

**INSTITUTO FEDERAL DO ESPÍRITO SANTO  
CURSO DE ENGENHARIA MECÂNICA**

**GUSTAVO RIGAMONTE GASPERAZZO**

**APLICAÇÃO DO ALGORITMO DE OTIMIZAÇÃO DE LOBOS CINZENTOS PARA  
PROJETO DE PLANTAS DE COGERAÇÃO.  
ESTUDO DE CASO: PROBLEMA CGAM.**

Vitória  
2020

GUSTAVO RIGAMONTE GASPERAZZO

**APLICAÇÃO DO ALGORITMO DE OTIMIZAÇÃO DE LOBOS CINZENTOS PARA  
PROJETO DE PLANTAS DE COGERAÇÃO.  
ESTUDO DE CASO: PROBLEMA CGAM.**

Monografia apresentada à Coordenadoria do Curso de Engenharia Mecânica do Instituto Federal do Espírito Santo, Campus Vitória, como requisito parcial para a obtenção do título de Bacharel em Engenharia Mecânica.

Orientador: Prof. Dr. Leonardo Rodrigues de Araújo.

Coorientador: Prof. Me. Rodrigo Guedes dos Santos.

Vitória

2020

Dados Internacionais de Catalogação-na-Publicação (CIP)  
(Biblioteca Nilo Peçanha do Instituto Federal do Espírito Santo)

G249a Gasperazzo, Gustavo Rigamonte.  
Aplicação do algoritmo de otimização de lobos cinzentos para projeto de plantas de cogeração : estudo de caso : Problema CGAM / Gustavo Rigamonte Gasperazzo. – 2020.  
80 f. : il. ; 30 cm

Orientador: Leonardo Rodrigues de Araújo.  
Coorientador: Rodrigo Guedes dos Santos.

Monografia (graduação) – Instituto Federal do Espírito Santo, Coordenadoria do Curso de Engenharia Mecânica do Curso Superior em Engenharia Mecânica, Vitória, 2020.

1. Engenharia mecânica. 2. Termodinâmica. 3. Energia elétrica e calor – Cogeração. 4. Mecânica. I. Araújo, Leonardo Rodrigues de. II. Santos, Rodrigo Guedes dos. III. Instituto Federal do Espírito Santo. IV. Título.

CDD 22 – 620.1

Elaborada por Marcileia Seibert de Barcellos – CRB-6/ES - 656

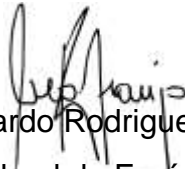
**GUSTAVO RIGAMONTE GASPERAZZO**

**APLICAÇÃO DO ALGORITMO DE OTIMIZAÇÃO DE LOBOS CINZENTOS PARA  
PROJETO DE PLANTAS DE COGERAÇÃO.  
ESTUDO DE CASO: PROBLEMA CGAM.**

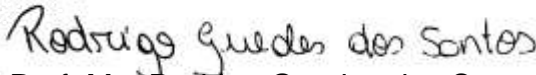
Monografia apresentada à Coordenadoria do Curso de Engenharia Mecânica do Instituto Federal do Espírito Santo, Campus Vitória, como requisito parcial para a obtenção do título de Bacharel em Engenharia Mecânica.

Aprovado em 11 de setembro de 2020.

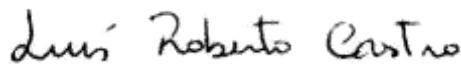
**COMISSÃO EXAMINADORA**



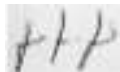
Prof. Dr. Leonardo Rodrigues de Araújo  
Instituto Federal do Espírito Santo  
Orientador



Prof. Me. Rodrigo Guedes dos Santos  
Instituto Federal do Espírito Santo  
Coorientador



Prof. Dr. Luis Roberto Castro  
Instituto Federal do Espírito Santo



Prof. Dr. João Luiz Marcon Donatelli  
Universidade Federal do Espírito Santo



Prof. Dr. Helder Roberto de Oliveira Rocha  
Universidade Federal do Espírito Santo

A Deus e aos meus pais José Augusto Gasperazzo e Eliane Dettmann Rigamonte Gasperazzo, que apesar de tantas dificuldades acreditaram em mim e investiram tudo em minha educação.

## **AGRADECIMENTOS**

Ao meu irmão Eduardo Rigamonte Gasperazzo, por ter sido fonte primária de inspiração ao longo de todos esses anos e pelos seus conselhos profissionais e pessoais.

À minha namorada Mariana Rocha Bello, por me apoiar sempre e por me compreender nos momentos em que tive que trocá-la por uma chamada de vídeo para orientação.

Ao meu professor orientador Dr. Leonardo Rodrigues de Araújo, pela orientação incisiva, presente e segura e pela maneira como acreditou no meu potencial.

Ao meu professor coorientador Me. Rodrigo Guedes dos Santos, pelas discussões e sugestões que contribuíram para o enriquecimento deste trabalho.

Ao professor Dr. Helder Roberto de Oliveira Rocha (UFES), pela ajuda na elaboração e aplicação do método de otimização de lobos cinzentos.

Ao meu amigo e colega de curso João Lucas Brum Orecchio, pela ajuda, parceria e respeito mútuo que mantivemos ao longo de todo o curso, assim como neste trabalho.

Ao Instituto Federal do Espírito Santo (IFES) e aos seus professores de maneira geral, que apesar de enfrentarem tantos desafios e turbulências puderam contribuir grandemente para a minha formação.

A todos os amigos que, de uma forma ou de outra, contribuíram para a realização deste trabalho e que porventura não estão aqui citados.

## RESUMO

A escassez de recursos naturais fósseis, o aumento da demanda energética mundial e a crescente ocorrência de problemas ambientais tornam necessário o desenvolvimento de procedimentos computacionais para projetos de sistemas térmicos cada vez mais eficientes, tanto do ponto de vista energético quanto econômico. Desta forma, a otimização termoeconômica surge como uma alternativa promissora para projetos de sistemas térmicos mais eficientes. Diante deste contexto, este trabalho tem como objetivo principal o desenvolvimento de um procedimento de otimização que utiliza *software* comercial e o algoritmo de lobos cinzentos (GWO) para projeto de plantas de cogeração. Para esse fim, é selecionada de uma literatura de referência uma planta de cogeração como estudo de caso (Problema CGAM) e após a modelagem termodinâmica e econômica deste sistema, uma função objetivo é proposta com base na taxa de custo total anual. A modelagem termodinâmica, modelagem econômica, assim como a formulação do problema de otimização para o estudo de caso são realizadas no *software* comercial EES, o qual possui uma ferramenta de otimização que inclui o método do algoritmo genético. O algoritmo de lobos cinzentos proposto neste trabalho é implementado no *software* MATLAB e acoplado ao *software* EES para otimização da planta de cogeração. Os resultados mostram que tanto o algoritmo genético (AG) do EES quanto o algoritmo de lobos cinzentos (GWO) mostram-se eficientes para a otimização da planta de cogeração, visto que ambos alcançam resultados similares a literatura de referência. Apesar do alto custo computacional o GWO mostra-se mais eficiente do que o AG para a solução do problema proposto, já que durante o procedimento de otimização o GWO possui menor valor do número de chamadas de função objetivo. Desta forma, o procedimento proposto neste trabalho pode ser aplicado para otimização de sistemas térmicos tanto do ponto de vista prático como acadêmico.

**Palavras-chave:** Plantas de cogeração. *Software* comercial. Otimização termoeconômica. Algoritmo de lobos cinzentos.

## ABSTRACT

The scarcity of fossil natural resources, the increase in global energy demand and occurrence of environmental problems make it necessary to develop computational procedures for increasingly efficient thermal system designs, both from an energy and an economic point of view. Thus, the thermoeconomic optimization shows as a promising alternative for more efficient thermal system designs. In this context, this work has as main objective the development of an optimization procedure that uses commercial software and the gray wolf algorithm (GWO) for cogeneration power plants designs. For this purpose, a cogeneration power plant is selected from the reference literature as a case study (CGAM problem) and after the thermodynamic and economic modelling of this system, an objective function is proposed based on the annual total cost rate. Thermodynamic modelling, economic modeling, as well as the formulation of the optimization problem for the case study are carried out in the commercial *software* EES, which has an optimization tool that includes the genetic algorithm method. The gray wolf algorithm proposed in this work is implemented in the MATLAB software, and it is coupled to the *software* EES to optimize the cogeneration power plant. The results show that both algorithms, the genetic (EES) and the gray wolf (MATLAB), are efficient for the optimization of the cogeneration plant, since both achieve results similar to the reference literature. Despite the high computational cost, the GWO proves to be more effective than the AG for the solution of the proposed problem, since during the optimization procedure the GWO has less value in the number of objective function calls. Thus, the procedure proposed in this work can be applied to optimize thermal systems both from a practical and academic point of view.

**Keywords:** Cogeneration power plants. Commercial software. Thermoeconomic optimization. Gray wolf algorithm.



## LISTA DE ILUSTRAÇÕES

Figura 1 - Faixa típica de temperatura para planta de cogeração do tipo <i>topping</i> .....	24
Figura 2 - Faixa típica de temperatura para planta de cogeração do tipo <i>bottoming</i> .	24
Figura 3 - Custo do ciclo de vida de plantas de cogeração. ....	26
Figura 4 - Estrutura física da planta de cogeração do Problema CGAM. ....	29
Figura 5 - Fluxograma do pseudocódigo do algoritmo genético. ....	31
Figura 6 - Comportamento de caça dos lobos cinzentos. ....	33
Figura 7 - Fluxograma do pseudocódigo do algoritmo de lobos cinzentos. ....	34
Figura 8 - Seleção de parâmetros do algoritmo genético do EES. ....	41
Figura 9 - Fluxograma do procedimento de otimização do algoritmo genético do EES. .....	41
Figura 10 - Gráfico função objetivo versus número de chamadas desta função para a primeira otimização do AG do EES. ....	53
Figura 11 - Gráfico função objetivo versus número de chamadas desta função para a segunda otimização do AG do EES. ....	53
Figura 12 - Gráfico função objetivo versus número de chamadas desta função para a terceira otimização do AG do EES. ....	53
Figura 13 - Gráfico função objetivo versus número de chamadas desta função para a quarta otimização do AG do EES. ....	54
Figura 14 - Gráfico função objetivo versus número de chamadas desta função para a quinta otimização do AG do EES. ....	54
Figura 15 - Gráfico função objetivo versus número de chamadas desta função para a sexta otimização do AG do EES. ....	54
Figura 16 - Gráfico função objetivo versus número de chamadas desta função para a sétima otimização do AG do EES. ....	55
Figura 17 - Fluxograma de instruções da macro de integração entre o EES e o MATLAB. ....	58
Figura 18 - Macro desenvolvida para a integração do EES com o MATLAB. ....	58
Figura 19 – Gráfico função objetivo versus número de chamadas desta função para a primeira otimização do GWO. ....	59
Figura 20 – Gráfico função objetivo versus número de chamadas desta função para a segunda otimização do GWO. ....	60

Figura 21 – Gráfico função objetivo versus número de chamadas desta função para a terceira otimização do GWO. ....	60
Figura 22 – Gráfico função objetivo versus número de chamadas desta função para a quarta otimização do GWO. ....	60
Figura 23 – Gráfico função objetivo versus número de chamadas desta função para a quinta otimização do GWO.....	61
Figura 24 – Gráfico função objetivo versus número de chamadas desta função para a sexta otimização do GWO.....	61
Figura 25 – Gráfico função objetivo versus número de chamadas desta função para a sétima otimização do GWO.....	61

## LISTA DE TABELAS

Tabela 1 - Parâmetros da modelagem termodinâmica do Problema CGAM.....	37
Tabela 2 - Variáveis de decisão e seus limites inferiores e superiores do Problema CGAM. ....	39
Tabela 3 – Comparação entre valores obtidos para as pressões na validação do Problema CGAM. ....	50
Tabela 4 – Comparação entre valores obtidos para as temperaturas na validação do Problema CGAM. ....	51
Tabela 5 - Comparação entre valores obtidos para as vazões na validação do Problema CGAM. ....	51
Tabela 6 - Comparação entre valores obtidos dos custos na validação do Problema CGAM. ....	51
Tabela 7 - Resultados das otimizações do Problema CGAM utilizando o AG do EES. ....	52
Tabela 8 - Análise estatística dos resultados das otimizações do AG do EES. ....	56
Tabela 9 - Solução do Problema CGAM utilizando o AG do EES. ....	57
Tabela 10 – Resultados das otimizações do Problema CGAM utilizando o GWO. ....	59
Tabela 11 - Análise estatística dos resultados das otimizações do GWO.....	62
Tabela 12 - Solução do Problema CGAM utilizando o GWO. ....	63
Tabela 13 - Comparação entre os resultados obtidos para solução do Problema CGAM. ....	64
Tabela 14 - Tempo computacional dos procedimentos de otimização para o Problema CGAM. ....	64
Tabela 15 - Número de chamadas de função objetivo para cada procedimento de otimização do Problema CGAM. ....	65

## LISTA DE SIGLAS

IFES	Instituto Federal do Espírito Santo.
UFES	Universidade Federal do Espírito Santo.
EES	<i>Engineering Equation Solver.</i>
AG	Algoritmo Genético.
GWO	<i>Grey Wolf Optimizer</i> - Algoritmo de lobos cinzentos.
CA	Compressor de ar.
PA	Pré-aquecedor de ar.
CC	Câmara de combustão.
TG	Turbina a gás.
CR	Caldeira de recuperação de calor.
EC	Economizador.
EV	Evaporador.
NCAR	<i>National Center for Atmospheric Research.</i>
ER	Erro relativo.

## LISTA DE SÍMBOLOS

$C_{P_{gases}}$	Calor específico dos gases de combustão.
$C_{P_{ar}}$	Calor específico do ar.
$CH_4$	Fórmula molecular do gás natural.
$T_0$	Temperatura ambiente.
$T_8$	Temperatura de entrada da água de alimentação da caldeira.
$P_0$	Pressão ambiente.
$P_7$	Pressão do gás de combustão na saída da caldeira.
$P_8$	Pressão de entrada da água de alimentação da caldeira.
$\dot{W}_{liq}$	Potência líquida produzida.
$P_9$	Pressão do vapor saturado produzido.
$\dot{m}_{água}$	Vazão mássica de vapor saturado produzido.
$PCI_{comb}$	Poder calorífico inferior do combustível.
$k_a$	Razão de calor específico do ar.
$k_g$	Relação entre os calores específicos a pressão e volume constantes dos gases.
$\eta_{CC}$	Rendimento térmico da câmara de combustão.
$\Delta P_{CC}$	Perda de carga na Câmara de Combustão.
$\Delta P_{a,PA}$	Perda de carga do ar no pré-aquecedor.
$\Delta P_{g,PA}$	Perda de carga dos gases de combustão no pré-aquecedor.
$\Delta P_{CR}$	Perda de carga na caldeira de recuperação de calor para os gases.
$\Delta T_a$	<i>Approach</i> da caldeira de recuperação de calor.
$P_2/P_1$	Razão de pressão do compressor de ar.
$\eta_{CA}$	Eficiência isentrópica do compressor de ar.
$T_3$	Temperatura na entrada da câmara de combustão.

$\eta_{TG}$	Eficiência isentrópica da turbina a gás.
$T_4$	Temperatura na saída da câmara de combustão.
$Z_i$	Custo de aquisição dos equipamentos da planta.
$\dot{Z}_i$	Taxa de custos associada ao investimento de capital e custos de manutenção.
$\dot{Z}_{comb}$	Taxa de custo associada ao combustível.
$\dot{Z}$	Taxa de custo total para a instalação.
$N$	Número de horas de operação da planta durante um ano.
$\varphi$	Fator de manutenção.
$CRF$	Fator anual de recuperação de capital.
$C_{comb}$	Custo do combustível por unidade de energia.
$\dot{m}_{comb}$	Vazão mássica de combustível.
$\alpha$	Lobo cinzento “alfa”.
$\beta$	Lobo cinzento “beta”.
$\delta$	Lobo cinzento “delta”.
$n$	Número de variáveis de decisão.
$\mathbf{x}_{P,\alpha}$	Vetor posição do lobo cinzento $\alpha$ .
$x_{P,\alpha}$	Posição do lobo cinzento $\alpha$ .
$\mathbf{x}_{P,\beta}$	Vetor posição do lobo cinzento $\beta$ .
$x_{P,\beta}$	Posição do lobo cinzento $\beta$ .
$\mathbf{x}_{P,\delta}$	Vetor posição do lobo cinzento $\delta$ .
$x_{P,\delta}$	Posição do lobo cinzento $\delta$ .
$\mathbf{f}$	Vetor <i>fitness</i> .
$f_\alpha$	<i>Fitness</i> para o lobo cinzento $\alpha$ .
$f_\beta$	<i>Fitness</i> para o lobo cinzento $\beta$ .
$f_\delta$	<i>Fitness</i> para o lobo cinzento $\delta$ .
$\mathbf{X}_P$	Matriz de posição dos agentes de busca.
$m$	Número de agentes de busca.

$R$	Matriz composta de valores aleatórios gerados entre 0 e 1.
$M_A$	Matriz de alcance para a posição dos lobos cinzentos.
$L_B$	Matriz que contém em cada coluna os valores de limite inferior para cada variável de decisão.
$ub$	Valor de limite superior para cada variável de decisão.
$lb$	Valor de limite inferior para cada variável de decisão.
$F_{ab}$	Matriz que contém os <i>fitness</i> de cada agente de busca para uma dada iteração.
$F$	Matriz que contém os <i>fitness</i> dos melhores agentes de busca.
$i$	Número máximo de iterações.
$m^*$	Número de melhores agentes de busca.
$a$	Vetor com $i$ elementos cujos valores diminuem de 2 para 0 de forma linear.
$R_1, R_2, R_3, R_4, R_5$ e $R_6$	Matrizes formadas por valores aleatórios contidos no intervalo [0,1].
$A_1, A_2, A_3, C_1, C_2$ e $C_3$	Matrizes de coeficiente.
$A$	Matriz que contém os valores de $a_i$ .
$D_\alpha, D_\beta$ e $D_\delta$	Matrizes que imitam o tratamento envolvente dos lobos cinzentos.
$X_{P,\alpha}$	Matriz diagonal das posições do lobo alfa.
$X_{P,\beta}$	Matriz diagonal das posições do lobo beta.
$X_{P,\delta}$	Matriz diagonal das posições do lobo delta.
$X_\alpha$	Matriz que contém em cada linha as posições do lobo alfa.
$X_\beta$	Matriz que contém em cada linha as posições do lobo beta.
$X_\delta$	Matriz que contém em cada linha as posições do lobo delta.
$X_1, X_2$ e $X_3$	Matrizes cuja média se obtém $X_P$ .
$\circ$	Produto de Hadamard.
$s^2$	Variância.

