

**UNIVERSIDADE DO VALE DO RIO DOS SINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
NÍVEL MESTRADO**

CLEMAR TRENTIN OLIVEIRA

**OTIMIZAÇÃO DE UM TROCADOR DE CALOR CASCO E TUBOS UTILIZANDO
O ALGORITMO LOBO CINZENTO**

**SÃO LEOPOLDO
2018**

CLEMAR TRENTIN OLIVEIRA

OTIMIZAÇÃO DE UM TROCADOR DE CALOR CASCO E TUBOS UTILIZANDO O ALGORITMO LOBO CINZENTO

Dissertação de mestrado apresentado como pré-requisito parcial para a obtenção do título de Mestre em Engenharia Mecânica, pelo Programa de Pós-Graduação em Engenharia Mecânica da UNISINOS

Orientador: Profa. Dra. Jacqueline Biancon Copetti

Coorientador: Prof. Dr. Mario Henrique Macagnan

Banca Examinadora:

Prof. Dr. Paulo Roberto Wander (UNISINOS)
Prof. Dr. Luiz Alberto Oliveira Rocha (UNISINOS)
Profa. Dra. Maria Luiza Sperb Indrusiak (UFRGS)

SÃO LEOPOLDO
2018

O48o Oliveira, Clemar Trentin.
Otimização de um trocador de calor casco e tubos utilizando o algoritmo lobo cinzento / Clemar Trentin Oliveira. – 2018.
145 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Engenharia Mecânica, 2018.

"Orientador: Profa. Dra. Jacqueline Biancon Copetti ;
Coorientador: Prof. Dr. Mario Henrique Macagnan."

1. Trocador de calor casco e tubos. 2. Otimização. 3. Algoritmo lobo cinzento. I. Título.

CDU 621

AGRADECIMENTOS

Gostaria de agradecer de coração a minha querida mãe Antoninha de Lourdes Trentin Oliveira a meu Pai Camilo Tadeu da Silva Oliveira, (*in memoriam*) e a minha irmã Marluce Trentin Oliveira pelo apoio e compreensão durante esta caminhada.

A minha esposa Ana Claudia Lopes Tonetto e minha filha Helena Tonetto Trentin pelos momentos de compreensão, paciência e dedicação.

A Profa. Dra. Jacqueline Biancon Copetti, pela orientação, dedicação e compartilhamento de seu conhecimento durante toda a execução deste trabalho.

Ao Prof. Dr. Mario Henrique Macagnan, pela coorientação e dedicação à realização deste trabalho.

Por fim aos colegas de empresa, pela disposição na realização de trocas de turno para minha participação em atividades acadêmicas e aos colegas do PPGEM pelo apoio e amizade.

RESUMO

Neste trabalho, desenvolve-se uma nova abordagem de otimização do projeto de um trocador de calor casco e tubos. O algoritmo Otimizador por Lobo Cinzento (GWO) é aplicado para minimizar a função objetivo custo total do trocador de calor proposto. As variáveis de otimização adotadas são: número de passes nos tubos, diâmetro externo dos tubos, diâmetro interno do casco, espaçamento dos defletores e corte dos defletores. O método Bell-Delaware e o método de Kern são utilizados para calcular o coeficiente de transferência de calor e a perda de pressão para o lado do casco. Os resultados da otimização são comparados com o projeto original do trocador de calor e também com os resultados alcançados por outros algoritmos de otimização da literatura. Além disso, o algoritmo GWO é comparado com outras meta-heurísticas de otimização em três funções de teste distintas. Os resultados da comparação do algoritmo GWO nas funções de teste mostram um desempenho competitivo, comparado com o Algoritmo Genético, Otimização por Enxame de Partículas, algoritmo Evolução Diferencial e Algoritmo do Vaga-Lume. Os resultados da otimização do trocador de calor utilizando o método de Kern mostra um bom desempenho, com a redução do investimento de capital em 11,95%, 7,93%, 6,24%, 2,37% e 0,19% comparado ao projeto original, GA, ICA, PSO e GSA respectivamente. Além disso, o custo operacional total descontado foi menor que o projeto original e o restante das metaheurísticas exceto para o algoritmo GSA onde o algoritmo GWO obteve resultado 22,33 %, superior.

No geral, a redução combinada do investimento de capital e do custo operacional total descontado obtido pela aplicação do algoritmo GWO levaram a uma redução de custo total de 20,80%, 7,28%, 6,07% e 4,06% comparado ao projeto original, GA, ICA e PSO respectivamente.

Por fim, os resultados da otimização do trocador de calor utilizando o método Bell-Delaware comparado ao projeto original mostram desempenho satisfatório com redução do investimento de capital em 13,32%. O custo operacional total foi menor em 32,56%. Neste caso, a redução combinada do investimento de capital e do custo operacional total descontado com o GWO levaram a uma redução de custo total de 17,19%.

Palavras-chave: trocador de calor casco e tubos, otimização, algoritmo lobo cinzento.

ABSTRACT

In this work, a new approach to optimizing the design of a shell and tube heat exchanger is developed. The Grey Wolf Optimizer algorithm (GWO) is applied to minimize the objective total cost function of the proposed heat exchanger. The optimization variables adopted are: number of tubes passes, tube outside diameter, shell inside diameter, baffles spacing and baffle cut. The Bell-Delaware method and the Kern method are used to calculate the heat transfer coefficient and the pressure drop from the shell side. The results of the optimization are compared with the original design and with other optimization algorithms in the literature. In addition, the GWO algorithm is compared with other optimization meta-heuristics in three different test functions. The results of the comparison of the GWO algorithm in the test functions show a competitive performance compared to the Genetic Algorithm, Particle Swarm Optimization, Differential Evolution algorithm and Firefly Algorithm. Already, the results of the optimization of the heat exchanger using the Kern method shows a good performance, with the reduction of capital investment by 11.95%, 7.93%, 6.24%, 2.37% and 0.19% compared to the original project, GA, ICA, PSO and GSA, respectively. In addition, the total discounted operating cost was lower than the original project and the rest of the metaheuristics except for the GSA algorithm where the GWO algorithm obtained 22.33% higher result.

