution-based PID control of a quadrotor system for hovering application. *2016 IEEE Congress on Evolutionary Computation, CEC 2016*, p. 2791–2798, 2016.
- PIOTROWSKI, A. P. Review of Differential Evolution population size. *Swarm and Evolutionary Computation*, v. 32, p. 1–24, 2017. Disponível em: http://dx.doi.org/10.1016/j.swevo.2016.05.003>.
- RASMUSSEN, H. Automatic Tuning of PID-regulators. *Aalborg University, Dept. of Control Engineering*, n. U93-4019, p. 1–21, 2002. Disponível em: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.114.1331%7B&%7Damp;type=pdf.
- RECHENBERG, I. Evolutionsstrategie: Optimierung Technischer Systeme nach Prinzipien der biologischen Evolution. Stuttgart: Frommann-Holzboog, 1973.
- REYNOSO-MEZA, G. Controller Tuning by Means of Evolutionary Multiobjective Optimization: a Holistic Multiobjective Optimization Design Procedure. 2014. Universitat Politècnica de València, Valencia (Spain), 2014.
- REYNOSO-MEZA, G.; BLASCO, X.; *et al.* Controller tuning using evolutionary multiobjective optimisation: Current trends and applications. *Control Engineering Practice*, v. 28, n. 1, p. 58–63, 2014. Disponível em: http://dx.doi.org/10.1016/j.conengprac.2014.03.003>.
- REYNOSO-MEZA, G. et al. Controller Tuning with Evolutionary Multiobjective Optimization. Cham: Springer International Publishing, 2017. v. 85. Disponível em: http://link.springer.com/10.1007/978-3-319-41301-3. (Intelligent Systems, Control and Automation: Science and Engineering).
- REYNOSO-MEZA, G. *et al.* Evolutionary multi-objective optimisation with preferences for multivariable PI controller tuning. *Expert Systems with Applications*, v. 51, p. 120–133, 2016. Disponível em: http://dx.doi.org/10.1016/j.eswa.2015.11.028>.
- REYNOSO-MEZA, G.; SÁNCHEZ, H. S.; et al. Reliability based multiobjective optimization design procedure for PI controller tuning. *IFAC Proceedings Volumes (IFAC-PapersOnline)*, v. 19, p. 10263–10268, 2014.

- REYNOSO-MEZA, G.; SÁNCHEZ, H. S.; ALVES RIBEIRO, V. H. Control of Refrigeration Systems based on Vapour Compression using Multi-objective Optimization Techniques. *IFAC-PapersOnLine*, v. 51, n. 4, p. 722–727, 2018.
- RIBEIRO, J. M. S. *et al.* Comparison of PID controller tuning methods: analytical/classical techniques versus optimization algorithms. maio 2017, [S.I.]: IEEE, maio 2017. p. 533–538. Disponível em: http://ieeexplore.ieee.org/document/7970458/>.
- SABZI, H. Z. et al. Optimization of adaptive fuzzy logic controller using novel combined evolutionary algorithms, and its application in Diez Lagos flood controlling system, Southern New Mexico. Expert Systems with Applications, v. 43, p. 154–164, jan. 2016. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S0957417415006004.
- SARABIA, D. et al. Hybrid NMPC of supermarket display cases. Control Engineering Practice, v. 17, n. 4, p. 428–441, 2009.
- SAWARAGI, Y.; NAKAYAMA, H.; TANINO, T. *Theory of Multiobjective Optimization*. London: Academic Press, 1985.
- SEN, R. *et al.* Comparison Between Three Tuning Methods of PID Control for High Precision Positioning Stage. *MAPAN Journal of Metrology Society of India*, v. 30, n. 1, p. 65–70, 26 mar. 2015. Disponível em: http://link.springer.com/10.1007/s12647-014-0123-z.
- SHAHROKHI, M.; ZOMORRODI, A. A Comparison of PID Controller Tuning Methods. *The Canadian Journal of Chemical Engineering*, v. 83, n. 4, p. 712–722, 2010.
- SIDDIQUE, N. Control Systems. *Intelligent Control*. Switzerland: Springer, 2014. p. 39–55. Disponível em: http://link.springer.com/10.1007/978-3-319-02135-5_3.
- SONI, N.; KUMAR, T. Study of Various Mutation Operators in Genetic Algorithms. *International Journal of Computer Science and Information Technologies*, v. 5, n. 3, p. 4519–4521, 2014.
- SOTO, G. J. A.; LÓPEZ, J. M. G.; HERNÁNDEZ-RIVEROS, J. A. Coupled evolutionary tuning of PID Controllers for the Benchmark on Vapor Compression Refrigeration. *IFAC-PapersOnLine*, v. 51, n. 4, p. 509–514, 2018.
- SRINIVAS, M.; PATNAIK, L. M. Genetic Algorithms: A Survey. *COMPUTER*, v. 27, n. 6, p. 17–26, 1994.
- STARR, K. D.; PETERSEN, H.; BAUER, M. Control loop performance monitoring ABB's experience over two decades. *IFAC-PapersOnLine*, v. 49, n. 7, p. 526–532, 2016. Disponível em: http://dx.doi.org/10.1016/j.ifacol.2016.07.396.
- STORN, R.; PRICE, K. Differential Evolution A simple and efficient adaptive scheme for global optimization over continuous spaces. *Dr. Dobb's journal*, v. 22, n. 4, p. 18–24, 1997a.
- STORN, R.; PRICE, K. Differential Evolution A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization*, v. 11, n.

- 4, p. 341–359, 1997b.
- SWANN, G. D.; KAMALASADAN, S. An approach for temperature and frequency control of a crystal oscillator. *IECON Proceedings (Industrial Electronics Conference)*, p. 2976–2981, 2008.
- TAN, W. et al. Comparison of some well-known PID tuning formulas. *Computers and Chemical Engineering*, v. 30, n. 9, p. 1416–1423, 2006.
- TZENG, G.-H.; HUANG, J.-J. Multiple Attribute Decision Making Methods and applications. Boca Raton: CRC Press, 2011. v. 1.
- WANG, G. G.; SHAN, S. An Efficient Pareto Set Identification Approach for Multi-Objective Optimization on Black-Box Functions. *Journal of Mechanical Design*, v. 127, p. 866–874, 2005. Disponível em: http://proceedings.asmedigitalcollection.asme.org/proceeding.aspx?articleid=1651216.
- YANO, H. Interactive Multi-Objective Decision Making Under Uncertainty. [S.I: s.n.], 2017.
- YOUNEY, J. A Comparison And Evaluation of common Pid Tuning Methods. 2007. 86 f. University of Central Florida, 2007.
- ZAVADSKAS, E. K. *et al.* Development of TOPSIS method to solve complicated decision-making problems: An overview on developments from 2000 to 2015. *International Journal of Information Technology & Decision Making*, v. 15, n. 03, p. S0219622016500176, 4 abr. 2016. Disponível em: http://www.worldscientific.com/doi/abs/10.1142/S0219622016300019>.
- ZIEGLER, J. G.; NICHOLS, N. B. Optimum Settings for Automatic Controllers. *TRANSACTIONS OF THE A.S.M.E.*, p. 759–765, 1942. Disponível em: http://dynamicsystems.asmedigitalcollection.asme.org/article.aspx?articleid=140623 1>.
- ZIELINSKI, K.; LAUR, R. Constrained Single-Objective Optimization Using Differential Evolution. 2006 IEEE International Conference on Evolutionary Computation, p. 223–230, 2006.