$s$	Desvio padrão.
$x_i$	Valor da amostra.
$\bar{x}$	Média das amostras.
$n$	Número de amostras.
$ x_i $	Variável de decisão normalizada.
$T_2$	Temperatura do ar na saída do compressor.
$T_1$	Temperatura do ar na entrada do compressor.
$P_2$	Pressão do ar na saída do compressor.
$P_1$	Pressão do ar na entrada do compressor.
$\dot{W}_{CA}$	Potência do compressor de ar.
$\dot{m}_{ar}$	Vazão mássica de ar.
$h_3$	Entropia do ar na entrada da câmara de combustão.
$h_4$	Entropia do ar na saída da câmara de combustão.
$\dot{Q}_{CC}$	Taxa de calor perdido na câmara de combustão.
$P_4$	Pressão na saída da câmara de combustão.
$P_3$	Pressão na entrada da câmara de combustão.
$T_5$	Temperatura dos gases na entrada do pré-aquecedor de ar.
$T_6$	Temperatura dos gases na saída do pré-aquecedor de ar.
$P_5$	Pressão dos gases de combustão na entrada do pré-aquecedor.
$P_6$	Pressão dos gases de combustão na saída do pré-aquecedor.
$\dot{W}_{TG}$	Potência desenvolvida pela turbina a gás.
$T_9$	Temperatura de saturação do vapor à pressão de saída da caldeira de recuperação de calor.
$T_{8P}$	Temperatura na saída do pré-aquecedor da caldeira de recuperação de calor.
$T_{7P}$	Temperatura dos gases de combustão após passar pelo evaporador da caldeira de recuperação de calor.



$\dot{m}_{\text{vapor}}$	Vazão mássica de vapor produzido na caldeira de recuperação de calor.
$h_9$	Entalpia do vapor na saída da caldeira de recuperação de calor.
$h_{8P}$	Entalpia da água na saída do pré-aquecedor da caldeira de recuperação de calor.
$h_8$	Entalpia da água na entrada da caldeira de recuperação de calor.
$\Delta T_P$	Diferença de temperatura no <i>pinch point</i> da caldeira de recuperação de calor.
$Z_{CA}$	Custo de aquisição do compressor de ar.
$Z_{CC}$	Custo da câmara de combustão.
$h_5$	Entalpia dos gases na entrada do pré-aquecedor de ar.
$h_6$	Entalpia dos gases na saída do pré-aquecedor de ar.
$Z_{PA}$	Custo de aquisição do pré-aquecedor de ar.
$\Delta TLM_{PA}$	Diferença de temperatura média logarítmica no pré-aquecedor de ar.
$Z_{TG}$	Custo de aquisição da turbina a gás.
$Z_{CR}$	Custo de aquisição da caldeira de recuperação de calor.
$\Delta TLM_{EC}$	Diferença de temperatura média logarítmica no economizador.
$\Delta TLM_{EV}$	Diferença de temperatura média logarítmica no evaporador.
$\dot{Q}_{EC}$	Taxa de calor trocado no economizador da caldeira de recuperação de calor.
$\dot{Q}_{EV}$	Taxa de calor trocado no evaporador da caldeira de recuperação de calor.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>17</b>
1.1	MOTIVAÇÕES, JUSTIFICATIVAS E CONTRIBUIÇÕES .....	19
1.2	OBJETIVOS .....	20
1.3	ORGANIZAÇÃO DA MONOGRAFIA.....	21
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>23</b>
2.1	PLANTAS DE COGERAÇÃO .....	23
2.2	O PROBLEMA CGAM.....	28
2.3	MÉTODOS DE OTIMIZAÇÃO HEURÍSTICOS E META-HEURÍSTICOS.....	30
<b>2.3.1</b>	<b>Algoritmo Genético</b> .....	<b>30</b>
<b>2.3.2</b>	<b>Algoritmo de Lobos Cinzentos</b> .....	<b>33</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>37</b>
3.1	MODELAGENS TERMODINÂMICA E ECONÔMICA DO PROBLEMA CGAM.....	37
3.2	FORMULAÇÃO DO PROBLEMA DE OTIMIZAÇÃO.....	38
3.3	ALGORITMO GENÉTICO DO EES.....	40
3.4	ALGORITMO DE LOBOS CINZENTOS DESENVOLVIDO NO TRABALHO .....	42
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>50</b>
4.1	MODELAGEM E FORMULAÇÃO DO PROBLEMA DE OTIMIZAÇÃO .....	50
4.2	RESULTADOS DO ALGORITMO GENÉTICO DO EES .....	52
4.3	RESULTADOS DO ALGORITMO DE LOBOS CINZENTOS .....	57
4.4	COMPARAÇÕES DOS RESULTADOS .....	63
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b> .....	<b>66</b>
	<b>REFERÊNCIAS</b> .....	<b>69</b>
	<b>APÊNDICE A – MODELAGEM TERMODINÂMICA DO PROBLEMA CGAM</b> .....	<b>75</b>
	<b>APÊNDICE B - MODELAGEM ECONÔMICA DO PROBLEMA CGAM</b> .....	<b>79</b>

## 1 INTRODUÇÃO

A escassez de recursos naturais fósseis, o aumento da demanda energética mundial, a crescente ocorrência de problemas ambientais, a complexidade de projeto e a dificuldade para estimativas de custos tornam necessário o desenvolvimento de procedimentos computacionais para projeto de sistemas térmicos. A utilização de projetos otimizados de sistemas térmicos busca encontrar a melhor relação custo/benefício que pode ser alcançada por meio da combinação dos princípios termodinâmicos, modelos econômicos e métodos de otimização (ARAÚJO, 2020).

A crise energética mundial ao longo da história tornou-se cada vez mais evidente e preocupante, visto que a energia é crucial para o desenvolvimento científico e sobrevivência humana. Sendo assim, a partir da década de 70, após a crise do petróleo, ocorreram pela primeira vez ações políticas que demonstraram preocupação em relação aos recursos utilizados para a geração de energia e problemas ambientais (FRANGOPOULOS, 2017). Dessa forma, surgiu a necessidade do desenvolvimento de metodologias para projetos de sistemas térmicos.

Ainda na década de 70, o conceito de termoeconomia foi proposto pela primeira vez por Tribus e Evans (1962). Segundo Valero et al. (1999), termoeconomia pode ser definida como uma área da ciência que combina a análise de segunda lei da termodinâmica e princípios econômicos para fornecer maneiras de resolver problemas em sistemas energéticos que não poderiam ser resolvidos pelo balanço de massa, balanço de energia e técnicas de análise econômica.

Dentre as várias metodologias de termoeconomia, uma característica comum é a maneira pela qual o custo é calculado a partir de uma base racional, a saber, a segunda lei da termodinâmica (VALERO et al., 1999). De acordo com Dimopoulos e Frangopoulos (2008), existem dois grupos principais de métodos termoeconômicos: (a) métodos de contabilidade de custos que usam custos médios como base para uma avaliação racional de preços e (b) métodos de otimização que empregam custos marginais para minimizar os custos dos produtos de um sistema ou componente.

Sistemas térmicos podem ser estruturalmente e termodinamicamente complexos. Sendo assim, é indicado o uso de um *software* comercial para desenvolvimento das modelagens destes sistemas (ARAÚJO et al., 2020). Além disso, é possível realizar a integração do *software* comercial com rotinas de otimização, programadas em um ambiente computacional externo ao *software*, para otimização termoeconômica de sistemas térmicos (PRESS et al., 1992; GOFFE et al., 1994; STORN e PRICE, 1995; KENNEDY e EBERHART, 1995; MANOLAS et al., 1997; CAMMARATA et al., 1998; DONATELLI 2002; ARAÚJO, 2008; ARAÚJO et al., 2009a, 2009b, 2010, 2015; VIEIRA et al., 2006, 2010; CORDEIRO et al., 2011) ou até mesmo utilizar *software* comercial que possui ferramentas de otimização (ARAÚJO et al., 2020; ARAÚJO, 2020).

Diferentes técnicas de otimização ou combinações delas têm sido desenvolvidas e aplicadas em todo o mundo para usinas de energia e cogeração, onde são encontrados trabalhos que utilizam estratégias de otimização em sistemas térmicos, como estratégias estocásticas (MANOLAS et al., 1997; TOFFOLO, 2002; SAHOO, 2008), algébricas (LAZZARETTO e TSATSARONIS, 2006; VALERO, 2006) e métodos de cálculo (FRANGOPOULOS, 2003).

Métodos clássicos podem ser usados para resolver casos especiais de problemas de otimização de sistemas térmicos. No entanto, devido as dificuldades de diferenciabilidade, não linearidade e não convexidade dos problemas de otimização de sistemas térmicos, esses métodos podem falhar em fornecer o ideal global. Sendo assim, torna-se essencial o desenvolvimento de métodos de otimização capazes de superar essas desvantagens e lidar com essas dificuldades. Com esse objetivo em mente, nas últimas décadas, muitos métodos heurísticos e meta-heurísticos foram desenvolvidos para resolver problemas complexos de otimização.

Dada a complexidade do problema de otimização de projeto de sistemas térmicos, encontram-se muitos trabalhos publicados sobre otimização termoeconômica destes sistemas usando algoritmos heurísticos (VIEIRA et al., 2006, 2010; CALISE et al., 2007; DIMOPOULOS e FRANGOPOULOS, 2008; ARAÚJO et al., 2009a, 2009b, 2010, 2015; CORDEIRO et al., 2011; SAYYAADI et al., 2011), o que ratifica o interesse da comunidade científica nesse campo.

Uma nova técnica meta-heurística de otimização proposta por Mirjalili et al. (2014), denominada em inglês *Grey Wolf Optimizer* (GWO), foi inspirada no comportamento dos lobos cinzentos. O algoritmo de lobos cinzentos (GWO) imita a hierarquia de liderança e o mecanismo de caça dos lobos cinzentos na natureza. Quatro tipos de lobos cinzentos, como alfa, beta, delta e ômega, são empregados para simular a hierarquia de liderança. Além disso, os três principais passos do método de caça dos lobos cinzentos (busca, cercamento e ataque de presas) são implementados no algoritmo. No trabalho de Mirjalili et al. (2014) é possível verificar que os resultados obtidos mostraram que o GWO é capaz de fornecer resultados muito competitivos em comparação com as técnicas meta-heurísticas conhecidas (enxame de partículas, busca gravitacional, evolução diferencial, programação evolutiva e estratégia de evolução), o que o torna apreciável para otimização de sistemas térmicos. Além disso, recentemente o método de lobos cinzentos tem sido aplicado para otimização de diversos problemas de engenharia (KAUR et al., 2020; ZHU e ZHOU, 2020).

### 1.1 MOTIVAÇÕES, JUSTIFICATIVAS E CONTRIBUIÇÕES

Devido à crise energética de 1970, conceitos, terminologias e princípios de termoeconomia aliados a técnicas de simulação numérica intensificaram a publicação de trabalhos para análise, projeto e otimização de sistemas térmicos até a década de 90 (BEJAN et al., 1996). Sendo assim, um problema *benchmark*, denotado como Problema CGAM (VALERO et al., 1994a), foi formulado para permitir a comparação de diferentes metodologias para otimização de sistemas de energia.

Ao longo dos anos, diferentes métodos de otimização foram utilizados para solucionar o Problema CGAM (FRANGOPOULOS, 1994; VALERO et al., 1994b; VON SPAKOVSKY, 1994; CERQUEIRA, 1999; SEYYEDI et al., 2011; ARAÚJO et al., 2020). Entretanto, não se encontra na literatura a solução deste problema a partir da integração de um *software* comercial com uma rotina de otimização meta-heurística programada em um ambiente externo e baseada no método de lobos cinzentos.

Muitos trabalhos de otimização na área de engenharia têm utilizado o algoritmo meta-heurístico de lobos cinzentos (KAUR et al., 2017; LAKUM e MAHAJAN, 2017;

KARSAZ et al., 2018; KUMAR et al., 2020; ZHU e ZHOU, 2020). Porém, não são encontrados na literatura trabalhos de otimização de plantas de cogeração utilizando este método.

Diante deste contexto, o desenvolvimento de um procedimento de otimização que integra um *software* comercial com o algoritmo de lobos cinzentos (GWO) programado em um ambiente computacional externo ao *software* comercial para projeto de plantas de cogeração mostra-se atrativo e inovador, tanto do ponto de vista acadêmico quanto prático.

## 1.2 OBJETIVOS

Este trabalho tem como objetivo principal o desenvolvimento de um procedimento de otimização que utiliza *software* comercial e o algoritmo de lobos cinzentos (GWO) programado em um ambiente computacional externo ao *software* comercial para projeto de plantas de cogeração. Para alcançar o objetivo principal proposto neste trabalho são definidos os seguintes objetivos específicos:

- I. Selecionar um *software* comercial para modelagem da planta de cogeração (Problema CGAM).
- II. Desenvolver as modelagens termodinâmicas, modelagens econômicas e formulação do problema de otimização no *software* comercial.
- III. Selecionar um *software* de programação numérica para desenvolvimento do algoritmo de otimização.
- IV. Desenvolver o algoritmo de otimização de lobos cinzentos utilizando o *software* de programação numérica.
- V. Integrar o *software* comercial e o *software* de programação numérica.
- VI. Realizar otimizações da planta de cogeração.
- VII. Analisar, comparar e discutir os resultados.

### 1.3 ORGANIZAÇÃO DA MONOGRAFIA

A aplicação do método de otimização de lobos cinzentos para projeto de plantas de cogeração, que constitui o tema central deste trabalho, é abordado neste texto em 5 capítulos, uma lista de referências bibliográficas e 2 Apêndices.

Nesta introdução (Capítulo 1), após uma breve abordagem sobre trabalhos de sistemas térmicos, métodos de otimização e método de lobos cinzentos, apresentam-se as motivações, justificativas, contribuições, objetivos e as etapas deste trabalho, e por fim, a organização básica do texto.

Uma revisão bibliográfica sobre tópicos importantes e trabalhos relacionados ao título deste trabalho é apresentado no Capítulo 2. Em seu início, faz-se uma apresentação de trabalhos de plantas de cogeração, a fim de identificar os *softwares* para modelagem e métodos de otimização, além de suas principais características. Por fim aborda-se os métodos de otimização, dando ênfase ao método de otimização meta-heurístico de lobos cinzentos.

No Capítulo 3, primeiro são descritas as principais características da modelagem termodinâmica e econômica, além do problema de otimização da planta de cogeração do estudo de caso. Posteriormente é apresentado o algoritmo de otimização utilizado neste trabalho.

No Capítulo 4, primeiramente são apresentados e discutidos os resultados da modelagem da planta de cogeração (validação). Em seguida são apresentados e discutidos os resultados da otimização da planta de cogeração utilizando o algoritmo genético do *software* comercial e o algoritmo de lobos cinzentos programado externo ao *software* comercial.

No Capítulo 5 são apresentadas as considerações finais do trabalho e feitas as sugestões para trabalhos futuros. Após esse último capítulo insere-se a listagem das referências bibliográficas consultadas.

Nos dois Apêndices, os quais servem como texto de apoio do trabalho, são apresentados os detalhes da modelagem termodinâmica e econômica da planta de cogeração.



## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo os principais conceitos envolvendo as palavras chaves que formam o título deste trabalho são apresentados. Além disso, é realizada uma revisão do estado da arte sobre projeto de plantas de cogeração, Problema CGAM e do método de otimização de algoritmo genético e de lobos cinzentos. Esses conceitos e revisão literária são imprescindíveis para a melhor compreensão e entendimento dos objetivos e motivações deste trabalho.

### 2.1 PLANTAS DE COGERAÇÃO

Plantas de cogeração são sistemas que geram energia mecânica e térmica por meio de uma única fonte energética. Isso difere de algumas gerações em centrais elétricas que utilizam equipamentos externos de aquecimento e resfriamento para suprir a uma demanda de transferência de energia térmica. O calor recuperado pode ser usado diretamente para aquecimento ou resfriamento, ou uma combinação deles (FLIN, 2009).


Em termos de utilização da ideia de cogeração para uso industrial e comercial, Frangopoulos (2017) afirma que a cogeração surgiu na Europa e nos Estados Unidos entre os anos de 1880 e 1890. Várias indústrias no Brasil, a partir do plano governamental da década de 1940, começaram também a utilizar o sistema de cogeração, queimando principalmente combustíveis fósseis, tais como petróleo, carvão e gás natural (CITTADINO, 2017).

Segundo Frangopoulos (2017), o aumento abrupto dos custos de combustíveis na década de 70 devido à crise energética da época, o crescimento da conscientização sobre a poluição ambiental, a aplicação de técnicas e métodos computacionais apropriados para análise e a otimização e o desenvolvimento de *softwares* comerciais, tornaram possíveis projetos de usinas de cogeração cada vez mais eficientes. Além disso, de acordo com Cittadino (2017) fatores como o desenvolvimento tecnológico das turbinas e motores, maior disponibilidade de gás natural em diversos países, necessidade de conversão energética de forma sustentável, aumento da regulação

da geração de eletricidade e perda de interesse pela construção de usinas nucleares impulsionaram o mercado de cogeração.