Overall, the combined reduction in capital investment and total discounted operating cost obtained by applying the GWO algorithm led to a total cost reduction of 20.80%, 7.28%, 6.07% and 4.06% compared to the original project, GA, ICA and PSO, respectively.

Finally, the results of optimization of the heat exchanger using the Bell-Delaware method compared to the original design show satisfactory performance with reduction of capital investment by 13.32 %. The total discounted operating cost was lower by 32.56%. In this case, the combined reduction in capital investment and discounted total operating cost obtained by applying the GWO algorithm led to a total cost reduction of 17.19%.

Key-words: shell and tube heat exchanger, optimization, grey wolf algorithm.

LISTA DE FIGURAS

Figura 1.1 – Número de publicações do algoritmo GWO por editora.	22
Figura 1.2 – Aplicação do algoritmo GWO.	22
Figura 2.1 – Partes principais de um trocador de calor casco e tubos.	25
Figura 2.2 – Classificação de trocadores de calor casco tubos conforme TEMA.	26
Figura 2.3 – Tipos de defletores.	27
Figura 2.4 – Efeito do corte de defletores.	28
Figura 2.5 – Padrões de arranjo de tubos.	28
Figura 2.6 – Métodos de cálculo para o lado do casco.	29
Figura 2.7 – Divisão das correntes de escoamento conforme método de Tinker.	30
Figura 2.8 – Corrente de vazamento A.	30
Figura 2.9 – Corrente de vazamento C.	31
Figura 2.10 – Corrente de vazamento E.	31
Figura 2.11 – Trocador de calor tipo TEMA E: (a) seção de fluxo cruzado, (b) seção de janelas e (c) seção de fluxo cruzado na entrada e saída.	35
Figura 2.12 - Folga entre o casco e defletor.	36
Figura 2.13 - Ângulos e diâmetros característicos.	37
Figura 2.14 – Função descontínua (a) e função multimodal (b).	40
Figura 2.15 – Meta-heurísticas baseadas em população.	42
Figura 2.16 – Divisão do processo de busca do algoritmo GWO.	43
Figura 2.17 - Fluxograma do Algoritmo Genético (GA).	44
Figura 2.18 - Fluxograma do algoritmo enxame de partículas (PSO).	45
Figura 2.19 - Fluxograma do algoritmo evolução diferencial (DE).	46
Figura 2.20 - Fluxograma do algoritmo colônia artificial de abelhas (ABC).	47
Figura 2.21 - Fluxograma do algoritmo competitivo imperialista (ICA).	48
Figura 2.22 - Fluxograma do algoritmo do vaga-lume (FFA).	50
Figura 2.23 - Fluxograma do algoritmo baseado na biogeografia (BBO).	51
Figura 2.24 - Fluxograma do algoritmo de busca gravitacional.	52
Figura 2.25 - Fluxograma do algoritmo busca por cuco (CSA).	53
Figura 2.26 – Hierarquia do lobo cinzento (dominância diminui de cima para baixo).	54
Figura 2.27 – Comportamento de caça de lobos cinzentos.	55
Figura 2.28 – Vetor de posição bidimensional da presa e alguns de seus possíveis locais.	56
Figura 2.29 – Vetor de posição tridimensional da presa e alguns de seus possíveis locais.	57

Figura 2.30 – Atualização da posição do algoritmo GWO.	58
Figura 2.31 – Lobos atacam em direção a presa.....	59
Figura 2.32 – Lobos procuram por presas.	60
Figura 2.33- Pseudocódigo do algoritmo lobo cinzento.....	60
Figura 2.34 – Fluxograma do algoritmo lobo cinzento.	61
Figura 3.1 – Etapas da metodologia.	66
Figura 3.2 - Função de Rosenbrock.....	67
Figura 3.3 - Função de Griewank.	68
Figura 3.4 - Função de Ackley.	69
Figura 3.5 – Fluxograma do procedimento de projeto ideal de trocadores de calor.	75
Figura 3.6 - Geometria do trocador de calor casco e tubos tipo TEMA E.....	77
Figura 3.7 - Primeira linha executável de um arquivo de função.....	78
Figura 3.8 - Descrição das variáveis de entrada no <i>New Script</i> do MATLAB®.	79
Figura 3.9 - Interface do algoritmo GWO.	80
Figura 4.1 -Curvas de convergência das meta-heurísticas para a <i>função de Rosenbrock</i>	86
Figura 4.2 - Comparação das meta-heurísticas para a <i>função de Rosenbrock</i>	87
Figura 4.3 - Curvas de convergência das meta-heurísticas para a <i>função de Griewank</i>	88
Figura 4.4 - Comparação das meta-heurísticas para a <i>função de Griewank</i>	89
Figura 4.5 - Curvas de convergência das meta-heurísticas para a <i>função de Ackley</i>	90
Figura 4.6 - Comparação das meta-heurísticas para a <i>função de Ackley</i>	91
Figura 4.7 – Curvas de convergência do algoritmo GWO para o método de Kern.....	93
Figura 4.8 – Resultados ótimos das variáveis de otimização.	93
Figura 4.9 - Histórico de busca do algoritmo GWO para o método de Kern.....	94
Figura 4.10 - Número total de tubos segundo cada meta-heurística.	96
Figura 4.11- Coeficiente de transferência de calor do lado dos tubos de cada meta-heurística.	97
Figura 4.12 – Coeficiente de transferência de calor do lado do casco de cada meta-heurística.	98
Figura 4.13 – Área de troca térmica e coeficiente global de transferência de calor de cada meta-heurística.....	99
Figura 4.14 – Perda de pressão do lado dos tubos de cada meta-heurística.	100
Figura 4.15 – Perda de pressão do lado do casco de cada meta-heurística.	101
Figura 4.16 – Custo total de cada meta-heurística.....	102
Figura 4.17 – Estratégia de otimização adotada pelo algoritmo GWO.....	103

Figura 4.18 – Número de iterações para convergência de cada meta-heurística.....	104
Figura 4.19 - Curvas de convergência do algoritmo GWO para o método Bell-Delaware....	104
Figura 4.20 - Resultados ótimos das variáveis de otimização.....	105
Figura 4.21 - Curvas de convergência da função objetivo para diferentes números de passes nos tubos.	106
Figura 4.22 - Curvas de convergência da função objetivo para diferentes diâmetros externos dos tubos.	106
Figura 4.23 - Histórico de busca do algoritmo GWO para o método de Bell-Delaware.....	107
Figura 4.24 - Curvas de convergência da função objetivo para diferentes velocidades do fluido do lado dos tubos.	109
Figura 4.25 - Resultados do fator de correção total na transferência de calor.	110
Figura 4.26 – Comparação do custo total.	112
Figura A.1 - Propriedades geométricas para tubos de trocadores de calor casco e tubos.	125
Figura A.2 – Constantes empíricas para o cálculo do coeficiente de transferência de calor e perda de pressão para o lado do casco.	128

LISTA DE TABELAS

Tabela 3.1 – Parâmetros de entrada para o algoritmo genético - GA.....	70
Tabela 3.2 – Parâmetros de entrada para o algoritmo enxame de partículas - PSO.....	71
Tabela 3.3 – Parâmetros de entrada para o algoritmo evolução diferencial - DE.	72
Tabela 3.4 - Parâmetros de entrada para o algoritmo do vaga-lume - FFA.	73
Tabela 3.5 - Parâmetros de entrada para o algoritmo otimizador por lobo cinzento - GWO...	73
Tabela 3.6 – Variáveis de otimização para cada programa computacional.....	74
Tabela 3.7 – Geometria do trocador de calor proposto.	78
Tabela 3.8 – Respostas do algoritmo de otimização.	81
Tabela 3.9 – Variáveis de otimização e dados de entrada para o método de Kern.	83
Tabela 3.10 - Variáveis de otimização e dados de entrada para o método Bell-Delaware.	84
Tabela 4.1 - Comparação das meta-heurísticas para a <i>função de Rosenbrock</i>	87
Tabela 4.2 - Comparação das meta-heurísticas para a <i>função de Griewank</i>	89
Tabela 4.3 - Comparação das meta-heurísticas para a <i>função de Ackley</i>	91
Tabela 4.4 – Resultados para o projeto original e as meta-heurísticas GA, ICA, PSO, ABC, BBO, GSA, CSA, DE, FFA e GWO.	95
Tabela 4.5 - Resultados do projeto original e do algoritmo GWO.....	108
Tabela B.1 - Simulações utilizando o método de Kern.	133
Tabela B.2 - Simulações utilizando o método de Kern.	134
Tabela B.3 - Simulações utilizando o método de Kern.	135
Tabela B.4 - Simulações utilizando o método Bell-Delaware.....	136
Tabela B.5 - Simulações utilizando o método Bell-Delaware.....	137
Tabela B.6 - Simulações utilizando o método Bell-Delaware.....	138
Tabela B.7 - Simulações utilizando o método Bell-Delaware.....	139
Tabela B.8 - Simulações utilizando o método Bell-Delaware.....	140
Tabela B.9 - Simulações utilizando o método Bell-Delaware.....	141
Tabela B.10 - Simulações utilizando o método Bell-Delaware.....	142

LISTA DE SIGLAS

ABC	Colônia Artificial de Abelhas (<i>Artificial Bee Colony</i>)
BBO	Otimização Baseada em Biogeografia (<i>Biogeography Based Optimization</i>)
BWG	<i>Birmingham Wire Gage</i>
CSA	Algoritmo Busca por Cuco (<i>Cuckoo Search Algorithm</i>)
DE	Algoritmo Evolução Diferencial (<i>Differential Evolution</i>)
FFA	Algoritmo do Vaga-Lume (<i>Firefly Algorithm</i>)
GA	Algoritmo Genético (<i>Genetic Algorithm</i>)
GWO	Otimizador por Lobo Cinzento (<i>Grey Wolf Optimizer</i>)
GSA	Algoritmo de Busca Gravitacional (<i>Gravitational Search Algorithm</i>)
ICA	Algoritmo Competitivo Imperialista (<i>Imperialist Competitive Algorithm</i>)
PSO	Otimização por Enxame de Partículas (<i>Particle Swarm Optimization</i>)
HTRI	<i>Heat Transfer Research Institute</i>
TEMA	<i>Tubular Exchanger Manufacturers Association</i>