Existem dois tipos de configuração de plantas de cogeração: plantas do tipo “*topping*” e “*bottoming*”. Na configuração *topping*, a planta de cogeração primeiro produz energia na forma de trabalho no nível de temperatura mais alto e em seguida ocorre o reaproveitamento de calor. Já na configuração *bottoming* após a utilização da energia térmica por meio de um sistema de recuperação de calor é produzida a energia mecânica (SANTOS, 2014). Geralmente as usinas de cogeração produzem eletricidade para uso próprio e vendem parte do excesso de energia para uma concessionária. Faixas típicas de temperatura para cada tipo de planta de cogeração são apresentadas na Figura 1 e na Figura 2.

Figura 1 - Faixa típica de temperatura para planta de cogeração do tipo *topping*.



Fonte: Santos (2014).

Figura 2 - Faixa típica de temperatura para planta de cogeração do tipo *bottoming*.



Fonte: Santos (2014).

Segundo Flin (2010), as plantas de ciclo *bottoming* são muito menos comuns do que as plantas de ciclo *topping*. Isso ocorre porque a eletricidade pode ser comprada ou vendida facilmente quando excede a demanda do local, enquanto a demanda de calor

é geralmente mais restritiva. As plantas do tipo *topping* podem ser encontradas em centrais termelétricas e as plantas *bottoming* existem em indústrias pesadas, como unidades de fabricação de vidro ou metal.

Nos últimos anos, devido à crescente concorrência econômica mundial e ao desenvolvimento de novos processos industriais, observa-se a necessidade do projeto de plantas de cogeração cada vez mais eficientes, tanto do ponto de vista termodinâmico quanto econômico (ARAÚJO, 2020).

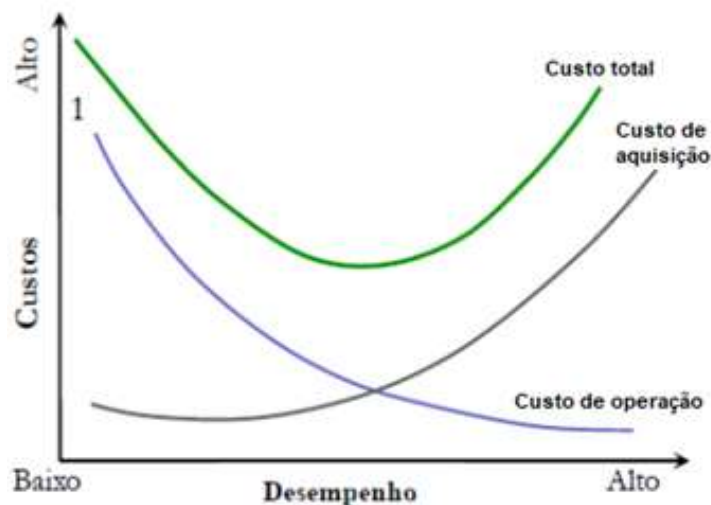
Ao longo dos anos, foram publicados inúmeros livros (BEJAN et al., 1996; JALURIA, 1998; SCIUBBA e MELLI, 1998; BEJAN e MAMUT, 1999; MOMOH, 2001; EL-SAYED, 2003; EBRAHIMI e KESHAVARZ, 2015; VIVEK et al, 2019) e artigos científicos (VALERO et al, 1994a; FRANGOPOULOS, 1994; FRANGOPOULOS et al, 1996; VALDÉS et al., 2003; LIU et al., 2007; CHEN e LIN, 2011; DONG et al, 2012; ZHENG e KIM, 2013) sobre modelagem e otimização de sistemas térmicos e plantas de cogeração.

Plantas de cogeração são estruturalmente e termodinamicamente complexas, com grande número de componentes, interconexões e fluxos modelados por sistemas de extensas / complexas equações não-lineares. Sendo assim, o uso de um *software* comercial para modelagem destas plantas é fundamental para obter maior eficiência computacional, já que ele fornece as propriedades termodinâmicas, modelos de componentes e resolve o conjunto de equações dos balanços de massa e energia (ARAÚJO et al., 2020; ARAÚJO, 2020).

Os *softwares* comerciais permitem ao engenheiro modelar o comportamento de um componente ou de todo o sistema térmico, sob condições específicas e realizar análises térmicas, de dimensionamento, de custo e de otimização. Essas atividades são requeridas para o desenvolvimento apropriado do projeto de um sistema térmico (BEJAN *et al.*, 1996). Plantas de cogeração modeladas em *softwares* comerciais podem ser encontradas nos trabalhos de Donatelli (2002), Vieira et al. (2006, 2010), Araújo et al. (2009a, 2009b, 2010 e 2015), Cordeiro et al. (2011) e Pires (2013). Nestes trabalhos as modelagens das plantas de cogeração foram desenvolvidas no *software* IPSEpro.

De acordo com a Figura 3, projetos de plantas de cogeração cada vez mais eficientes requerem sistemas complexos e de alto custo de implantação, entretanto a operação e manutenção destes sistemas tendem a ser mais econômica quando comparada a sistemas menos eficientes. Devido a esta dualidade entre custo e eficiência é necessária a otimização termoeconômica das plantas de cogeração com a finalidade de encontrar um ponto ótimo para um objetivo específico.

Figura 3 - Custo do ciclo de vida de plantas de cogeração.



Fonte: Elaborado pelo próprio autor.

Para que seja realizada uma otimização termoeconômica, é necessário que sejam especificados os modelos termodinâmicos e os modelos de custos da instalação da planta, assim como a formulação de um problema de otimização por meio de uma função objetivo, a qual possa ser previsto algum indicador de performance econômico associado ao projeto do sistema térmico (ARAÚJO, 2020).

Jaluria (1998) define a função objetivo como aquela que deve ser maximizada ou minimizada, representando uma característica de interesse particular para dada circunstância. Para otimizações de sistemas térmicos geralmente essa característica representa a eficiência térmica, custo total, lucro e irreversibilidades (PENONCELLO, 2015).

Técnicas de otimização são cada vez mais aplicadas no projeto ótimo de sistemas térmicos (ARAÚJO, 2020). Devido a eficiência dos métodos heurísticos otimização de

sistemas térmicos, observa-se um aumento do número de publicações (VIEIRA et al., 2006; CALISE et al., 2007; DIMOPOULOS e FRANGOPOULOS, 2008; ARAÚJO et al., 2009a, 2009b, 2010, 2015; VIEIRA et al., 2010; CORDEIRO et al., 2011; SAYYAADI et al., 2011).

Vieira et al. (2006) desenvolveram um processo de otimização integrada entre um simulador de processo (IPSE-pro) e o método dos poliedros flexíveis, programado em uma rotina externa de otimização (MS-EXCEL) e aplicando-a em um sistema complexo de cogeração com originalmente mais de 800 variáveis. A abordagem proposta provou-se eficaz, alcançando diferenças menores do que 5% entre os valores de função objetivo encontrada para diferentes pontos iniciais. Vieira et al. (2010) utilizaram a mesma abordagem integrada para a otimização paramétrica de uma planta de cogeração real localizada na periferia da cidade do Rio de Janeiro, onde foram utilizados o simulador de processo THERMOFLEX e o métodos de Powell, desenvolvido no MS-EXCEL. As condições ótimas de operação foram encontradas, onde a abordagem de otimização integrada se mostrou eficaz, robusta e útil para o gerenciamento ideal da planta.

Calise et al. (2007) utilizaram o algoritmo genético para minimizar os custos de uma usina híbrida de célula a combustível de óxido sólido, um problema complexo devido a não-linearidade dos modelos e a um grande número de variáveis de decisão. Os resultados mostraram que a otimização determinou um conjunto de variáveis de decisão cuja função objetivo foi significativamente inferior ao do projeto de referência.

Dimopoulos e Frangopoulos (2008) solucionaram problemas de otimização termoeconômica e de sistemas de energia utilizando métodos de otimização baseados nos algoritmos genético e de enxame de partículas. Embora todos os métodos tenham resolvido com sucesso os problemas propostos, o algoritmo de otimização de enxame de partículas com seleção de luta foi o que se mostrou mais eficaz, superando os outros métodos em termos de precisão dos resultados e de eficiência computacional.

Araújo et al. (2009a) realizaram otimização estrutural e paramétrica de uma usina de cogeração utilizando um algoritmo genético e Araújo et al. (2009b) realizaram

otimização estrutural e paramétrica da mesma planta por um método de busca direta (poliedros flexíveis), realizando assim uma análise comparativa entre os dois métodos. A configuração ótima do sistema foi definida utilizando-se uma superestrutura modelada em um simulador de processo comercial (IPSEpro), sendo a otimização realizada por meio de rotinas externas.

Araújo et al. (2010) compararam o desempenho de uma otimização estrutural e paramétrica de um sistema de cogeração utilizando os métodos genéticos e de recozimento simulado, por meio de uma superestrutura modelada em um simulador de processo (IPSEpro) acoplada a uma rotina de otimização externa implementada no MS-EXCEL, definindo assim a configuração ótima do sistema. No entanto, para o mesmo problema, Araújo et al. (2015) incluíram também o método de enxame de partículas na análise comparativa, em que o recozimento simulado ainda se mostrou o método mais eficaz, embora o algoritmo de enxame de partículas tenha se mostrado melhor do que o algoritmo genético para o problema de otimização analisado.

Cordeiro et al. (2011) otimizaram uma planta de cogeração modelada em um simulador de processos termodinâmicos utilizando o método de busca direta de Powell e o algoritmo genético. Os resultados obtidos permitiram comparar a eficácia entre o método de Powell, o algoritmo genético e o método dos poliedros flexíveis, onde constatou-se que o método de Powell apresentou melhor performance quando comparado aos outros dois métodos utilizados.

Sayyaadi et al. (2011) implementaram um otimizador de enxame de partículas multiobjetivo para a otimização de três funções objetivo: a exergética, a exergoeconômica e a ambiental, de um sistema de cogeração de referência, o Problema CGAM. Uma análise dos resultados obtidos pela otimização do problema multiobjetivo permitiu constatar que uma melhor operação exergética e ambiental para o sistema é dada a maior custo de produção.

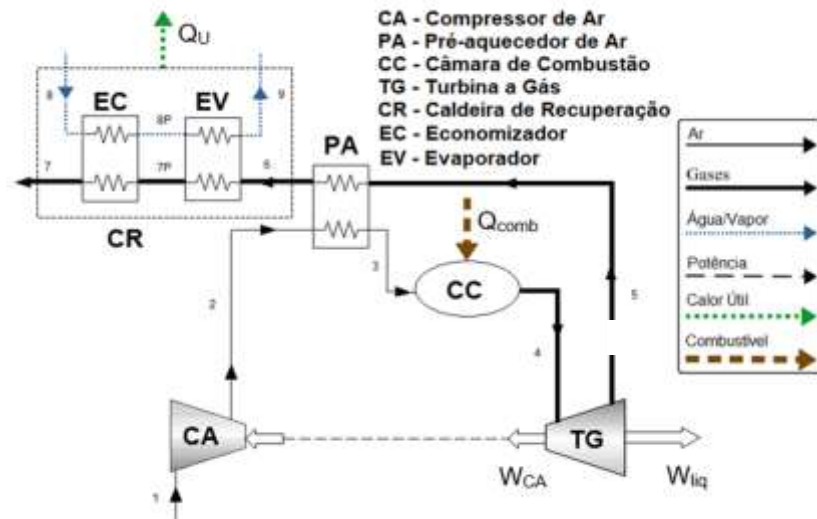
## 2.2 O PROBLEMA CGAM

Em 1994, um grupo de especialistas em termoeconomia decidiu comparar suas metodologias, resolvendo um problema generalizado e predefinido de uma planta de

cogeração com turbina a gás regenerativa (Problema CGAM - VALERO et al., 1994a). Para evitar o uso de diferentes modelos termodinâmicos para cada metodologia termoeconômica e procedimento de otimização, esses especialistas adotaram equações de estado comuns para calcular as propriedades termodinâmicas, um modelo termodinâmico denominado de modelo CGAM. O modelo termodinâmico CGAM considera um calor específico constante para os gases de combustão ( $c_{P_{gases}}$ ), calor específico constante para o ar ( $c_{P_{ar}}$ ) e leva em consideração o fluxo de massa de gás natural que entra na câmara de combustão. No entanto, este modelo não considerou as equações de conservação de energia para reagir misturas na câmara de combustão.

A planta de cogeração do Problema CGAM produz 30 MW de energia elétrica e 14 kg/s de vapor saturado a 20 bar. A estrutura física desta planta inclui compressor de ar (CA), pré-aquecedor de ar (PA), câmara de combustão (CC), turbina a gás (TG), caldeira de recuperação (CR) e pode ser visualizada na Figura 4. Além disso, as condições ambientais são definidas e o combustível é o gás natural ( $CH_4$ ).

Figura 4 - Estrutura física da planta de cogeração do Problema CGAM.



Fonte: Adaptado de Valero et al. (1994a).

Para a otimização do Problema CGAM (VALERO et al., 1994a), diferentes métodos de otimização foram utilizados, como o método do gradiente reduzido generalizado em Frangopoulos (1994), multiplicadores de Lagrange em Valero et al. (1994b),

multiplicadores de Lagrange, abordagens modulares e de decomposição em Von Spakovsky (1994), método do gradiente em Cerqueira (1999) e algoritmo genético em Seyyedi et al. (2011) e Araújo et al. (2020). Sendo assim, surge a oportunidade da otimização deste problema aplicando um novo método meta-heurístico.

## 2.3 MÉTODOS DE OTIMIZAÇÃO HEURÍSTICOS E META-HEURÍSTICOS

Tanto os métodos heurísticos quanto os meta-heurísticos apresentam eventos aleatórios em seus algoritmos matemáticos. Estes métodos baseiam-se na observação de processos da natureza e não apresentam fundamentação matemática teórica, apresentando a potencialidade de evitar a convergência prematura para pontos de mínimos locais (SÖRENSEN, 2015; DE LEON-ALDACO, 2015).

Os métodos heurísticos permitem encontrar por tentativa e erro soluções de qualidade para um problema difícil de otimização, porém não há garantia de que as soluções ideais sejam alcançadas. Geralmente é impossível pesquisar todas as soluções ou combinações possíveis devido à complexidade do problema de interesse, sendo o objetivo encontrar soluções boas e viáveis em uma escala de tempo aceitável. Já os métodos meta-heurísticos são aqueles em que houve um aprimoramento em relação aos heurísticos, onde “meta” significa “nível superior”, já que estes têm desempenho melhor do que as clássicas heurísticas (YANG, 2010).

### 2.3.1 Algoritmo Genético

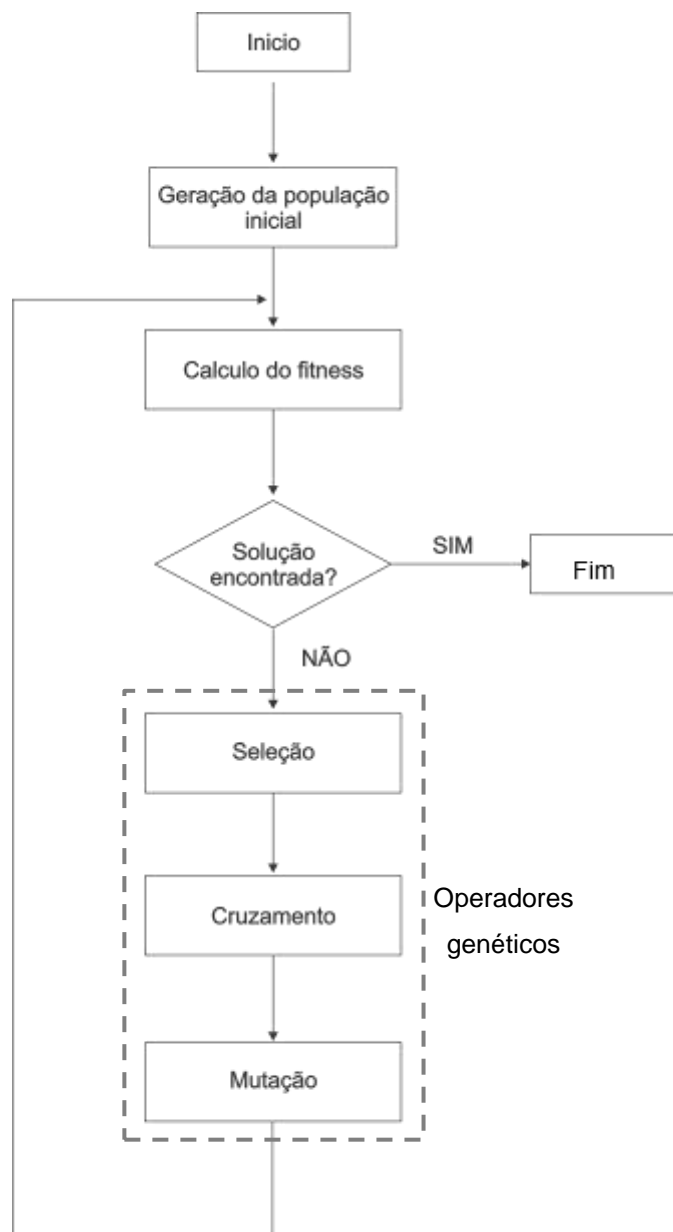
Os algoritmos genéticos tratam-se de algoritmos heurísticos, fundamentados na teoria de evolução das espécies proposta por Darwin e na teoria da genética de Mendel. De acordo com esta teoria, para uma dada população, os indivíduos que são melhores adaptados ao meio têm maiores chances de sobreviver e, portanto, transmitir seus genes às gerações seguintes, garantindo a evolução contínua de sua espécie. Os algoritmos genéticos foram introduzidos por Holland (1975), no qual o autor consolidou a teoria iniciada por ele próprio cerca de dez anos antes.

O algoritmo genético (AG) consiste em armazenar uma população de indivíduos a cada iteração, onde cada indivíduo representa uma solução potencial para o problema



de otimização. Alguns irão sofrer transformações aleatórias de operações genéticas, formando assim indivíduos diferentes a cada iteração, seja por mutação, que evolui a partir de mudanças em um único indivíduo, ou por crossover, que gera um único indivíduo a partir da combinação de dois outros. Dessa forma, os novos indivíduos gerados são avaliados a cada iteração até que ocorra a convergência das variáveis de decisão para valores ótimos (GEN e CHENG, 2000). Um fluxograma do pseudocódigo do algoritmo genético é apresentado na Figura 5.

Figura 5 - Fluxograma do pseudocódigo do algoritmo genético.



Fonte: Adaptado de Oliveira (2017).

Segundo ARAÚJO (2008), uma configuração simplificada do pseudocódigo do algoritmo genético pode ser estruturada da seguinte forma:

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

Encontram-se na literatura trabalhos de otimização de sistemas térmicos que utilizam algoritmo genético (AG). Koch et al. (2007) realizaram uma otimização termoeconômica de uma superestrutura para minimização do custo da eletricidade produzida em uma planta de potência a ciclo combinado. A modelagem da superestrutura foi desenvolvida em um *software* comercial (GateCycle) e adequadamente acoplada ao MATLAB, onde o algoritmo evolucionário (algoritmo genético) foi utilizado como método de otimização.

Araújo (2008) realizou a otimização de uma superestrutura de uma planta de cogeração para atender as demandas fixas de energia elétrica e vapor para um processo. Neste trabalho, a modelagem da superestrutura foi desenvolvida no *software* IPSEpro e acoplada ao *Visual Basic* do *Microsoft Excel*, onde o algoritmo genético também foi utilizado como método de otimização.

Rezaie et al. (2019) otimizaram e desenvolveram o projeto de uma caldeira de recuperação de calor com uma estrutura complexa utilizando algoritmo genético. Ren et al. (2019) aplicaram o AG em sistemas híbridos de geração de energia, constatando que por meio de otimizações a contribuição térmica solar deste sistema pode ser elevada em 206%.

Araújo et al. (2020) estudaram a influência dos modelos termodinâmicos nos resultados obtidos na otimização termoeconômica e na alocação de custos de uma planta de cogeração. Para realizar as otimizações termoeconômicas desta planta foi utilizado o algoritmo genético.

Apesar de suas vantagens em lidar com problemas complexos de otimização, a aplicação de algoritmos genéticos para a solução de problemas de otimização também possuem desvantagens. A formulação da função objetivo, o uso do tamanho da população, a escolha de parâmetros importantes, como a taxa de mutação e cruzamento, e os critérios de seleção da nova população devem ser cuidadosamente realizados. Qualquer escolha inadequada dificulta a convergência do algoritmo ou pode gerar resultados sem sentido (YANG, 2010).

### 2.3.2 Algoritmo de Lobos Cinzentos

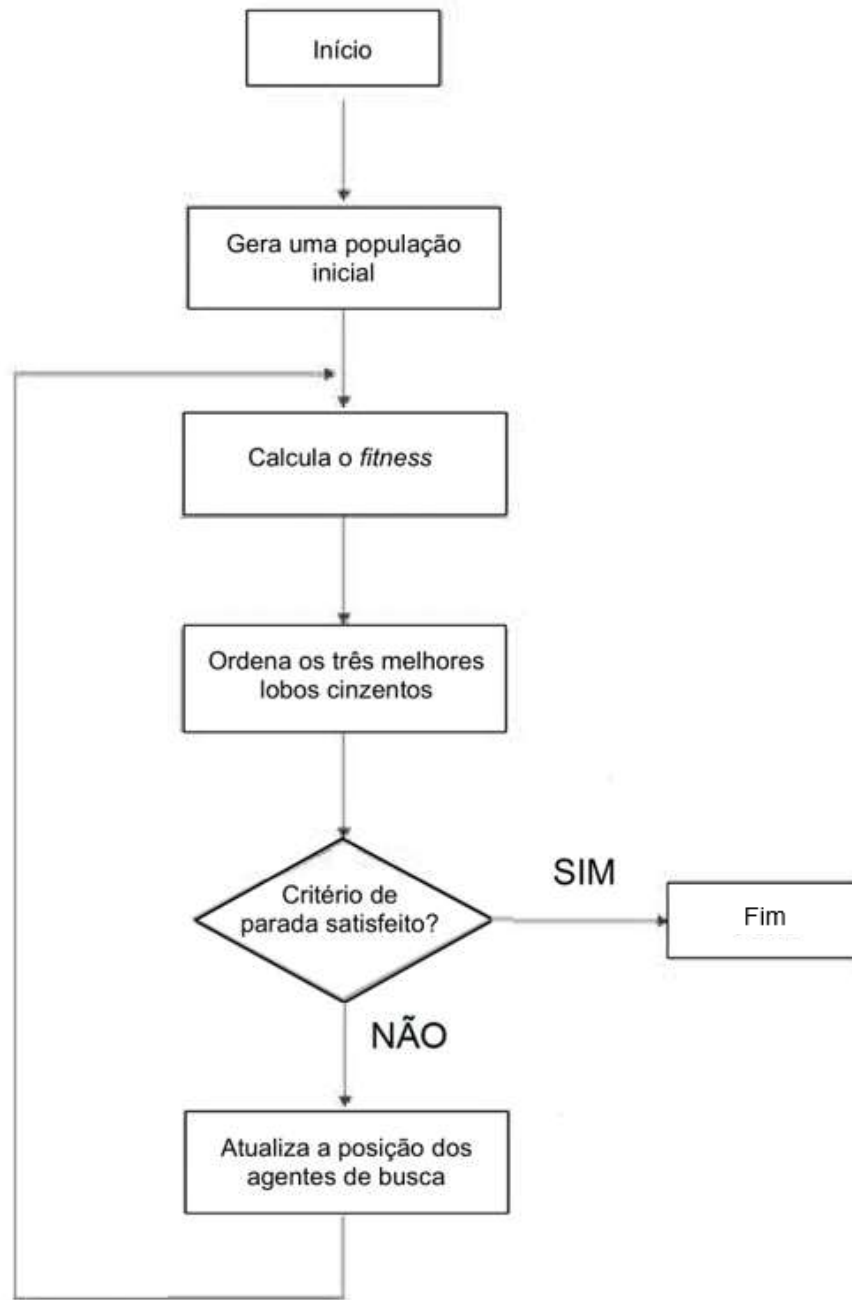
O algoritmo de otimização meta-heurístico de lobos cinzentos (GWO) é baseado no comportamento destes animais e foi proposto no trabalho de (MIRJALILI et al., 2014). Dessa forma, o algoritmo de lobos cinzentos consiste em três etapas: procurar presas, cercar presas e atacar presas. Após encontrar uma presa, o grupo de lobos cinzentos a rastreia e a acompanha. Aos poucos vão circundando a presa, como mostrado na Figura 6, até que ela pare de se mover. Depois disso, atacam a presa. Um fluxograma básico do pseudocódigo do algoritmo de lobos cinzentos é apresentado na Figura 7.

Figura 6 - Comportamento de caça dos lobos cinzentos.



Fonte: Mirjalili et al. (2014).

Figura 7 - Fluxograma do pseudocódigo do algoritmo de lobos cinzentos.



Fonte: Elaborado pelo próprio autor.

De acordo com Mirjalili et al. (2014) uma configuração simplificada do pseudocódigo do algoritmo genético pode ser estruturada da seguinte forma:

- i) Inicializa uma população de lobos cinzentos.
- ii) Enquanto não for alcançado o número máximo de iterações, faça:
  - ii.a) Calcula os vetores de coeficiente.
  - ii.b) Calcula o *fitness* de cada agente de busca.

- ii.c) Seleciona os três melhores agentes.
- ii.d) Ordena os três melhores agentes de busca.
- ii.e) Retorna o fitness do melhor agente de busca.
- ii.f) Atualiza a posição dos agentes de busca.

Recentemente, a aplicação de GWO têm-se mostrado eficiente para otimização de sistemas de potência (LAKUM e MAHAJAN, 2017; ABDULGADER et al., 2017; BAYGI et al., 2018; BO et al., 2019; LI et al.; 2019; KAUR et al., 2020). Lakum e Mahajan (2017) compararam o desempenho do GWO com outros dois algoritmos meta-heurísticos (algoritmos de libélulas e de baleias) para a solução de um problema de dimensionamento de filtros de potência, cujos resultados da simulação demonstraram a superioridade em eficácia e estabilidade do algoritmo GWO.

Abdulgader et al. (2017) otimizaram por meio do GWO e por meio do algoritmo de enxame de partículas um sistema de armazenamento elétrico em *smart homes*, onde a função objetivo era o equilíbrio da carga na rede elétrica, isto é, determinar para cada hora do dia quando a energia deve ser retirada da rede e quando deve ser retirada da unidade de armazenamento. O algoritmo de lobos cinzentos apresentou 25,57% de economia em relação ao algoritmo de enxame de partículas em relação aos custos.

Baygi et al. (2018) realizaram otimização multiobjetivo de um sistema de potência híbrido utilizando os métodos de enxame de partículas, algoritmo genético, enxame de salpas e de lobos cinzentos. A comparação dos resultados das funções objetivo para cada método mostraram que o método de lobos cinzentos apresentou os melhores resultados, demonstrando assim ser o método com maior eficiência computacional.

Kaur et al. (2020) otimizaram, por meio do DMGWO (uma variação do GWO para problemas multiobjetivos), um problema com três funções objetivo de um sistema híbrido de energia renovável baseado em bateria eólica-fotovoltaica para torres de telecomunicações *off-grid* em áreas rurais, obtendo assim um projeto que garantiria fornecimento de energia econômico e confiável.

Devido às características similares entre os problemas de otimização de sistemas de potência e de sistemas térmicos, a utilização do algoritmo de lobos cinzentos pode se mostrar atraente e promissor também para problemas de otimização de sistemas térmicos.

### 3 MATERIAIS E MÉTODOS

Este capítulo descreve as principais características da modelagem termodinâmica e econômica, além da formulação do problema de otimização do estudo de caso proposto (Problema CGAM).

#### 3.1 MODELAGENS TERMODINÂMICA E ECONÔMICA DO PROBLEMA CGAM

Para simplificar a modelagem termodinâmica do problema são consideradas as seguintes premissas: (i) os equipamentos são adiabáticos, exceto a câmara de combustão, (ii) cada equipamento é considerado em regime permanente, (iii) as energias cinética e potencial são negligenciadas. Além disso, valores razoáveis são assumidos para a perda de pressão dos fluxos de ar e gases na câmara de combustão, pré-aquecedor de ar e caldeira de recuperação. Os parâmetros considerados no desenvolvimento desta modelagem são apresentados na Tabela 1. As equações que compõem a modelagem termodinâmica deste problema são apresentadas e discutidas no Apêndice A e desenvolvidas no *software* comercial EES.

Tabela 1 - Parâmetros da modelagem termodinâmica do Problema CGAM.

Parâmetros	Símbolo	Valor
Temperatura ambiente [K]	$T_0$	298,15
Temperatura de entrada da água de alimentação da caldeira [K]	$T_8$	298,15
Pressão ambiente [bar]	$P_0$	1,013
Pressão do gás de combustão na saída da caldeira [bar]	$P_7$	1,013
Pressão de entrada da água de alimentação da caldeira [bar]	$P_8$	20
Potência líquida produzida [kW]	$\dot{W}_{liq}$	30000
Pressão do vapor saturado produzido [bar]	$P_9$	20
Vazão mássica de vapor saturado produzido [kg/s]	$\dot{m}_{\text{água}}$	14
Poder calorífico inferior do metano [kJ/kg]	$PCI_{comb}$	50000
Calor específico do ar [kJ/kg.K]	$C_{P_{ar}}$	1,004

Parâmetros	Símbolo	Valor
Calor específico dos gases de combustão [kJ/kg.K]	$C_{p_{gases}}$	1,17
Razão de calor específico do ar [-]	$k_a$	1,4
Razão de calor específico dos gases de combustão [-]	$k_g$	1,33
Eficiência da câmara de combustão [-]	$\eta_{CC}$	0,98
Perda de carga da câmara de combustão [%]	$\Delta P_{CC}$	5
Perda de carga do ar no pré-aquecedor [%]	$\Delta P_{a,PA}$	5
Perda de carga dos gases de combustão no pré-aquecedor [%]	$\Delta P_{g,PA}$	3
Perda de carga dos gases de combustão na caldeira de recuperação [%]	$\Delta P_{CR}$	5
<i>Approach</i> da caldeira de recuperação [K]	$\Delta T_A$	15

Fonte: Valero et al. (1994a).

Para uma conclusão efetiva de um projeto de sistema térmico é necessária uma metodologia para estimativa dos principais custos envolvidos no projeto (BEJAN; TSATSARONIS; MORAN, 1996). Desta forma, para avaliar os custos da planta de cogeração é necessário considerar o custo anual de combustível e o custo anual associado à operação de cada componente da planta. As expressões dadas por Valero et al. (1994a) para obter os custos de aquisição ( $Z_i$ ) dos equipamentos da planta são apresentados no Apêndice B e desenvolvidas no EES.

### 3.2 FORMULAÇÃO DO PROBLEMA DE OTIMIZAÇÃO

Com base nos custos de aquisição dos equipamentos e combustível, a função objetivo avaliada para o problema de otimização é a taxa de custo total anual ( $\dot{Z}$ ) expressa na Equação (3.1). Esta taxa de custo total anual é associada à taxa de custo total anual dos equipamentos ( $\dot{Z}_i$ ) e à taxa de custo anual de combustível ( $\dot{Z}_{comb}$ ), obtidas pelas Equações (3.2) e (3.3), respectivamente.

$$\dot{Z} = \sum \dot{Z}_i + \dot{Z}_{comb} \quad (3.1)$$



$$\dot{Z}_i = \frac{Z_i \cdot CRF \cdot \varphi}{N \cdot 3600} \quad (3.2)$$

$$\dot{Z}_{comb} = c_{comb} \cdot \dot{m}_{comb} \cdot PCI_{comb} \quad (3.3)$$

Onde:

$Z_i$  : Custo de aquisição do equipamento.

$CRF$  : Fator anual de recuperação de capital (18,2%).

$N$  : Número de horas de operação da planta durante um ano (8000 horas).

$\varphi$  : Fator de manutenção (1,06).

$c_{comb}$  : Custo do combustível por unidade de energia (0,004 US\$/MJ).

$\dot{m}_{comb}$  : Vazão mássica de combustível.

$PCI_{comb}$  : Poder calorífico inferior do combustível (50.000 KJ/kg).

O problema de otimização proposto pelo Problema CGAM consiste em minimizar os custos totais, assumindo uma taxa fixa de produção de eletricidade e vapor. Assim, a otimização do problema pode ser expressa como a minimização da Equação (3.1), sujeito às restrições impostas pelos modelos termodinâmico e econômico. As variáveis de decisão e seus limites inferiores e superiores do problema de otimização são apresentadas na Tabela 2. Assim como as modelagens termodinâmicas e econômicas da planta de cogeração, a formulação do problema de otimização também foi desenvolvida no EES.

Tabela 2 - Variáveis de decisão e seus limites inferiores e superiores do Problema CGAM.

Variável de decisão	Símbolo	Limite inferior	Valor inicial	Limite superior
Razão de pressão do compressor de ar [-]	$P_2/P_1$	1	7	12
Eficiência isentrópica do compressor de ar [-]	$\eta_{CA}$	0,6	0,7	0,89
Temperatura na entrada da câmara de combustão [K]	$T_3$	750	900	1250
Eficiência isentrópica da turbina a gás [-]	$\eta_{TG}$	0,6	0,8	0,91
Temperatura na saída da câmara de combustão [K]	$T_4$	1250	1300	2000

Fonte: Elaborado pelo próprio autor.

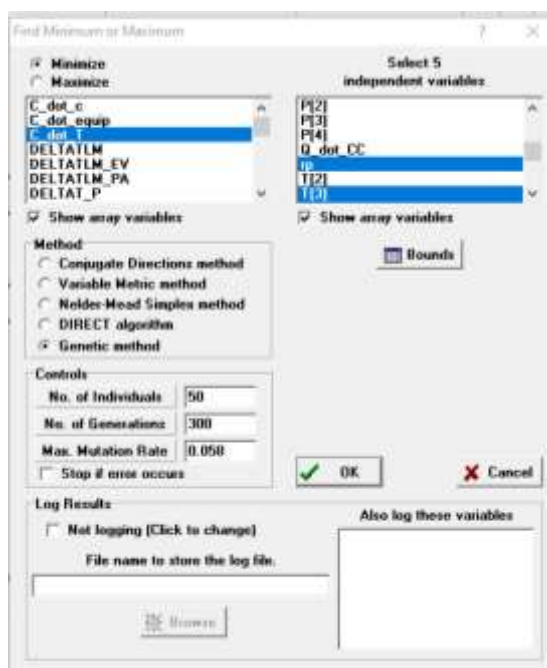
### 3.3 ALGORITMO GENÉTICO DO EES

O algoritmo genético (AG) utilizado para a otimização do Problema CGAM está disponível na ferramenta de otimização do EES. Este algoritmo é derivado do programa de otimização PIKAIA de domínio público (*version 1.2*, abril de 2002), escrita por Paul Charbonneau e Barry Knapp no Centro Nacional de Pesquisa Atmosférica (NCAR) (CHARBONNEAU e KNAPP, 2002).

PIKAIA incorpora apenas os dois operadores genéticos básicos: cruzamento de um ponto uniforme e mutação de um ponto uniforme. Ao contrário de muitos pacotes AG disponíveis comercialmente ou em domínio público, a codificação em PIKAIA é baseada em um alfabeto decimal formado por 10 inteiros simples (0 a 9). Isso ocorre porque as operações binárias geralmente são realizadas por meio de funções dependentes da plataforma no FORTRAN. Três planos de reprodução estão disponíveis: Substituição de geração completa, Steady-State-Delete-Random e Steady-State-Delete-Pior. O elitismo está disponível e é uma opção padrão. A taxa de mutação pode ser controlada dinamicamente monitorando a diferença de adequação entre o melhor e a mediana atual da população (também uma opção padrão). A seleção é baseada em classificação e estocástica, fazendo uso do Algoritmo de Roleta. Desta forma, o algoritmo genético do EES baseado na rotina de otimização PIKAIA apresenta características complementares aos algoritmos genéticos padrões (básicos).