LISTA DE SIMBOLOS

A	área de troca térmica [m ²]
A_{obp}	área de <i>by-pass</i> para o fluxo cruzado [m ²]
A_{ocr}	área de fluxo cruzado entre defletores [m ²]
A_{frit}	área ocupada pelos tubos na janela do defletor [m ²]
A_{frw}	área total da janela do defletor [m ²]
A_{osb}	área de vazamento entre o casco e o defletor [m ²]
A_{otb}	área de vazamento entre o tubo e o defletor [m ²]
A_{ow}	área de fluxo na janela do defletor [m ²]
\vec{A}	vetor de coeficiente [-]
\vec{c}	vetor que decresce em um intervalo determinado durante as iterações [-]
a_1	constante empírica para o cálculo do coeficiente de transferência de calor ideal para o lado do casco [-]
a_2	constante empírica para o cálculo do coeficiente de transferência de calor ideal para o lado do casco [-]
a_3	constante empírica para o cálculo do coeficiente de transferência de calor ideal para o lado do casco [-]
a_4	constante empírica para o cálculo do coeficiente de transferência de calor ideal para o lado do casco [-]
b_1	constante empírica para o cálculo da perda de pressão ideal para o lado do casco [-]
b_2	constante empírica para o cálculo da perda de pressão ideal para o lado do casco [-]
b_3	constante empírica para o cálculo da perda de pressão ideal para o lado do casco [-]
b_4	constante empírica para o cálculo da perda de pressão ideal para o lado do casco [-]
B_c	corte dos defletores segmentados [%]
C	folga entre os tubos adjacentes [m]
\vec{C}	vetor de coeficiente [-]
C_1	parâmetro social para o algoritmo PSO [-]
C_2	parâmetro cognitivo para o algoritmo PSO [-]

C_p	calor específico dos fluidos [J/(kg K)]
C_{p_s}	calor específico do fluido do lado do casco [J/(kg K)]
C_{p_t}	calor específico do fluido do lado dos tubos [J/(kg K)]
C_e	custo da energia [€/kWh]
C_i	investimento de capital [€]
C_o	custo anual de operação [€]
C_{od}	custo operacional total descontado [€]
CR	constante de <i>crossover</i> para o algoritmo DE [-]
C_{tot}	custo total [€]
D	número de dimensões [-]
\bar{D}	distância entre o lobo e a presa [-]
d_e	diâmetro equivalente do casco [m]
d_i	diâmetro interno dos tubos [m]
d_o	diâmetro externo dos tubos [m]
D_{ctl}	diâmetro do círculo formado pelo centro dos tubos mais externos do feixe [m]
D_h	diâmetro equivalente da janela de um defletor [m]
D_s	diâmetro interno do casco [m]
D_{otl}	diâmetro do círculo circunscrito aos tubos mais externos do feixe de tubos [m]
F_c	fração total de tubos em uma seção de fluxo cruzado [-]
f_1	constante que depende do tipo de material [-]
f_2	constante que depende do tipo de material [-]
f_3	constante que depende do tipo de material [-]
$F_{máx}$	fator de escala de mutação máximo para o algoritmo DE [-]
$F_{mín}$	fator de escala de mutação mínimo para o algoritmo DE [-]
f_s	fator de atrito para o lado do casco [-]
f_t	fator de atrito para o lado dos tubos [-]
F_w	fração de tubos na janela do defletor [-]
G_s	velocidade mássica do fluido do lado do casco [kg/(m ² s)]
G_t	velocidade mássica do fluido do lado do tubo [kg/(m ² s)]
G_w	velocidade mássica considerando a média geométrica da área de fluxo cruzado e a área de fluxo na janela do defletor [kg/(m ² s)]
H	tempo de operação anual [h]
h_{id}	coeficiente de transferência de calor ideal [W/(m ² K)]

h_t	coeficiente de transferência de calor do lado dos tubos [W/(m ² K)]
h_s	coeficiente de transferência de calor do lado do casco [W/(m ² K)]
I	intensidade de luz para o algoritmo FFA [-]
i	taxa de desconto anual [%]
J_{id}	fator para o cálculo do coeficiente de transferência de calor ideal sobre um feixe de tubos [-]
J_c	fator de correção devido aos efeitos da configuração dos defletores [-]
J_l	fator de correção devido aos efeitos de vazamento nos defletores [-]
J_b	fator de correção devido aos efeitos de <i>by-pass</i> no feixe de tubos [-]
J_s	fator de correção para o espaçamento entre defletores na entrada e/ou saída [-]
J_r	fator de correção para o gradiente de temperatura adverso no fluxo laminar [-]
J_{total}	fator de correção total na transferência de calor para o fluido do casco [-]
k	condutividade térmica dos fluidos [W/(m K)]
k_s	condutividade térmica do fluido do lado do casco [W/(m K)]
k_t	condutividade térmica do fluido do lado dos tubos [W/(m K)]
L	comprimento dos tubos [m]
l_c	altura da janela [m]
L_{bc}	espaçamento dos defletores centrais [m]
L_{bi}	espaçamento dos defletores na entrada do casco [m]
L_{bo}	espaçamento dos defletores na saída do casco [m]
\dot{m}	vazão mássica dos fluidos [kg/s]
\dot{m}_s	vazão mássica do fluido do lado do casco [kg/s]
\dot{m}_t	vazão mássica do fluido do lado dos tubos [kg/s]
n	número de passes nos tubos [-]
N_b	número de defletores [-]
N_p	número de divisores de passes no espelho estacionário [-]
NP	tamanho da população para o algoritmo DE [-]
N_{ss}	número de pares de tiras de selagem [-]
N_{ss}^+	razão entre o número de pares de tiras de selagem e o número de fileiras de tubos entre dois cortes de defletores [-]
N_t	número de tubos [-]
N_{tw}	número de tubos na seção da janela do defletor [-]
Nu	número de Nusselt [-]