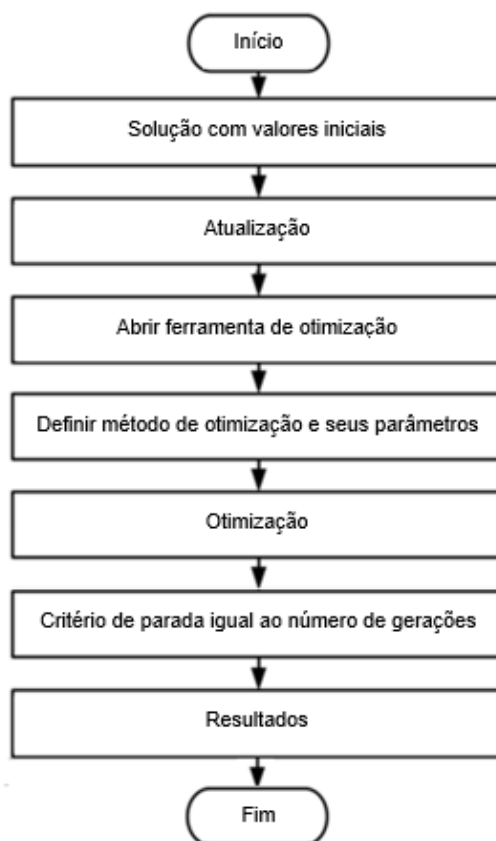
De acordo com a Figura 8, os parâmetros do algoritmo genético do EES são definidos na ferramenta de otimização e seu critério de convergência é dado pelo número de gerações. O fluxograma do processo de otimização do algoritmo genético do EES para as otimizações deste trabalho é mostrado na Figura 9.

Figura 8 - Seleção de parâmetros do algoritmo genético do EES.



Fonte: EES.

Figura 9 - Fluxograma do procedimento de otimização do algoritmo genético do EES.



Fonte: Elaborado pelo próprio autor.

### 3.4 ALGORITMO DE LOBOS CINZENTOS DESENVOLVIDO NO TRABALHO

O algoritmo de otimização lobos cinzentos (GWO) é baseado em imitações da hierarquia de liderança e mecanismo de caça de lobos cinzentos na natureza. Assim, o código desenvolvido em *software* numérico deve modelar este comportamento de forma que o melhor resultado seja o obtido pelo lobo alfa, o segundo melhor pelo lobo beta e o terceiro melhor pelo lobo delta.

A inicialização para cada variável de decisão é responsável por criar a primeira população de lobos cinzentos. Inicialmente os vetores de posição,  $\mathbf{x}_{P,\alpha}$ ,  $\mathbf{x}_{P,\beta}$ ,  $\mathbf{x}_{P,\delta}$ , com  $n$  elementos (número de variáveis de decisão) são expressos pelas Equações (3.4), (3.5) e (3.6) e o vetor *fitness* (função objetivo),  $f$ , que possui 3 elementos, pela Equação (3.7). Para problemas cujo objetivo seja de maximizar a função objetivo, o valor de  $\infty$  deve ser alterado para  $-\infty$ .

$$\mathbf{x}_{P,\alpha} = \begin{bmatrix} x_{P_1,\alpha} \\ x_{P_2,\alpha} \\ \vdots \\ x_{P_n,\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (3.4)$$

$$\mathbf{x}_{P,\beta} = \begin{bmatrix} x_{P_1,\beta} \\ x_{P_2,\beta} \\ \vdots \\ x_{P_n,\beta} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (3.5)$$

$$\mathbf{x}_{P,\delta} = \begin{bmatrix} x_{P_1,\delta} \\ x_{P_2,\delta} \\ \vdots \\ x_{P_n,\delta} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (3.6)$$

$$\mathbf{f} = \begin{bmatrix} f_{\alpha} \\ f_{\beta} \\ f_{\delta} \end{bmatrix} = \begin{bmatrix} \infty \\ \infty \\ \infty \end{bmatrix} \quad (3.7)$$

Onde:

$n$ : Número de variáveis de decisão.

$x_{P,\alpha}$ : Vetor posição do lobo cinzento  $\alpha$ .

$x_{P,\beta}$ : Vetor posição do lobo cinzento  $\beta$ .

$x_{P,\delta}$ : Vetor posição do lobo cinzento  $\delta$ .

$\mathbf{f}$ : Vetor *fitness*.

$f_{\alpha}$ : *fitness* para o lobo cinzento  $\alpha$ .

$f_{\beta}$ : *fitness* para o lobo cinzento  $\beta$ .

$f_{\delta}$ : *fitness* para o lobo cinzento  $\delta$ .

A posição dos primeiros agentes de busca é dada pela matriz  $\mathbf{X}_p$  de dimensões  $[m \times n]$  é obtida pela Equação (3.8), onde  $m$  é o número de agentes (lobos).

$$\mathbf{X}_p = \mathbf{R} \times \mathbf{M}_A + \mathbf{L}_B \quad (3.8)$$

A matriz  $\mathbf{R}$  de dimensões  $[m \times n]$ , calculada pela Equação (3.9), é composta por valores aleatórios.

$$\mathbf{R} = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ r_{m1} & r_{m2} & \cdots & r_{mn} \end{bmatrix} \quad (3.9)$$

Para o cálculo da posição dos primeiros agentes de busca, define-se a matriz diagonal  $\mathbf{M}_A$  como a matriz de alcance para a posição dos lobos cinzentos, que possui dimensões  $[n \times n]$  e que pode ser calculada pela Equação (3.10).

$$\mathbf{M}_A = \begin{bmatrix} (ub_1 - lb_1) & 0 & \dots & 0 \\ 0 & (ub_2 - lb_2) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & (ub_n - lb_n) \end{bmatrix} \quad (3.10)$$

Onde:

$ub$  : Limite superior para cada variável de decisão.

$lb$  : Limite inferior para cada variável de decisão.

A matriz  $\mathbf{L}_B$ , de dimensões  $[m \times n]$ , contém os valores de limite inferior para cada variável de decisão definida para o problema de otimização. Ela é dada pela Equação (3.11).

$$\mathbf{L}_B = \begin{bmatrix} lb_1 & lb_2 & \dots & lb_n \\ lb_1 & lb_2 & \dots & lb_n \\ \vdots & \vdots & \ddots & \vdots \\ lb_1 & lb_2 & \dots & lb_n \end{bmatrix} \quad (3.11)$$

Com a posição dos agentes de busca definida, é possível obter a matriz  $\mathbf{F}_{ab}$  de acordo com a Equação (3.12). Esta matriz tem dimensões  $[i \times m]$  e contém os *fitness* (função objetivo) dos agentes a cada iteração.

$$\mathbf{F}_{AB} = \begin{bmatrix} f_{11} & f_{12} & \dots & f_{1m} \\ f_{21} & f_{22} & \dots & f_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ f_{i1} & f_{i2} & \dots & f_{im} \end{bmatrix} \quad (3.12)$$

Após o cálculo do *fitness*, os lobos cinzentos são ordenados e os melhores são escolhidos e armazenados na matriz  $\mathbf{F}$  dada pela Equação (3.13) e de dimensões  $[i \times m^*]$ , sendo  $i$  o número de iterações e  $m^*$  o número dos melhores agente de busca. Desta forma,  $f_\alpha$  é o *fitness* do melhor agente,  $f_\beta$  é o *fitness* do segundo melhor

e  $f_{\delta}$  é o *fitness* do terceiro melhor a cada iteração. Além disso, são atualizados os vetores de posição ( $\mathbf{x}_{P,\alpha}$ ,  $\mathbf{x}_{P,\beta}$  e  $\mathbf{x}_{P,\delta}$ ) dos melhores agentes de busca.

$$\mathbf{F} = \begin{bmatrix} f_{1\alpha} & f_{1\beta} & f_{1\delta} \\ f_{2\alpha} & f_{2\beta} & f_{2\delta} \\ \vdots & \vdots & \vdots \\ f_{i\alpha} & f_{i\beta} & f_{i\delta} \end{bmatrix} \quad (3.13)$$

Visto que os lobos cinzentos terminam a caça atacando a presa quando ela para de se mover, a modelagem matemática deste fenômeno pode ser feita diminuindo-se o valor de um vetor  $\mathbf{a}$  com  $i$  elementos, cujo valores variam entre 2 e 0 de forma linear (RADOSAVLJEVIĆ, 2018), como é mostrado na Equação (3.14).

$$\mathbf{a} = \begin{bmatrix} a_1 = 2 \\ a_2 \\ \vdots \\ a_{i-1} \\ a_i = 0 \end{bmatrix} \quad (3.14)$$

As matrizes  $\mathbf{R}_1$ ,  $\mathbf{R}_2$ ,  $\mathbf{R}_3$ ,  $\mathbf{R}_4$ ,  $\mathbf{R}_5$  e  $\mathbf{R}_6$ , de dimensões  $[m \times n]$  e formadas por valores aleatórios, são dadas pelas Equações (3.15), (3.16), (3.17), (3.18), (3.19) e (3.20).

$$\mathbf{R}_1 = \begin{bmatrix} r_{111} & r_{112} & \dots & r_{11n} \\ r_{121} & r_{122} & \dots & r_{12n} \\ \vdots & \vdots & \vdots & \vdots \\ r_{1m1} & r_{1m2} & \dots & r_{1mn} \end{bmatrix} \quad (3.15)$$

$$\mathbf{R}_2 = \begin{bmatrix} r_{211} & r_{212} & \dots & r_{21n} \\ r_{221} & r_{222} & \dots & r_{22n} \\ \vdots & \vdots & \vdots & \vdots \\ r_{2m1} & r_{2m2} & \dots & r_{2mn} \end{bmatrix} \quad (3.16)$$

$$\mathbf{R}_3 = \begin{bmatrix} r_{3_{11}} & r_{3_{12}} & \cdots & r_{3_{1n}} \\ r_{3_{21}} & r_{3_{22}} & \cdots & r_{3_{2n}} \\ \vdots & \vdots & \vdots & \vdots \\ r_{3_{m1}} & r_{3_{m2}} & \cdots & r_{3_{mn}} \end{bmatrix} \quad (3.17)$$

$$\mathbf{R}_4 = \begin{bmatrix} r_{4_{11}} & r_{4_{12}} & \cdots & r_{4_{1n}} \\ r_{4_{21}} & r_{4_{22}} & \cdots & r_{4_{2n}} \\ \vdots & \vdots & \vdots & \vdots \\ r_{4_{m1}} & r_{4_{m2}} & \cdots & r_{4_{mn}} \end{bmatrix} \quad (3.18)$$

$$\mathbf{R}_5 = \begin{bmatrix} r_{5_{11}} & r_{5_{12}} & \cdots & r_{5_{1n}} \\ r_{5_{21}} & r_{5_{22}} & \cdots & r_{5_{2n}} \\ \vdots & \vdots & \vdots & \vdots \\ r_{5_{m1}} & r_{5_{m2}} & \cdots & r_{5_{mn}} \end{bmatrix} \quad (3.19)$$

$$\mathbf{R}_6 = \begin{bmatrix} r_{6_{11}} & r_{6_{12}} & \cdots & r_{6_{1n}} \\ r_{6_{21}} & r_{6_{22}} & \cdots & r_{6_{2n}} \\ \vdots & \vdots & \vdots & \vdots \\ r_{6_{m1}} & r_{6_{m2}} & \cdots & r_{6_{mn}} \end{bmatrix} \quad (3.20)$$

As matrizes de coeficiente  $\mathbf{A}_1$ ,  $\mathbf{A}_2$ ,  $\mathbf{A}_3$ ,  $\mathbf{C}_1$ ,  $\mathbf{C}_2$  e  $\mathbf{C}_3$ , de dimensões  $[m \times n]$ , são calculadas pelas Equações (3.21), (3.22), (3.23), (3.24), (3.25) e (3.26).

$$\mathbf{A}_1 = 2 \cdot a_i \cdot \mathbf{R}_1 - \mathbf{A} \quad (3.21)$$

$$\mathbf{A}_2 = 2 \cdot a_i \cdot \mathbf{R}_3 - \mathbf{A} \quad (3.22)$$

$$\mathbf{A}_3 = 2 \cdot a_i \cdot \mathbf{R}_5 - \mathbf{A} \quad (3.23)$$

$$\mathbf{C}_1 = 2 \cdot \mathbf{R}_2 \quad (3.24)$$



$$\mathbf{C}_2 = 2 \cdot \mathbf{R}_4 \quad (3.25)$$

$$\mathbf{C}_3 = 2 \cdot \mathbf{R}_6 \quad (3.26)$$

Onde:

$a_i$ : Elemento de  $\mathbf{a}$  para cada iteração.

$\mathbf{A}$ : Matriz de dimensões  $[m \times n]$  em que todos os elementos possuem o valor de  $a_i$ .

As matrizes  $\mathbf{D}_\alpha$ ,  $\mathbf{D}_\beta$  e  $\mathbf{D}_\delta$ , de dimensões  $[m \times n]$ , são definidas pelas Equações (3.27), (3.28), (3.29). As matrizes diagonais  $\mathbf{X}_{P,\alpha}$ ,  $\mathbf{X}_{P,\beta}$  e  $\mathbf{X}_{P,\delta}$ , de dimensões  $[n \times n]$ , são dadas pelas Equações (3.30), (3.31) e (3.32). Esta formulação foi desenvolvida por MIRJALILI et al. (2014) com o intuito de expressar o tratamento envolvente dos lobos cinzentos.

$$\mathbf{D}_\alpha = |\mathbf{C}_1 \mathbf{x} \mathbf{X}_{P,\alpha} - \mathbf{X}_P| = \begin{bmatrix} D_{\alpha_{11}} & D_{\alpha_{12}} & \dots & D_{\alpha_{1n}} \\ D_{\alpha_{21}} & D_{\alpha_{22}} & \dots & D_{\alpha_{2n}} \\ \vdots & \vdots & \vdots & \vdots \\ D_{\alpha_{m1}} & D_{\alpha_{m2}} & \dots & D_{\alpha_{mn}} \end{bmatrix} \quad (3.27)$$

$$\mathbf{D}_\beta = |\mathbf{C}_2 \mathbf{x} \mathbf{X}_{P,\beta} - \mathbf{X}_P| = \begin{bmatrix} D_{\beta_{11}} & D_{\beta_{12}} & \dots & D_{\beta_{1n}} \\ D_{\beta_{21}} & D_{\beta_{22}} & \dots & D_{\beta_{2n}} \\ \vdots & \vdots & \vdots & \vdots \\ D_{\beta_{m1}} & D_{\beta_{m2}} & \dots & D_{\beta_{mn}} \end{bmatrix} \quad (3.28)$$

$$\mathbf{D}_\delta = |\mathbf{C}_3 \mathbf{x} \mathbf{X}_{P,\delta} - \mathbf{X}_P| = \begin{bmatrix} D_{\delta_{11}} & D_{\delta_{12}} & \dots & D_{\delta_{1n}} \\ D_{\delta_{21}} & D_{\delta_{22}} & \dots & D_{\delta_{2n}} \\ \vdots & \vdots & \vdots & \vdots \\ D_{\delta_{m1}} & D_{\delta_{m2}} & \dots & D_{\delta_{mn}} \end{bmatrix} \quad (3.29)$$

$$\mathbf{X}_{P,\alpha} = \begin{bmatrix} x_{P_1,\alpha} & 0 & \dots & 0 \\ 0 & x_{P_2,\alpha} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & x_{P_n,\alpha} \end{bmatrix} \quad (3.30)$$

$$\mathbf{X}_{P,\beta} = \begin{bmatrix} x_{P_1,\beta} & 0 & \dots & 0 \\ 0 & x_{P_2,\beta} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & x_{P_n,\beta} \end{bmatrix} \quad (3.31)$$

$$\mathbf{X}_{P,\delta} = \begin{bmatrix} x_{P_1,\delta} & 0 & \dots & 0 \\ 0 & x_{P_2,\delta} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & x_{P_n,\delta} \end{bmatrix} \quad (3.32)$$

As matrizes  $\mathbf{X}_\alpha$ ,  $\mathbf{X}_\beta$  e  $\mathbf{X}_\delta$ , de dimensões  $[m \times n]$ , são dadas pelas Equações (3.33), (3.34) e (3.35) e contém os valores das posições dos lobos alfa, beta e delta.

$$\mathbf{X}_\alpha = \begin{bmatrix} x_{P_1,\alpha} & x_{P_2,\alpha} & \dots & x_{P_n,\alpha} \\ x_{P_1,\alpha} & x_{P_2,\alpha} & \dots & x_{P_n,\alpha} \\ \vdots & \vdots & \ddots & \vdots \\ x_{P_1,\alpha} & x_{P_2,\alpha} & \dots & x_{P_n,\alpha} \end{bmatrix} \quad (3.33)$$

$$\mathbf{X}_\beta = \begin{bmatrix} x_{P_1,\beta} & x_{P_2,\beta} & \dots & x_{P_n,\beta} \\ x_{P_1,\beta} & x_{P_2,\beta} & \dots & x_{P_n,\beta} \\ \vdots & \vdots & \ddots & \vdots \\ x_{P_1,\beta} & x_{P_2,\beta} & \dots & x_{P_n,\beta} \end{bmatrix} \quad (3.34)$$

$$\mathbf{X}_\delta = \begin{bmatrix} x_{P_1,\delta} & x_{P_2,\delta} & \dots & x_{P_n,\delta} \\ x_{P_1,\delta} & x_{P_2,\delta} & \dots & x_{P_n,\delta} \\ \vdots & \vdots & \ddots & \vdots \\ x_{P_1,\delta} & x_{P_2,\delta} & \dots & x_{P_n,\delta} \end{bmatrix} \quad (3.35)$$

A atualização da matriz  $\mathbf{X}_p$ , de dimensões  $[m \times n]$ , a qual armazena as posições dos novos agentes de busca é dada pela Equação (3.36). Onde as matrizes  $\mathbf{X}_1$ ,  $\mathbf{X}_2$  e  $\mathbf{X}_3$ , de dimensões  $[m \times n]$ , são calculadas pelas Equações (3.37), (3.38) e (3.39).

$$\mathbf{X}_p = \frac{\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3}{3} \quad (3.36)$$

$$\mathbf{X}_1 = \mathbf{X}_\alpha - \mathbf{A}_1 \circ \mathbf{D}_\alpha \quad (3.37)$$

$$\mathbf{X}_2 = \mathbf{X}_\beta - \mathbf{A}_2 \circ \mathbf{D}_\beta \quad (3.38)$$

$$\mathbf{X}_3 = \mathbf{X}_\delta - \mathbf{A}_3 \circ \mathbf{D}_\delta \quad (3.39)$$

Onde:

$\circ$ : Produto de Hadamard (operação que multiplica elemento a elemento das matrizes).