Nu_s	número de Nusselt para o lado do casco [-]
Nu_t	número de Nusselt para o lado dos tubos [-]
N_{rc}	número total de fileiras de tubos cruzadas através de uma seção defletores [-]
N_{rcw}	número de fileiras de tubos no escoamento cruzado em cada janela defletor [-]
N_{rcc}	número de fileiras de tubos entre dois cortes do defletor [-]
n_y	vida útil do equipamento [ano]
P	potência de bombeamento [W]
P_t	passo tubular [m]
Pr	número de Prandtl [-]
Pr_s	número de Prandtl para o lado do casco [-]
Pr_t	número de Prandtl para o lado dos tubos [-]
r_1	valores aleatórios em um intervalo determinado [-]
r_2	valores aleatórios em um intervalo determinado [-]
R_b	razão de <i>by-pass</i> para a área de fluxo cruzado [-]
Re	número de Reynolds [-]
Re_s	número de Reynolds do lado do casco [-]
Re_t	número de Reynolds do lado dos tubos [-]
R_f	resistência à incrustação dos fluidos [m ² K/W]
R_{lm}	razão entre as áreas de vazamento e a área de fluxo cruzado [-]
R_s	razão da área de vazamento casco defletor e a soma das áreas de vazamento [-]
t	iteração corrente [-]
T_i	temperatura dos fluidos na entrada [°C]
T_o	temperatura dos fluidos na saída [°C]
U	coeficiente global de transferência de calor [W/(m ² K)]
w	fator inercial para o algoritmo PSO [-]
W_p	divisão interna do espelho [m]
$w_{máx}$	fator inercial máximo para o algoritmo PSO [-]
$w_{mín}$	fator inercial mínimo para o algoritmo PSO [-]
X_l	passo longitudinal dos tubos [m]
X_t	passo transversal dos tubos [m]
\vec{X}	vetor posição de um lobo [-]
$\vec{X}_p(t)$	vetor posição de uma presa [-]

Símbolos Gregos

α	solução de melhor aptidão [-]
α_r	parâmetro de randomização para o algoritmo FFA [-]
β	segunda solução de melhor aptidão [-]
β_f	atratividade mínima para o algoritmo FFA [-]
γ	coeficiente de absorção de luz para o algoritmo FFA [-]
δ	terceira solução de melhor aptidão [-]
δ_{bb}	folga entre casco e feixe de tubos [m]
δ_{sb}	folga entre casco e defletor [m]
δ_{tb}	folga entre tubo e defletor [m]
η	eficiência da bomba [-]
μ	viscosidade dos fluidos [Pa.s]
μ_s	viscosidade do fluido do lado do casco [Pa.s]
μ_t	viscosidade do fluido do lado dos tubos [Pa.s]
μ_w	viscosidade dos fluidos à temperatura de parede [Pa.s]
μ_{ws}	viscosidade do fluido à temperatura de parede do lado do casco [Pa.s]
μ_m	viscosidade média do fluido do lado do casco [Pa.s]
μ_{wt}	viscosidade do fluido à temperatura de parede do lado dos tubos [Pa.s]
θ_b	ângulo central formado pela interseção do corte do defletor com o D_s [°]
θ_{ctl}	ângulo formado pela interseção do corte do defletor com o diâmetro D_{ctl} [°]
ρ	massa específica [kg/m ³]
ρ_s	massa específica do fluido do lado do casco [kg/m ³]
ρ_t	massa específica do fluido do lado dos tubos [kg/m ³]
v_t	velocidade do fluido nos tubos [m/s]
v_s	velocidade do fluido no lado do casco [m/s]
ζ_b	fator de correção para efeitos de <i>by-pass</i> [-]
ζ_l	fator de correção para efeitos de vazamento [-]
ζ_s	fator de correção para seção de entrada e saída com espaçamento dos defletores diferentes dos defletores centrais [-]
$\Delta P_{b,id}$	perda de pressão referente ao fluxo cruzado ideal entre dois defletores [Pa]
ΔP_{cr}	perda de pressão na seção central (fluxo cruzado) [Pa]
ΔP_{i-o}	perda de pressão nas seções de entrada e saída do trocador de calor [Pa]

ΔP_s	perda de pressão do lado do casco [Pa]
ΔP_t	perda de pressão do lado dos tubos [Pa]
ΔP_w	perda de pressão na seção das janelas dos defletores [Pa]
$\Delta P_{w,id}$	perda de pressão ideal nas janelas dos defletores [Pa]
ω	restante das soluções candidatas [-]

SUMÁRIO

1 INTRODUÇÃO.....	19
1.1 OBJETIVOS.....	21
1.1.1 Objetivo Geral	21
1.1.2 Objetivos Específicos.....	21
1.2 JUSTIFICATIVA	21
1.3 ESTRUTURA DA PESQUISA.....	23
2 FUNDAMENTAÇÃO TEÓRICA.....	25
2.1 TROCADORES DE CALOR CASCO E TUBOS.....	25
2.1.1 Características	25
2.1.2 Métodos de cálculo para o lado do casco	29
2.1.2.1 Método Kern.....	32
2.1.2.2 Método Bell-Delaware.....	34
2.1.3 Cálculo para o lado dos tubos	37
2.2 ALGORITMOS META-HEURÍSTICOS	40
2.2.1 Algoritmo Genético – GA	43
2.2.2 Algoritmo Enxame de Partículas – PSO	45
2.2.3 Algoritmo Evolução Diferencial - DE.....	46
2.2.4 Algoritmo Colônia Artificial de Abelhas - ABC.....	47
2.2.5 Algoritmo Competitivo Imperialista – ICA	48
2.2.6 Algoritmo do Vaga-Lume - FFA.....	49
2.2.7 Algoritmo Baseado na Biogeografia - BBO	50
2.2.8 Algoritmo de Busca Gravitacional - GSA	51
2.2.9 Algoritmo Busca por Cuco - CSA.....	52
2.3 ALGORITMO LOBO CINZENTO	54
2.3.1 Modelo matemático e algoritmo.....	55
2.3.1.1 Hierarquia social.....	55
2.3.1.2 Cercando a presa.....	55
2.3.1.3 Caçando	57
2.3.1.4 Atacar presas.....	59
2.3.1.5 Busca por presas	59
2.4 REVISÃO BIBLIOGRÁFICA – ESTADO DA ARTE.....	62
3 MATERIAIS E MÉTODOS	66