## 4 RESULTADOS E DISCUSSÕES

Neste capítulo primeiramente serão analisados os resultados da modelagem do Problema CGAM e, posteriormente, os resultados da otimização utilizando o método do algoritmo genético. Em seguida, são avaliados os resultados da otimização utilizando o método de lobos cinzentos. Por fim, apresenta-se uma análise comparativa entre os resultados das otimizações com a literatura de referência.

### 4.1 MODELAGEM E FORMULAÇÃO DO PROBLEMA DE OTIMIZAÇÃO

As modelagens termodinâmica e econômica, assim como a formulação do problema de otimização do estudo de caso deste trabalho (Problema CGAM), foram implementadas no *software* EES. Dado o conjunto de variáveis de decisão ótimas do Problema CGAM, os resultados obtidos por Valero et al. (1994a) e pela modelagem proposta neste trabalho utilizando o EES são apresentados nas Tabelas 3, 4, 5 e 6. Observa-se que os erros relativos (ER) entre os resultados obtidos da modelagem desenvolvida no EES e da literatura de referência (VALERO et al., 1994a) são extremamente baixos, o que evidencia a validação da modelagem desenvolvida neste trabalho.

Tabela 3 – Comparação entre valores obtidos para as pressões na validação do Problema CGAM.

Fluxo	Valero et al (1994a) [bar]	Modelagem EES [bar]	ER (%)
1	1,013	1,013	0,0000
2	8,634	8,634	0,0023
3	8,202	8,202	0,0060
4	7,792	7,792	0,0047
5	1,099	1,099	0,0264
6	1,066	1,066	0,0300
7	1,013	1,013	0,0000
8	20,000	20,000	0,0000
9	20,000	20,000	0,0000

Fonte: Elaborado pelo próprio autor.

Tabela 4 – Comparação entre valores obtidos para as temperaturas na validação do Problema CGAM.

Fluxo	Valero et al (1994a) [K]	Modelagem EES [K]	ER (%)
1	298,15	298,15	0,0000
2	595,51	595,51	0,0000
3	914,28	914,28	0,0000
4	1492,63	1492,63	0,0000
5	987,90	987,89	0,0010
6	718,76	718,75	0,0014
7	400,26	400,29	0,0075
8	298,15	298,15	0,0000
9	485,52	485,53	0,0021

Fonte: Elaborado pelo próprio autor.

Tabela 5 - Comparação entre valores obtidos para as vazões na validação do Problema CGAM.

Fluxo	Valero et al (1994a) [kg/s]	Modelagem EES [kg/s]	ER (%)
1	99,55	99,45	0,1005
2	99,55	99,45	0,1005
3	99,55	99,45	0,1005
4	101,18	101,08	0,0988
5	101,18	101,08	0,0988
6	101,18	101,08	0,0988
7	101,18	101,08	0,0988
8	14,00	14,00	0,0000
9	14,00	14,00	0,0000

Fonte: Elaborado pelo próprio autor.

Tabela 6 - Comparação entre valores obtidos dos custos na validação do Problema CGAM.

Custo	Valero et al (1994a)	Modelagem EES	ER (%)
Custo total [US\$/s]	0,362009	0,361990	0,0052
Custo de combustível [US\$/s]	0,325489	0,325466	0,0071
Custo dos equipamentos [US\$/s]	0,036520	0,036524	0,0110
Custo da câmara de combustão [US\$]	146.900,00	146.854,00	0,0313

Custo	Valero et al (1994a)	Modelagem EES	ER (%)
Custo do compressor [US\$]	1.348.000,00	1.348.589,00	0,0437
Custo da turbina a gás [US\$]	1.927.000,00	1.927.933,00	0,0484
Custo do pré-aquecedor [US\$]	827.700,00	828.279,00	0,0700
Custo da caldeira de recuperação [US\$]	1.202.000,00	1.200.866,00	0,0943

Fonte: Elaborado pelo próprio autor.

## 4.2 RESULTADOS DO ALGORITMO GENÉTICO DO EES

Neste item são apresentados os resultados ótimos das variáveis de decisão e função objetivo do Problema CGAM pelo algoritmo genético (AG) do EES, conforme detalhado na Tabela 7. Para o algoritmo genético são considerados como parâmetros uma população de 50 indivíduos, 300 gerações e taxa de mutação igual a 0,058.

Tabela 7 - Resultados das otimizações do Problema CGAM utilizando o AG do EES.

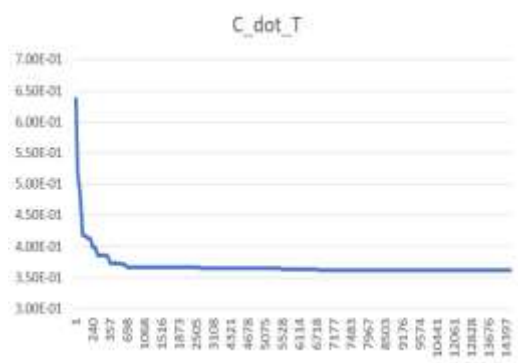
Valores Ótimos	Otimização 1	Otimização 2	Otimização 3	Otimização 4	Otimização 5	Otimização 6	Otimização 7
$P_2/P_1$ [-]	8,4560	8,7581	8,6186	8,5637	8,4577	8,4687	8,5671
$\eta_{CA}$ [-]	0,8472	0,8472	0,8495	0,8469	0,8469	0,8472	0,8475
$T_3$ [K]	914,03	909,39	909,94	911,87	913,37	913,40	911,26
$\eta_{TG}$ [-]	0,8791	0,8800	0,8794	0,8796	0,8797	0,8793	0,8797
$T_4$ [K]	1492,20	1492,42	1491,30	1491,67	1491,85	1492,03	1491,42
$\dot{Z}$ [US\$/s]	0,361992	0,362036	0,362037	0,362000	0,361997	0,361994	0,362002

Fonte: Elaborado pelo próprio autor.

A evolução do valor da função objetivo em relação ao número de chamadas de função para as otimizações utilizando o algoritmo genético é mostrado nos gráficos das Figuras 10, 11, 12, 13, 14, 15 e 16. Nota-se uma redução acentuada do valor da função objetivo no início das otimizações e uma linearidade no final. Este comportamento é devido à convergência do algoritmo de otimização, já que no final do processo de otimização ocorre uma homogeneidade da população, ou seja, não ocorrem variações significativas no valor das variáveis de decisão e consequentemente da função objetivo.

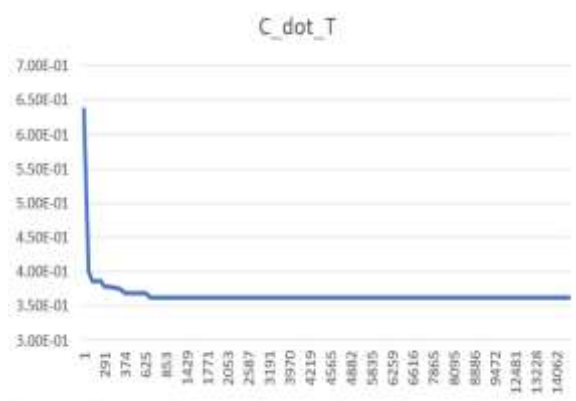


Figura 13 - Gráfico função objetivo versus número de chamadas desta função para a quarta otimização do AG do EES.




Fonte: Elaborado pelo próprio autor.

Figura 14 - Gráfico função objetivo versus número de chamadas desta função para a quinta otimização do AG do EES.



Fonte: Elaborado pelo próprio autor.

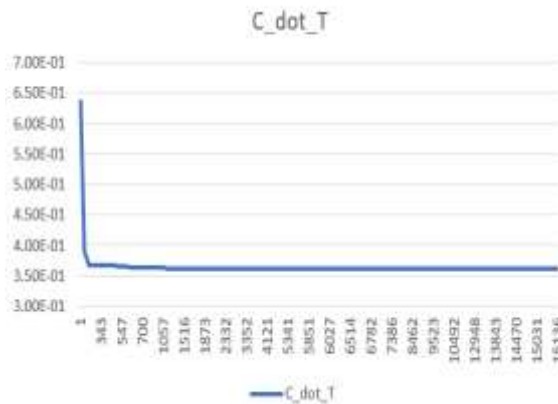
Figura 15 - Gráfico função objetivo versus número de chamadas desta função para a sexta otimização do AG do EES.



Fonte: Elaborado pelo próprio autor.



Figura 16 - Gráfico função objetivo versus número de chamadas desta função para a sétima otimização do AG do EES.



Fonte: Elaborado pelo próprio autor.

Visto que os métodos heurísticos possuem em sua natureza a característica de serem algoritmos formados por eventos aleatórios, é necessário que se faça uma análise estatística para uma melhor verificação da convergência dos métodos. Desta forma, para a análise da eficácia do algoritmo genético do EES é necessário que se faça uma avaliação da variância ( $s$ ) e do desvio padrão ( $s^2$ ) dos resultados das otimizações da Tabela 7, conforme Equações (4.1) e (4.2), respectivamente.

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \quad (4.1)$$

$$s = \sqrt{s^2} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (4.2)$$

Onde:

$s^2$ : Variância.

$s$ : Desvio padrão.

$x_i$ : Valor da amostra.

$\bar{x}$ : Média das amostras.

$n$ : Número de amostras.

Tendo em vista que as variáveis de decisão para o Problema CGAM possuem diferenças significativas em suas magnitudes, é necessário que se normalizem os resultados obtidos pela Equação (4.3). Dessa forma, os valores da média, variância e desvio padrão dos resultados das otimizações utilizando o algoritmo genético do EES são mostrados na Tabela 8.

$$|x_i| = \frac{x_i - lb_i}{ub_i - lb_i} \quad (4.3)$$

Onde:

$|x_i|$ : Variável de decisão ótima normalizada.

$x_i$ : Variável de decisão ótima.

$lb_i$ : Limite inferior da variável de decisão.

$ub_i$ : Limite superior da variável de decisão.

Tabela 8 - Análise estatística dos resultados das otimizações do AG do EES.

Valores Ótimos	Média ( $\bar{x}$ )	Variância ( $s^2$ )	Desvio Padrão ( $s$ )
$P_2/P_1$ [-]	0,686881	0,000099	0,009974
$\eta_{CA}$ [-]	0,853399	0,000010	0,003144
$T_3$ [K]	0,323789	0,000013	0,003606
$\eta_{TG}$ [-]	0,901751	0,000001	0,000965
$T_4$ [K]	0,322455	0,000000	0,000544
$\dot{Z}$ [US\$/s]	0,362008	0,000000	0,000020

Fonte: Elaborado pelo próprio autor.

A eficácia do algoritmo genético do EES para a minimização do problema proposto pode ser justificada pelos baixos valores encontrados para variância e desvio padrão dos resultados das otimizações, ou seja, no final de cada otimização o algoritmo converge para uma região de busca próxima do ótimo global. Além disso, a partir dos resultados das Tabelas 7 e 8 adota-se como solução do problema de otimização o conjunto de valores ótimos obtidos pela Otimização 1, visto que esta otimização

possui o menor valor da função objetivo. Assim, a solução do Problema CGAM utilizando o algoritmo genético do EES é mostrada na Tabela 9.

Tabela 9 - Solução do Problema CGAM utilizando o AG do EES.

Variável de Decisão	Valor Ótimo
$P_2/P_1$ [-]	8,4560
$\eta_{CA}$ [-]	0,8472
$T_3$ [K]	914,03
$\eta_{TG}$ [-]	0,8791
$T_4$ [K]	1492,20
Função Objetivo	Valor Ótimo
$\dot{Z}$ [US\$/s]	0,361992

Fonte: Elaborado pelo próprio autor.

#### 4.3 RESULTADOS DO ALGORITMO DE LOBOS CINZENTOS

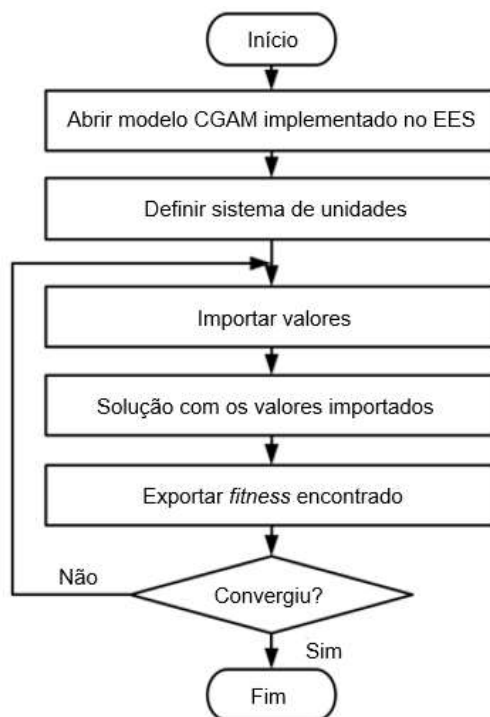
Para realizar a otimização do Problema CGAM utilizando o algoritmo de lobos cinzentos, programado no MATLAB, é necessário a realização das seguintes etapas:

- i) Abrir o arquivo referente à função objetivo e definir as variáveis de decisão, função objetivo, diretório dos arquivos da macro, dados de entrada e dados de saída. Neste arquivo é aberta a macro de integração para executar o arquivo do EES referente ao problema de otimização, o que permite importar e exportar os valores das variáveis de decisão e função objetivo para o otimizador.
- ii) Abrir o arquivo principal para definir o número de agentes, iterações, número de variáveis de decisão e seus limites inferiores e superiores. Após a definição destes parâmetros compilar e executar o arquivo.

A integração entre o EES e a rotina de otimização programada no MATLAB é realizada por meio de uma macro, ou seja, um conjunto de instruções que permite que tarefas sejam executadas de forma automática e possibilita a integração do EES com outros *softwares* de programação numérica. As instruções da macro utilizada neste trabalho

para integração do EES com o MATLAB são representadas pelo fluxograma da Figura 17 e a macro programada no EES é mostrada pela Figura 18.

Figura 17 - Fluxograma de instruções da macro de integração entre o EES e o MATLAB.



Fonte: Elaborado pelo próprio autor.

Figura 18 - Macro desenvolvida para a integração do EES com o MATLAB.

```

Macro Command List in E:\Engenharia_Mecanica\Graduacao\TCC\EES\exercises\CGAM\CGAM_TCC_completo\CGAM_macro.emf
Open 'E:\Engenharia_Mecanica\Graduacao\TCC\EES\exercises\CGAM\CGAM_TCC_completo\CGAM_TCC_completo_virgula_por_ponto.EES'
Units SI K bar kJ Mass
Import 'E:\Engenharia_Mecanica\Graduacao\TCC\EES\exercises\CGAM\CGAM_TCC_completo\Input.dat' eta_C rp T[3] T[4] eta_T
Solve
Export 'E:\Engenharia_Mecanica\Graduacao\TCC\EES\exercises\CGAM\CGAM_TCC_completo\Output.dat' C_dot_T
Quit
  
```

Fonte: Elaborado pelo próprio autor.

Para o algoritmo de lobos cinzentos são considerados como parâmetros de otimização uma população de 50 agentes de busca ( $m$ ) e 300 iterações ( $i$ ). Os resultados ótimos das variáveis de decisão e função objetivo do Problema CGAM utilizando este algoritmo são apresentados na Tabela 10.


Tabela 10 – Resultados das otimizações do Problema CGAM utilizando o GWO.

Valores Ótimos	Otimização 1	Otimização 2	Otimização 3	Otimização 4	Otimização 5	Otimização 6	Otimização 7
$P_2/P_1 [-]$	8,2184	8,7469	9,5815	7,8791	8,3684	8,5466	8,7413
$\eta_{CA} [-]$	0,8488	0,8466	0,8480	0,8476	0,8459	0,8467	0,8482
$T_3 [K]$	918,03	908,98	900,41	920,98	915,23	913,71	909,48
$\eta_{TG} [-]$	0,8780	0,8792	0,8804	0,8798	0,8787	0,8790	0,8793
$T_4 [K]$	1495,02	1489,31	1492,28	1492,69	1489,92	1491,88	1492,00
$\dot{Z} [US\$/s]$	0,362072	0,362044	0,362561	0,362217	0,362024	0,362007	0,362037

Fonte: Elaborado pelo próprio autor.


A evolução do valor da função objetivo em relação ao número de chamadas de função para as otimizações utilizando o algoritmo de lobos cinzentos é mostrado nos gráficos das Figuras 19, 20, 21, 22, 23, 24 e 25. Nota-se, na maioria das vezes, uma redução acentuada do valor da função objetivo no início das otimizações e uma linearidade no final. Este comportamento é devido à convergência do algoritmo de otimização, já que no final do processo de otimização ocorre uma homogeneidade da população, ou seja, não ocorrem variações significativas no valor das variáveis de decisão e conseqüentemente da função objetivo.

Figura 19 – Gráfico função objetivo versus número de chamadas desta função para a primeira otimização do GWO.




Fonte: Elaborado pelo próprio autor.

Figura 20 – Gráfico função objetivo versus número de chamadas desta função para a segunda otimização do GWO.




Fonte: Elaborado pelo próprio autor.

Figura 21 – Gráfico função objetivo versus número de chamadas desta função para a terceira otimização do GWO.




Fonte: Elaborado pelo próprio autor.

Figura 22 – Gráfico função objetivo versus número de chamadas desta função para a quarta otimização do GWO.



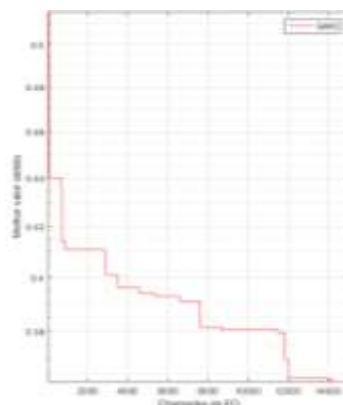
Fonte: Elaborado pelo próprio autor.

Figura 23 – Gráfico função objetivo versus número de chamadas desta função para a quinta otimização do GWO.



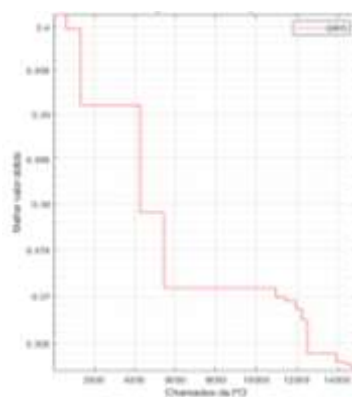
Fonte: Elaborado pelo próprio autor.

Figura 24 – Gráfico função objetivo versus número de chamadas desta função para a sexta otimização do GWO.



Fonte: Elaborado pelo próprio autor.

Figura 25 – Gráfico função objetivo versus número de chamadas desta função para a sétima otimização do GWO.



Fonte: Elaborado pelo próprio autor.

A análise da eficácia do algoritmo de lobos cinzentos é similar a utilizada para o algoritmo genético, ou seja, avaliar a variância ( $s^2$ ) e o desvio padrão ( $s$ ) dos resultados das otimizações da Tabela 10 de acordo com as Equações (4.1) e (4.2), respectivamente. Porém, para as variáveis de decisão é necessário normalizar estes resultados de acordo com a Equação (4.3), já que estas variáveis possuem diferenças significativas em suas magnitudes. Os valores da média, variância e desvio padrão dos resultados das otimizações utilizando o GWO são mostrados na Tabela 11.

Tabela 11 - Análise estatística dos resultados das otimizações do GWO.

Valores Ótimos	Média ( $\bar{x}$ )	Variância ( $s^2$ )	Desvio Padrão ( $s$ )
$P_2/P_1$ [-]	0,689378	0,002376	0,048740
$\eta_{CA}$ [-]	0,853084	0,000013	0,003621
$T_3$ [K]	0,324804	0,000186	0,013638
$\eta_{TG}$ [-]	0,900626	0,000006	0,002442
$T_4$ [K]	0,322499	0,000006	0,002501
$\dot{Z}$ [US\$/s]	0,362137	0,000000	0,000199

Fonte: Elaborado pelo próprio autor.

A eficácia do algoritmo de lobos cinzentos para a minimização do problema proposto pode ser justificada pelos baixos valores encontrados para variância e desvio padrão dos resultados das otimizações, ou seja, no final de cada otimização o algoritmo converge para uma região de busca próxima do ótimo global. Além disso, a partir dos resultados das Tabelas 10 e 11 adota-se como solução do problema de otimização o conjunto de valores ótimos obtidos pela Otimização 6, visto que esta otimização possui o menor valor da função objetivo. Assim, a solução do Problema CGAM utilizando o algoritmo de lobos cinzentos é mostrada na Tabela 12.



Tabela 12 - Solução do Problema CGAM utilizando o GWO.

Variável de Decisão	Valor Ótimo
$P_2/P_1$ [-]	8,5466
$\eta_{CA}$ [-]	0,8467
$T_3$ [K]	913,71
$\eta_{TG}$ [-]	0,8790
$T_4$ [K]	1491,88
Função Objetivo	Valor Ótimo
$\dot{Z}$ [US\$/s]	0,362007

Fonte: Elaborado pelo próprio autor.

#### 4.4 COMPARAÇÕES DOS RESULTADOS

As comparações entre os valores ótimos obtidos no trabalho de Valero et al. (1994a) e os valores ótimos obtidos na otimização deste problema por meio do algoritmo genético do EES e do algoritmo de lobos cinzentos programado em ambiente computacional externo ao *software* comercial são apresentados na Tabela 13. Observa-se que tanto as variáveis de decisão quanto a função objetivo convergem para o mesmo valor de ótimo global. A diferença infinitesimal do valor da função objetivo menor para o algoritmo genético e de lobos cinzentos em relação ao valor do problema de referência (VALERO et al., 1994a) pode ser justificada pelos valores considerados para os limites inferiores e superiores adotados para as variáveis de decisão serem diferentes, assim como a convergência dos métodos numéricos utilizados pelo EES. Dessa forma, verifica-se que tanto o procedimento de otimização utilizando o AG do EES quanto o procedimento de otimização utilizando o GWO são eficientes para otimização da planta de cogeração, já que eles alcançam resultados similares ao problema de referência proposto na literatura.

Tabela 13 - Comparação entre os resultados obtidos para solução do Problema CGAM.

Variável de Decisão	Valero et al. (1994a)	Valores Ótimos AG	ER AG (%)	Valores Ótimos GWO	ER GWO (%)
$P_2/P_1$ [-]	8,5234	8,4560	0,791	8,5466	0,272
$\eta_{CA}$ [-]	0,8468	0,8472	0,047	0,8467	0,012
$T_3$ [K]	914,28	914,03	0,027	913,71	0,062
$\eta_{TG}$ [-]	0,8786	0,8791	0,057	0,8790	0,046
$T_4$ [K]	1492,63	1492,20	0,029	1491,88	0,050
Função Objetivo	Valero et al. (1994a)	Valores Ótimos AG	ER AG (%)	Valores Ótimos GWO	ER GWO (%)
$\dot{Z}$ [US\$/s]	0,362009	0,361992	0,005	0,362007	0,001

Fonte: Elaborado pelo próprio autor.

Outra questão relevante para os procedimentos de otimização do Problema CGAM é o custo computacional. Levando em conta que os procedimentos de otimização foram executados em um notebook com processador Intel Core 2 Duo T8300 2.40 GHz e 3 GB de memória RAM, a Tabela 14 apresenta o custo computacional de cada procedimento de otimização utilizado neste trabalho para a otimização do estudo de caso. Além disso, na Tabela 15 apresenta-se o número de chamadas de função objetivo para cada procedimento de otimização. Embora os parâmetros de otimização utilizados tenham sido os mesmos, o número de chamadas da função objetivo é diferente, uma vez que o AG do EES não é um AG padrão e o número de chamadas da função objetivo torna-se maior que o produto entre o número de indivíduos e número de gerações.

Tabela 14 - Tempo computacional dos procedimentos de otimização para o Problema CGAM.

Procedimentos de Otimização	Tempo Computacional
Algoritmo Genético	2 min
Lobos Cinzentos	2583 min (43 horas)

Fonte: Elaborado pelo próprio autor.

Tabela 15 - Número de chamadas de função objetivo para cada procedimento de otimização do Problema CGAM.

Procedimento de Otimização	Chamadas de Função Objetivo
Algoritmo Genético	15184
Lobos Cinzentos	15000

Fonte: Elaborado pelo próprio autor.

Em relação à eficácia dos procedimentos computacionais propostos neste trabalho, o algoritmo genético possui um tempo computacional menor do que o algoritmo de lobos cinzentos, porém possui maior número de chamadas de função objetivo durante o processo de otimização, o que o torna menos eficaz do que o algoritmo de lobos cinzentos. Vale ressaltar que a diferença entre o tempo computacional dos procedimentos de otimização é justificada pelo fato do algoritmo de lobos cinzentos ser programado no ambiente externo ao *software* comercial, o que torna necessária a utilização de uma macro para integração dos *softwares*, ou seja, durante o processo de otimização a macro abre o arquivo do *software* EES, importa dados do *software* MATLAB, executa o arquivo do *software* EES e exporta dados para o *software* MATLAB, o que demanda maior tempo computacional.

## 5 CONSIDERAÇÕES FINAIS

A escassez de recursos naturais fósseis, o aumento da demanda energética mundial e a crescente ocorrência de problemas ambientais tornam necessário o desenvolvimento de procedimentos computacionais para projetos de sistemas térmicos cada vez mais eficientes, tanto do ponto de vista energético quanto econômico.

Sistemas térmicos geralmente possuem inúmeros componentes, interconexões e fluxos, o que resulta em um grande sistema de equações não lineares dado pelas modelagens termodinâmica e econômica destes sistemas. Além disso, as funções objetivo dos problemas de otimização destes sistemas são analiticamente intratáveis (descontínuas, multi-modais e não diferenciáveis) e possuem muitas variáveis de decisão. Desta forma, a utilização de um *software* comercial para o desenvolvimento destas modelagens e formulação do problema de otimização proporciona uma boa eficiência computacional, já que o *software* comercial fornece todas as propriedades termodinâmicas, modelos dos componentes e soluciona o sistema de equações das modelagens e do problema de otimização.

Devido à natureza dos problemas de otimização de sistemas térmicos os métodos convencionais (exatos), que utilizam gradientes, tornam-se inviáveis ou ineficientes para a solução do problema. Portanto, a aplicação de métodos de otimização que utilizam algoritmos heurísticos e meta-heurísticos para otimização de sistemas térmicos torna-se atraente, visto que durante o processo de otimização somente o valor da função objetivo é avaliada, sem necessitar de informações de suas derivadas. Além disso, esses algoritmos produzem soluções robustas, de baixo custo computacional e podem ser programados em *software* de programação numérica e acoplados com o *software* comercial.

Nesse contexto, o presente trabalho tem como objetivo principal o desenvolvimento de um procedimento de otimização para projeto de plantas de cogeração utilizando *software* comercial e o algoritmo meta-heurístico de lobos cinzentos programado em um ambiente computacional externo ao *software* comercial.

Após definição de uma planta de cogeração como estudo de caso (Problema CGAM), seleção do *software* comercial EES para modelagem termodinâmica, modelagem econômica e formulação do problema de otimização, desenvolvimento no *software* MATLAB da rotina de otimização baseada no método de lobos cinzentos e integração entre os *softwares*, o problema de otimização foi solucionado e comparado com a literatura de referência (VALERO et. Al., 1994a). Desta forma, o procedimento de otimização aqui proposto foi capaz de cumprir os objetivos do trabalho.

Na apresentação dos resultados deste trabalho, primeiramente verificou-se a validação da modelagem termodinâmica, modelagem econômica e formulação do problema de otimização desenvolvidos no *software* EES para a planta de cogeração (Problema CGAM). Adotando-se o mesmo conjunto de variáveis de decisão ótimas da literatura de referência (VALERO et al., 1994a), foi observado que os valores das variáveis dependentes e da função objetivo são similares a literatura, ou seja, possuem erro relativo extremamente baixo.

A partir da validação das modelagens termodinâmica e econômica, assim como do problema de otimização, a planta de cogeração foi otimizada utilizando o algoritmo genético (AG) do EES e o algoritmo de lobos cinzentos (GWO) programado externo ao EES. Verifica-se que o conjunto de valores ótimos para as variáveis de decisão e função objetivo obtido por ambos os métodos de otimização são bem próximos aos valores da literatura de referência. Sendo assim, os métodos de otimização (AG e GWO) utilizados neste trabalho mostram-se eficientes para a otimização de plantas de cogeração. Apesar do algoritmo de lobos cinzentos (GWO) possuir um tempo computacional maior do que o algoritmo genético (AG), observa-se que GWO se mostrou mais eficaz do que o AG para a solução do problema proposto, uma vez que o GWO possui um menor número de chamadas de função objetivo durante o processo de otimização. Desta forma, o GWO mostra-se promissor para otimização de plantas de cogeração, tanto do ponto de vista prático como acadêmico.

Após a realização deste trabalho, percebe-se que ainda há um campo muito amplo para a aplicação de técnicas de otimização em sistemas térmicos. Como perspectiva de trabalhos futuros, sugere-se desenvolver o problema de otimização para o estudo de caso proposto (Problema CGAM) considerando-se diferentes modelos físicos, tais

como modelo ar padrão, modelo ar padrão frio e modelo de combustão completa e utilizar o algoritmo de lobos cinzentos para solução do problema de otimização. Além disso, é recomendado aplicar o algoritmo de lobos cinzentos para otimização de sistemas térmicos mais complexos, os quais apresentam maior número de variáveis de decisão, ou para otimização de superestruturas de sistemas térmicos, ou seja, otimização estrutural e paramétrica de sistemas térmicos (configuração e parâmetros de projeto ótimos do sistema). Outra sugestão que pode ser levada em consideração é a utilização de novos métodos de otimização meta-heurísticos para a otimização de sistemas térmicos modelados em *software* comercial. Por fim, sugere-se o uso do algoritmo de lobos cinzentos para a solução de problemas de otimização multiobjetivos aplicados a sistemas térmicos.

## REFERÊNCIAS

- ABDULGADER, M.; LAKSHMINARAYANAN, S.; KAUR, D. ***Efficient Energy Management for Smart Homes with Grey Wolf Optimizer***. IEEE International Conference on Electro Information Technology (EIT), 2017.
- ABUSOGLU A, KANOGLU M. ***Exergoeconomic analysis and optimization of combined heat and power production: A review***. Renewable and Sustainable Energy Reviews 2009;13:2295–308. doi:10.1016/j.rser.2009.05.004.
- ALDACO, S. E. de L.; CALLEJA, H.; ALQUICIRA, J. A. ***Metaheuristic Optimization Methods Applied to Power Converters: A Review***. IEEE Trans. Power Electron, vol. 30, no. 12, pp. 6791–6803, Dec. 2015.
- ARAUJO, L. R. ***Análise Comparativa da Otimização de Sistemas de Cogeração Através de Um Método de Busca Direta e Um Estocástico Utilizando Superestrutura e Simulador de Processo***. Dissertação (Mestrado em Engenharia Mecânica). Universidade Federal do Espírito Santo. Vitória. 2008.
- ARAÚJO, L. R.; DONATELLI, J. L. M.; SILVA, E. A. C. ***Structural and Parametric Optimization of Cogeneration Power Plants Using Genetic Algorithm***. 22<sup>nd</sup> International Conference on Efficiency, Cost, Optimization Simulation and Environmental Impact of Energy Systems, 2009a.
- ARAÚJO, L. R.; DONATELLI, J. L. M.; SILVA, E. A. C. ***Comparative Analysis of Cogeneration Power Plants Optimization by a Direct Search and a Stochastic Method Using Superstructure and Process Simulator***. 20<sup>th</sup> International Congress of Mechanical Engineering, 2009b.
- ARAÚJO, L. R.; DONATELLI, J. L. M.; SILVA, E. A. C.; AZEVEDO, J. L. F. ***Comparative Analysis of Cogeneration Power Plants Optimization Based on Stochastic Methods Using Superstructure and Process Simulator***. 13<sup>th</sup> Brazilian Congress of Thermal Sciences and Engineering, 2010.
- ARAUJO, L. R.; MORAWSKI, A. P.; BARONE, M. A.; CHUN, A.; OLIVEIRA, R. C. L.; SCHIAFFINO, M. E. D. S.; CUNHA, C. C. M.; DONATELLI, J. L. M. ***Using Stochastic Methods***. 23<sup>rd</sup> ABCM International Congress of Mechanical Engineering 2015.
- ARAÚJO, L. R.; MORAWSKI, A. P.; BARONE, M. A.; DONATELLI, J. L. M.; SANTOS, J. J. C. S. ***On the effects of thermodynamic assumptions and thermoeconomic approaches for optimization and cost allocation in a gas turbine cogeneration system***. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2020.
- ARAÚJO, L. R. ***O Uso do Método de Superfície de Resposta na Otimização Termoeconômica de Superestruturas Modeladas em Software Comercial para Projeto de Sistemas de Recuperação de Calor Residual em Motores Diesel Estacionários***. Tese (Doutorado em Engenharia Mecânica). Universidade Federal do Espírito Santo, Vitória, 2020.

BAYGI, S. M. H.; ELAHI, A.; KARSAZ, A. ***A novel framework for optimal sizing of hybrid stand-alone renewable energy system: A Gray Wolf Optimizer***. 3rd Conference on Swarm Intelligence and Evolutionary Computation (CSIEC2018), Higher Education Complex of Bam, Iran, 2018.

BEJAN, A., TSATSARONIS, G., MORAN, M. ***Thermal Design and Optimization***. John Wiley & Sons, New York, EUA, 1996.

BEJAN, A., MAMUT, E. ***Thermodynamic Optimization of Complex Energy Systems***. Kluwer Academic Publishers, Holland, 1999.

CAMMARATA, G.; FICHERA, A.; MARLETTA, L. ***Using genetic algorithms and the exergonomic approach to optimize district heating networks***. J Energy Resour Technol, 1998.

CALISE, F.; DENTICE, D' ACCADIA M.; VANOLI, L.; VON SPAKOVSKY, M.R. ***Full load synthesis/design optimization of a hybrid SOFC-GT power plant***. Energy 2007;32:446–58. doi:10.1016/j.energy.2006.06.016.

CERQUEIRA, S. A. A. G. ***Metodologias de Análise Termoeconômica de Sistemas*** [in Portuguese]. Universidade Estadual de Campinas, 1999.

CHARBONNEAU, P.; KNAPP, B. ***Pikaia Optimization Program***. Disponível em: <<http://www.hao.ucar.edu/modeling/pikaia/pikaia.php>>. Acesso em: 21 de agosto de 2020.

CITTADINO, G. ***Otimização da Malha de Cogeração de Energia em Usina de Açúcar e Álcool***. 125f. Dissertação de mestrado – Universidade de São Paulo, São Paulo, 2017.

CORDEIRO, A.S.; VIEIRA, L.S.; CRUZ, M. E. ***Exergoeconomic optimization and improvement of a cogeneration system modeled in a process simulator using direct search and evolutionary methods***. International Journal of Energy & Environment 2011;2:463–76, 2011.

DIMOPOULOS, G. G.; FRANGOPOULOS, C. A. ***Optimization of energy systems based on evolutionary and social metaphors***. Energy 33:171–179, 2008.

DONATELLI, J. L. M.; 2002. ***Otimização Estrutural e Paramétrica de Sistemas de Cogeração Utilizando Superestruturas***. Tese (Doutorado em Engenharia Mecânica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil.

EL-SAYED, Y. M., 2003, ***The Thermoeconomics of Energy Conversions***, Elsevier, New York, EUA.

FLIN, D. ***Cogeneration: A User's Guide***. 1ª ed. Londres: IET, 2010.