3.1 FUNÇÕES DE TESTE.....	66
3.2 DEFINIÇÃO DE PARÂMETROS DAS META-HEURÍSTICAS.....	69
3.3 OTIMIZAÇÃO E FUNÇÃO OBJETIVO.....	73
3.4 TROCADOR DE CALOR PROPOSTO.....	76
3.5 CONSTRUÇÃO DO PROGRAMA COMPUTACIONAL E INTERFACE DO ALGORITMO GWO.....	78
3.5.1 Métodos para a análise do casco	81
3.5.1.1 Detalhamento para simulação utilizando o método de Kern	82
3.5.1.2 Detalhamento para simulação utilizando o método Bell-Delaware.....	83
4 RESULTADOS E DISCUSSÃO.....	86
4.1 COMPARAÇÃO DO DESEMPENHO DO ALGORITMO GWO	86
4.2 OTIMIZAÇÃO DO TROCADOR DE CALOR - MÉTODO DE KERN	92
4.3 OTIMIZAÇÃO DO TROCADOR DE CALOR - MÉTODO BELL DELAWARE	104
5 CONCLUSÕES.....	113
5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS.....	115
REFERÊNCIAS.....	116
APÊNDICE A – DESCRIÇÃO DETALHADA DO MÉTODO BELL-DELAWARE....	122
APÊNDICE B – RESULTADOS DAS SIMULAÇÕES.....	133
APÊNDICE C – DESENHO DO TROCADOR DE CALOR OBTIDO PELO ALGORITMO GWO.....	143

1 INTRODUÇÃO

Os trocadores de calor do tipo casco e tubos são amplamente utilizados para aquecimento e resfriamento, em refinarias de petróleo e processamento químico, dentre outras. Permitem a operação em uma ampla faixa de temperaturas e pressões, além de apresentarem facilidade de manutenção e confiabilidade.

O projeto convencional de um trocador de calor muitas vezes depende da experiência do projetista. Geralmente uma configuração geométrica de referência do equipamento é escolhida e um valor de perda de pressão admissível é fixado. Então os valores das variáveis são definidos nas especificações de projeto, assim como a suposição de alguns parâmetros como comprimento dos tubos, limitado pelo espaço físico e considerando montagem e manutenção, e o coeficiente global de transferência de calor, afim de obter a utilização apropriada da superfície de troca térmica.

As definições de projeto são então verificadas com base em procedimentos iterativos envolvendo muitos testes até que um projeto razoável seja obtido, sendo que este deve atender as especificações de projeto como perda de pressão e desempenho de troca térmica. Embora bem comprovado este tipo de abordagem é demorado e não garante uma solução ótima. Considerando a importância funcional e a utilização generalizada de trocadores de calor casco e tubos, seu projeto visando o custo mínimo é considerado um objetivo importante. Em particular a minimização do custo relacionado com a energia (perdas de bombeamento) é fundamental na visão de conservação de recursos naturais. O crescente apelo pela sustentabilidade de processos, incentiva o desenvolvimento de equipamentos e sistemas mais eficientes mediante a otimização.

Segundo Lopes e Takahashi (2011), nas últimas décadas, pesquisadores desenvolveram novas abordagens para o problema de otimização, tendo como inspiração os mecanismos de adaptação biológica existentes na natureza. Foram desenvolvidos novos algoritmos evolutivos e também algoritmos baseados na inteligência por enxame. Tais algoritmos têm apresentado excelentes resultados resolvendo problemas de projeto de engenharia. Atualmente, estes algoritmos constituem um conjunto de ferramentas que se associam a praticamente todo projeto de sistemas de “alta tecnologia”.

Devido ao papel importante dos trocadores de calor casco e tubos, uma variedade de técnicas foram propostas ao problema de otimização do projeto nos últimos anos. A metodologia de inteligência artificial, especificamente as meta-heurísticas, têm sido utilizadas extensivamente para obter o projeto ótimo. Alguns pesquisadores utilizaram os algoritmos

genéticos (GAs) para otimização do equipamento. Além destes algoritmos pode ser destacado também: otimização por enxame de partículas (PSO), colônia artificial de abelhas (ABC), evolução diferencial (DE), otimização baseada em biogeografia (BBO), algoritmo busca por cuco (CSA), algoritmo do vaga-lume (FFA), algoritmo de busca gravitacional (GSA), algoritmo competitivo imperialista (ICA), dentre outros.