FRANGOPOULOS, C. A. ***Application of the thermoeconomic functional approach to the CGAM problem***. Energy 1994;19:323–42. doi:10.1016/0360-5442(94)90114-7.



FRANGOPOULOS, C. A. **Cogeneration: Technologies, Optimisation and Implementation**. 1<sup>a</sup> ed. Londres: IET, 2017.

FRANGOPOULOS, C. A. **Methods of energy systems optimization**, Department of Naval Architecture and Marine Engineering 2003.

GOFFE, W. K.; FERRIER, G. D.; ROGERS, J. **Global optimization of statistical functions with simulated annealing**. J econom, 1994,

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence. Complex Adaptive Systems**. The MIT Press: 1975.

JALURIA, Y. **Design and Optimization of Thermal Systems**. McGraw-Hill, New York, EUA, 1998.

KAUR, R.; KRISHNASAMY, V.; KANDASAMY, N. K.; KUMAR, S. **Discrete Multiobjective Grey Wolf Algorithm Based Optimal Sizing and Sensitivity Analysis of PV-Wind-Battery System for Rural Telecom Towers**. IEEE Syst. J., vol. 14, no. 1, pp. 729–737, Mar. 2020.

KENNEDY, J.; EBERHART, R.C. **Particle swarm optimization**. In: Proceedings of the IEEE international conference on neural networks (ICNN) IV, Perth, Australia, 1995.

KOCH C, CZIESLA F, TSATSARONIS G. **Optimization of combined cycle power plants using evolutionary algorithms. Chemical Engineering and Processing: Process Intensification** 2007;46:1151–9. doi:10.1016/j.cep.2006.06.025, 2007.

LAZZARETTO, A.; TSATSARONIS, G.. **SPECO: A systematic and general methodology for calculating efficiencies and costs in thermal systems**. Energy 2006;31:1257–89. doi:10.1016/j.energy.2005.03.011.

LAKUM, A.; MAHAJAN, V. **Optimal Placement and Sizing of Multiple Active Power Filters for Radial Distribution System Using Grey Wolf Optimizer**. 7th International Conference on Power Systems (ICPS) College of Engineering Pune, India. Dec 21-23, 2017.

LI, Y.R.; DU, M.T.; WU, C.M.; WU, S.Y.; LIU, C.; XU, J.L. **Economical Evaluation and Optimization of Subcritical Organic Rankine Cycle Based on Temperature Matching Analysis**. Energy 68: 238-247, 2014.

LI, L. L.; ZHAO, X.; TSENG, M. L.; TAN, R. R. **Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm**. J. Clean. Prod., vol. 242, p. 118447, Jan. 2020.

LI, J.; LU, J.; YAO, L.; CHENG, L.; QIN, H. **Wind-Solar-Hydro power optimal scheduling model based on multi-objective dragonfly algorithm**. Energy Procedia, vol. 158, pp. 6217–6224, Feb. 2019.

MANOLAS, D. A.; FRANGOPOULOS, C.A.; GIALAMAS TP, TSAHALIS, D. T. **Operation optimization of an industrial cogeneration system by a genetic algorithm.** Energy Conversion and Management;38:1625–36. doi:10.1016/S0196-8904(96)00203-8, 1997.

MIRJALILI, S., MIRJALILI, S. M., LEWIS, A. **Grey Wolf Optimizer**, Elsevier, v. 69, pp. 46-61, 2014.

OLIVEIRA, Jorge Alexandre de; ALVES, Marcus Vinícius Resende Costa. **Utilizando Algoritmo Genético no Problema do Corte de Estoque Bidimensional Guilhotinado Restrito.** Revista Científica Multidisciplinar Núcleo do Conhecimento. Edição 06. Ano 02, Vol. 01. pp 161-227, Setembro de 2017. ISSN:2448-0959

PENONCELLO, S. G. **Thermal Energy Systems: Design and Analysis.** 1ª ed. Idaho: CRC, 2015.

PIRES, T. S.; CRUZ, M.E.; COLAÇO, M. J. **Response surface method applied to the thermoeconomic optimization of a complex cogeneration system modeled in a process simulator.** Energy 2013;52:44–54. doi:10.1016/j.energy.2012.12.049.

PRESS, W. H.; FLANNERY, B. P.; TEUKOLSKY, S. A.; VETTERLING, W. T. **Numerical recipes in FORTRAN 77: the art of scientific computing.** 2<sup>nd</sup> ed. New York: Cambridge University Press, 1992.

REN, H.; MA, Z.; LIN, W.; WANG, S.; LI, W. **Optimal design and size of a desiccant cooling system with onsite energy generation and thermal storage using a multilayer perceptron neural network and a genetic algorithm.** Energy 180: 598-608, 2019.

REZAIE, A.; TSATSARONIS, G.; HELLWIG, U. **Thermal design and optimization of a heat recovery steam generator in a combined-cycle power plant by applying a genetic algorithm.** Energy: Volume 168, 1 February 2019, Pages 346-357.

SAHOO, P. K. **Exergoeconomic analysis and optimization of a cogeneration system using evolutionary programming.** Applied Thermal Engineering 2008;28:1580–8. doi:10.1016/j.applthermaleng.2007.10.011, 2008.

SANTOS, R.G.; FARIA, P. R.; SANTOS, J.J.C.S. **The Effect of the Thermodynamic Models on The Results of Thermoeconomic Analysis Based on Cost Allocation in a Gas Turbine Cogeneration System.** Brazilian Congress of Thermal Sciences and Engineering, November, 2014a, Belém, PA, Brazil

SANTOS, R.G.; FARIA, P. R.; SANTOS, J. J. C. S.; SILVA, J. A. M.; DONATELLI J. L. M. **The effect of the thermodynamic models on the thermoeconomic results for cost allocation in a gas turbine cogeneration system.** Engenharia Térmica (Thermal Engineering) 2015;14:47–52.

SANTOS, R. G. **Avaliação dos Modelos Termodinâmicos e Abordagem da Alocação de CO<sub>2</sub> em Termoeconomia.** 161p. Dissertação (Mestrado em

Engenharia Mecânica) – Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2015.

SANTOS, M. I. C. dos. **Um Modelo para a Otimização da Cogeração de Calor e Eletricidade em uma Planta Industrial**. 98f. Dissertação de mestrado – Universidade de Minas Gerais, Belo Horizonte, 2014b.

SANTOS, J. J. C. S. **Optimization of the Waste Heat Recovery Superstructures for Large Stationary Diesel Engines**. In: ENCIT 2018 - Brazilian Congress of Thermal Sciences and Engineering, 2018, Águas de Lindóia - São Paulo. ENCIT 2018 - Brazilian Congress of Thermal Sciences and Engineering, 2018.

SAYYAADI H, BABAIE M, FARMANI MR. **Implementing of the multi-objective particle swarm optimizer and fuzzy decision-maker in exergetic, exergoeconomic and environmental optimization of a benchmark cogeneration system**. Energy 2011;36:4777–89. doi:10.1016/j.energy.2011.05.012.

SCIUBBA, E., MELLI, R., 1998, **Artificial Intelligence in Thermal Systems Design: Concepts and Applications**, Nova Science Publishers Inc., New York, EUA.

SEYYEDI, S. M.; AJAM, H.; FARAHAT, S. **Thermoenviromonic optimization of gas turbine cycles with air preheat**. Proc Inst Mech Eng Part A J Power Energy 225:12–23, 2011.

SÖRENSEN, K. **Metaheuristics-the metaphor exposed**. Int. Trans. Oper. Res., vol. 22, no. 1, pp. 3–18, Jan. 2015.

STORN, R.; PRICE, K. **Differential evolution – a simple and efficient adaptive scheme for global optimization over continuous spaces**. International Computer Science Instituto, Berkeley (CA), 1995.

TOFFOLO, A. **Evolutionary algorithms for multi-objective energetic and economic optimization in thermal system design**. Energy 2002;27:549–67. doi:10.1016/S0360-5442(02)00009-9, 2002.

TRIBUS, M., EVANS, R. M. **Optimum-Energy Technique for Determining Costs of Saline-Water Conversion**. American Water Works Association, Vol. 54, No. 12, pp. 1473 -1490, 1962.

VALERO, A., LOZANO, M. A., SERRA, L., et al., **“CGAM Problem: Definition and Conventional Solution”**, Energy, v. 19, nº 3, pp. 279–286, 1994a.

VALERO A, LOZANO M. A., SERRA L, TORRES C. **Application of the exergetic cost theory to the CGAM problem**. Energy 1994;19:365–81. doi:10.1016/0360-5442(94)90116-3, 1994b.

VALERO, A.; TORRES, C.; LERCH, F. **Structural theory and thermoeconomic diagnosis, part III: intrinsic and induced malfunctions**. In: Proceedings of ECOS'99, Tokyo, Japan, 1999.

VALERO, A. et al. ***On the thermoeconomic approach to the diagnosis of energy systems malfunctions. Part I: the TADEUS problem.*** Energy, v. 29, p. 1875-1887, 2004a.

VALERO A. ***Exergy accounting: Capabilities and drawbacks.*** Energy;31:164–80. doi:10.1016/j.energy.2004.04.054, 2006.

VIEIRA, L. S.; DONATELLI, J. L.; CRUZ, M.E. ***Mathematical exergoeconomic optimization of a complex cogeneration plant aided by a professional process simulator.*** Appl Therm Eng; 26(5-6):654-62, 2006.

VIEIRA, L. L.; MATT, C. F.; GUEDES, V. G.; CRUZ, M. E.; CASTELLÕES, F. V. ***Maximization of the Profit of a Complex Combined-Cycle Cogeneration Plant Using a Professional Process Simulator.*** ASME J Eng Gas Turbines Power, 2010.

VON SPAKOVSKY, M.R. ***Application of engineering functional analysis to the analysis and optimization of the CGAM problem.*** Energy; 19:343–64. doi:10.1016/0360-5442(94)90115-5, 1994.

YANG, Xin-She. ***Engineering optimization: an introduction with metaheuristic applications.*** John Wiley & Sons, 2010.

ZHU, Z.; ZHOU, X. ***An efficient evolutionary grey wolf optimizer for multi-objective flexible jobshop scheduling problem with hierarchical job precedence constraints.*** Computers & Industrial Engineering, 2020.

## APÊNDICE A – MODELAGEM TERMODINÂMICA DO PROBLEMA CGAM

Neste Apêndice são descritas as equações da modelagem termodinâmica do Problema CGAM (VALERO et al., 1994a).

- Compressor de ar:

$$T_2 = T_1 \left\{ 1 + \frac{1}{\eta_{CA}} \left[ \left( \frac{P_2}{P_1} \right)^{\frac{k_a-1}{k_a}} - 1 \right] \right\} \quad (\text{A.1})$$

$$\dot{W}_{CA} = \dot{m}_{ar} c_{P_{ar}} (T_2 - T_1) \quad (\text{A.2})$$

Onde:

$T_2$ : Temperatura na saída do compressor de ar [K].

$T_1$ : Temperatura na entrada do compressor de ar [K].

$P_2$ : Pressão na saída do compressor de ar [bar].

$P_1$ : Pressão na entrada do compressor de ar [bar].

$\dot{W}_{CA}$ : Potência do compressor de ar [kW].

$\dot{m}_{ar}$ : Vazão mássica de ar [kg/s].

- Câmara de combustão:

$$\dot{m}_{gases} = \dot{m}_{ar} + \dot{m}_{comb} \quad (\text{A.3})$$

$$\dot{m}_{ar} h_3 + \dot{m}_{comb} PCI_{comb} = \dot{m}_{gases} h_4 + \dot{Q}_{CC} \quad (\text{A.4})$$

$$\dot{Q}_{CC} = \dot{m}_{comb} PCI_{comb} (1 - \eta_{CC}) \quad (\text{A.5})$$

$$P_4 = P_3 (1 - \Delta P_{CC}) \quad (\text{A.6})$$

Onde:

$\dot{m}_{gases}$ : Vazão mássica dos gases da combustão [kg/s].

$\dot{m}_{comb}$ : Vazão mássica do combustível [kg/s].

$h_3$ : Entropia do ar na entrada da câmara de combustão [kJ/kg].

$h_4$ : Entropia do ar na saída da câmara de combustão [kJ/kg].

$\dot{Q}_{CC}$ : Taxa de calor perdido na câmara de combustão [kW].

$P_4$ : Pressão na saída da câmara de combustão [bar].

$P_3$ : Pressão na entrada da câmara de combustão [bar].

• Pré-aquecedor de ar:

$$\dot{m}_{ar} c_{P_{ar}} (T_3 - T_2) = \dot{m}_{gases} c_{P_{gases}} (T_5 - T_6) \quad (A.7)$$

$$P_3 = P_2 (1 - \Delta P_{a,PA}) \quad (A.8)$$

$$P_6 = P_5 (1 - \Delta P_{g,PA}) \quad (A.9)$$

Onde:

$T_5$ : Temperatura dos gases na entrada do pré-aquecedor de ar [K].

$T_6$ : Temperatura dos gases na saída do pré-aquecedor de ar [K].

$P_5$ : Pressão dos gases de combustão na entrada do pré-aquecedor [bar].

$P_6$ : Pressão dos gases de combustão na saída do pré-aquecedor [bar].

• Turbina a gás:

$$T_5 = T_4 \left\{ 1 - \eta_{TG} \left[ 1 - \left( \frac{P_4}{P_5} \right)^{\frac{1-k_g}{k_g}} \right] \right\} \quad (A.10)$$

$$\dot{W}_{TG} = \dot{m}_{gases} c_{P_{gases}} (T_4 - T_5) \quad (A.11)$$

Onde:

$\dot{W}_{TG}$ : Potência desenvolvida pela turbina a gás [kW].

• Caldeira de recuperação de calor:

$$T_{8P} = T_9 - \Delta T_a \quad (A.12)$$

$$\dot{m}_{gases} c_{P_{gases}} (T_6 - T_{7P}) = \dot{m}_{vapor} (h_9 - h_{8P}) \quad (A.13)$$

$$\Delta T_P = T_{7P} - T_9 > 0 \quad (A.14)$$

$$T_7 = T_6 - \frac{\dot{m}_{vapor} (h_9 - h_8)}{\dot{m}_{gases} c_{P_{gases}}} \quad (A.15)$$

$$P_0 = P_6 - (1 - \Delta P_{CR}) \quad (A.16)$$

$$h_9 - h_{8P} = 1956 \text{ kJ/kg} \quad (A.17)$$

$$h_9 - h_8 = 2690 \text{ kJ/kg} \quad (A.18)$$

Onde:

$T_9$ : Temperatura de saturação do vapor à pressão de saída da caldeira de recuperação de calor [K].

$T_{8P}$ : Temperatura na saída do pré-aquecedor da caldeira de recuperação de calor [K].

$T_{7P}$ : Temperatura dos gases de combustão após passar pelo evaporador da caldeira de recuperação de calor [K].

$h_9$ : Entalpia do vapor na saída da caldeira de recuperação de calor [kJ/kg].

$h_{8p}$ : Entalpia da água na saída do pré-aquecedor da caldeira de recuperação de calor [kJ/kg].

$h_8$ : Entalpia da água na entrada da caldeira de recuperação de calor [kJ/kg].

$\Delta T_p$ : Diferença de temperatura no *pinch point* da caldeira de recuperação de calor [K].



## APÊNDICE B - MODELAGEM ECONÔMICA DO PROBLEMA CGAM

Neste Apêndice são descritas as equações do custo de aquisição dos equipamentos utilizados na modelagem econômica do Problema CGAM (VALERO et al., 1994a).

- Compressor de ar:

$$Z_{CA} = \left( \frac{39,5 \dot{m}_{ar}}{0,9 - \eta_{CA}} \right) \left( \frac{P_2}{P_1} \right) \ln \left( \frac{P_2}{P_1} \right) \quad (B.1)$$

Onde:

$Z_{CA}$ : Custo de aquisição do compressor de ar [US\$].

- Câmara de combustão:

$$Z_{CC} = \left( \frac{25,6 \dot{m}_{ar}}{0,995 - \frac{P_4}{P_3}} \right) [1 + \exp(0,018T_4 - 26,4)] \quad (B.2)$$

Onde:

$Z_{CC}$ : Custo da câmara de combustão [US\$].

- Pré-aquecedor de ar:

$$Z_{PA} = 266,3 \left[ \frac{\dot{m}_{gases} (h_5 - h_6)}{0,018 \Delta TLM_{PA}} \right]^{0,6} \quad (B.3)$$

Onde:

$Z_{PA}$ : Custo de aquisição do pré-aquecedor de ar [US\$].

$h_5$ : Entalpia dos gases na entrada do pré-aquecedor de ar [kJ/kg].

$h_6$ : Entalpia dos gases na saída do pré-aquecedor de ar [kJ/kg].

$\Delta TLM_{PA}$ : Diferença de temperatura média logarítmica no pré-aquecedor de ar [K].

- Turbina a gás:

$$Z_{TG} = \left( \frac{266,3\dot{m}_{gases}}{0,92 - \eta_{TG}} \right) \ln \left( \frac{P_4}{P_5} \right) [1 + \exp(0,036T_4 - 54,4)] \quad (B.4)$$

Onde:

$Z_{TG}$ : Custo de aquisição da turbina a gás [US\$].

- Caldeira de recuperação de calor:

$$Z_{CR} = 3650 \left[ \left( \frac{\dot{Q}_{EC}}{\Delta TLM_{EC}} \right)^{0,8} + \left( \frac{\dot{Q}_{EV}}{\Delta TLM_{EV}} \right)^{0,8} \right] + 11820\dot{m}_{vapor} + 658\dot{m}_{gases}^{1,2} \quad (B.5)$$

Onde:

$Z_{CR}$ : Custo de aquisição da caldeira de recuperação de calor [US\$].

$\Delta TLM_{EC}$ : Diferença de temperatura média logarítmica no economizador [K].

$\Delta TLM_{EV}$ : Diferença de temperatura média logarítmica no evaporador [K].

$\dot{Q}_{EC}$ : Taxa de calor trocado no economizador da caldeira de recuperação de calor [kW].

$\dot{Q}_{EV}$ : Taxa de calor trocado no evaporador da caldeira de recuperação de calor [kW].