No entanto, é necessário investigar o potencial de aplicação de técnicas de otimização não tradicionais. A meta-heurística Otimizador por Lobo Cinzento (GWO, do inglês *Grey Wolf Optimizer*) é uma destas técnicas e será investigada neste trabalho para verificar seu desempenho comparando seus resultados com outras meta-heurísticas. Este algoritmo é uma técnica nova no âmbito da inteligência por enxame proposta por Mirjalili *et al.* (2014), e foi baseado no comportamento de caça e hierarquia social dos lobos cinzentos. Segundo Song *et al.* (2015), a meta-heurística GWO é um algoritmo bastante simples e isto favorece seu entendimento e aplicação por pesquisadores de diferentes áreas do conhecimento. Este algoritmo possui mecanismo de livre derivação. Em contraste com as abordagens de otimização baseadas em gradiente, o algoritmo GWO otimiza os problemas de forma estocástica. Pode ser usado em problemas onde as funções objetivo são descontínuas ou não diferenciáveis. Finalmente, este algoritmo possui habilidades superiores para evitar ótimos locais em comparação com técnicas de otimização convencionais. Assim, esta meta-heurística é adequada para resolver problemas de otimização de funções não lineares, multivariadas e multimodais.

A fim de contribuir para a solução do problema de projeto ótimo para trocadores de calor casco e tubos do ponto de vista econômico, este trabalho aborda a implementação deste novo método computacional de inteligência por enxame. O algoritmo GWO avalia a função objetivo custo total de projeto e atualiza as variáveis de otimização a fim de gerar um novo desenho do trocador de calor, obtendo a cada nova iteração um novo valor para a função objetivo. São considerados diferentes métodos de cálculo para o lado do casco, além de tratar o problema com e sem restrições geométricas.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

O objetivo geral deste trabalho é minimizar o custo total de um trocador de calor casco e tubos utilizando o algoritmo Otimizador por Lobo Cinzento, GWO, tendo como variáveis os parâmetros geométricos de projeto: número de passes nos tubos, diâmetro externo dos tubos, diâmetro interno do casco, espaçamento entre os defletores e corte dos defletores.

1.1.2 Objetivos Específicos

- Comparar o desempenho do algoritmo GWO com relação às meta-heurísticas GA, PSO, DE e FFA em três funções de teste;
- Implementar o algoritmo GWO na otimização de um trocador de calor casco e tubos sem restrições geométricas utilizando o método Kern;
- Implementar o algoritmo GWO na otimização de um trocador de calor casco e tubos com restrições geométricas e utilizando o método Bell-Delaware;
- Comparar os resultados das simulações com o projeto original e também com outras meta-heurísticas da literatura.

1.2 JUSTIFICATIVA

O algoritmo Otimizador por Lobo Cinzento (GWO) é um dos métodos de inteligência por enxame recentemente desenvolvido. Ele vem sendo utilizado em uma ampla variedade de problemas de otimização por apresentar um desempenho competitivo e muitas vezes superior em relação a outros métodos de inteligência por enxame (FARIS *et al.*, 2017). A Fig. (1.1) mostra o número de publicações por editora que abordam o algoritmo GWO no período de 2014 a 2017.

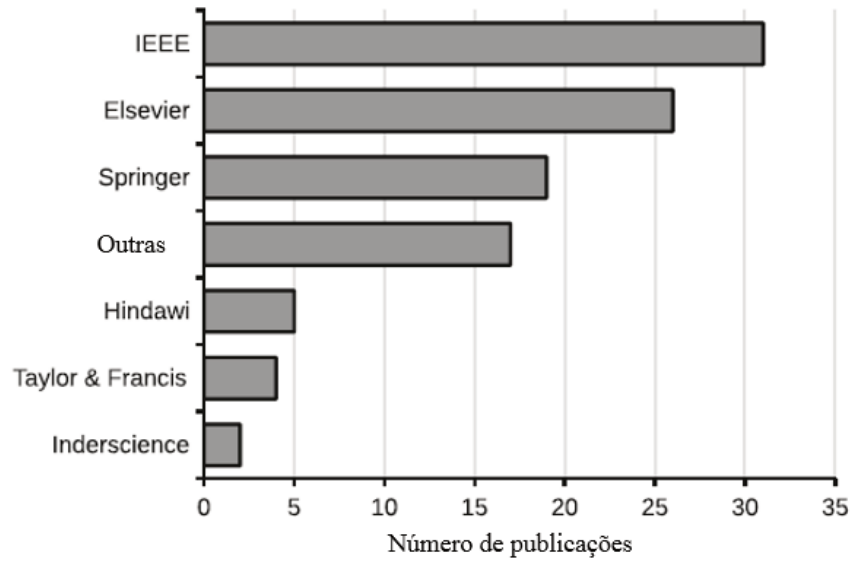


Figura 1.1 – Número de publicações do algoritmo GWO por editora.

Fonte: Adaptado de Faris *et al.* (2017).

A Fig. (1.2) mostra a distribuição dessas publicações com base no tipo de aplicação.

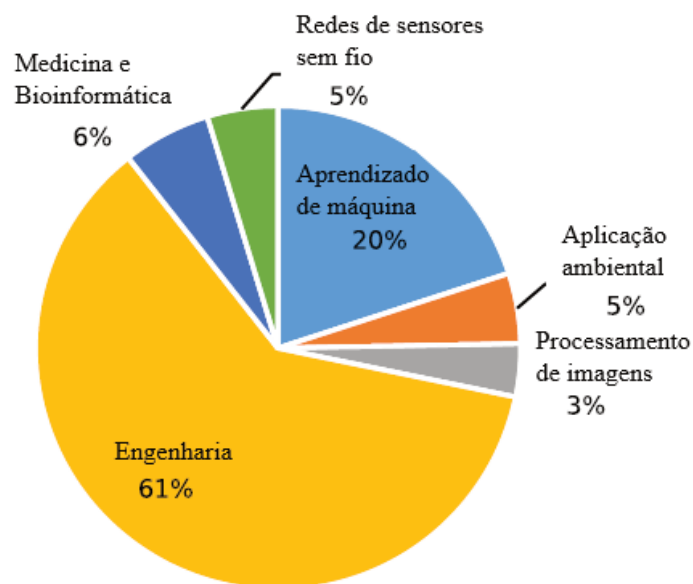


Figura 1.2 – Aplicação do algoritmo GWO.

Fonte: Adaptado de Faris *et al.* (2017).

Este algoritmo vem sendo usado com êxito em diversas aplicações da engenharia tais como: Otimização do despacho econômico de uma usina de energia elétrica (Nascimento, 2016), otimização de controladores PI - proporcional e Integral (Pinto, 2016), treinamento de redes neurais artificiais (Hassanin *et al.*, 2016), planejamento do caminho ótimo de veículo

aéreo de combate não tripulado (Zhang *et al.*, 2016), alocação de controladores FACTS – *Flexible Alternate Current Transmission System* (Reis, 2017), classificação da qualidade do ar ambiente (Saxena e Shekhawat, 2017), dentre outros.

Considerando a versatilidade desta nova meta-heurística, esta dissertação aborda sua implementação na otimização do projeto de um trocador de calor casco e tubos.

Inicialmente o GWO é comparado com as meta-heurísticas bem conhecidas e que já possuem resultados em otimização do projeto de trocadores de calor casco e tubos com o objetivo de avaliar seu desempenho. Um bom resultado do GWO nas funções de teste comparado aos algoritmos GA, PSO, DE e FFA trará evidências de que esta meta-heurística terá resultados satisfatórios na otimização do projeto de trocadores de calor casco e tubos. No entanto, não se pode ter certeza, pois de acordo com o teorema da inexistência do almoço grátis (*No-free-Lunch Theorem*, ou NFL) nenhum algoritmo de otimização é capaz de resolver todos os problemas de otimização. Além disso, as simulações nas funções de teste servem para avaliar os parâmetros de ajuste do algoritmo e seus efeitos na otimização.

As simulações utilizando o método de Kern, sem restrições geométricas, tem o objetivo de avaliar o projeto de forma preliminar, além de comparar os resultados de otimização com os resultados de nove diferentes meta-heurísticas apresentadas em trabalhos anteriores onde este método também foi aplicado.

Por fim, as simulações utilizando o método de Bell-Delaware com restrições geométricas tem o objetivo de otimizar o trocador de calor respeitando algumas das limitações impostas pela norma TEMA. Além disso, este método fornece resultados mais precisos do coeficiente de transferência de calor e perda de pressão para o lado do casco.

1.3 ESTRUTURA DA PESQUISA

No capítulo 2 são apresentadas as características dos trocadores de calor casco e tubos considerando a norma TEMA e o histórico da evolução do método de cálculo para o lado do casco. São descritos também os algoritmos que foram selecionados para serem comparados com o desempenho do algoritmo GWO na otimização do projeto de um trocador de calor casco e tubos. Em seguida, é apresentado o algoritmo Otimizador por Lobo Cinzento GWO considerando sua inspiração natural e o modelo matemático. Por fim, é apresentado o estado da arte em otimização de projeto de trocadores de calor casco e tubos que utilizaram diferentes ferramentas (meta-heurísticas) considerando a metodologia adotada e os principais resultados encontrados.

No capítulo 3 são apresentados os detalhes da rotina de otimização e especificada a função objetivo. Além disso, é detalhada a metodologia desenvolvida para realização dos testes de desempenho do algoritmo GWO com outras meta-heurísticas em três funções de teste e detalhado o trocador de calor casco e tubos proposto. Por fim, é apresentada a construção do programa e a interface do algoritmo GWO. São definidos também todos os detalhes para realização das simulações.

No capítulo 4 são apresentados os resultados obtidos através das simulações e discussões.

No capítulo 5 são apresentadas as conclusões e também sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 TROCADORES DE CALOR CASCO E TUBOS

2.1.1 Características

Trocadores de calor casco e tubos são os mais comuns e empregados na indústria de processos, representando mais de 65 %, em relação a outros tipos de trocadores. Seu uso generalizado pode ser justificado pela sua versatilidade, robustez e confiabilidade. São construídos basicamente de um feixe de tubos e um casco. Um dos fluidos circula pelo interior do feixe de tubos e o outro fluido circula pela parte externa, sobre o feixe de tubos, que está envolvido por um casco.

Conforme Fig. (2.1), as partes principais de um trocador de calor casco e tubos são: casco (1), feixe de tubos (2), espelho (3), defletores (4), carretel (5), tampa do carretel (6), tampo do casco (7), bocais de entrada e saída do fluido dos tubos (8) e bocais de entrada e saída do fluido do casco (9).




Figura 2.1 – Partes principais de um trocador de calor casco e tubos.

Fonte: Adaptado de Kakaç et al. (2012).

A norma TEMA classificou diversos tipos de cabeçotes dianteiros e traseiros e tipos de casco conforme mostra a Fig. (2.2). Assim, os trocadores de calor casco e tubos são classificados de acordo com três letras que correspondem às partes: tipo de cabeçote dianteiro ou estacionário (A, B, C, N, D), tipo de casco (E, F, H, J, K, X), tipo de cabeçote traseiro ou de retorno (L, M, N, P, S, T, U, W). Ainda, a norma divide os trocadores de calor casco e tubos em três classes distintas (R, C e B) que devem ser selecionadas de acordo com a necessidade específica de cada projeto, sendo a classe R a mais restritiva (serviços mais severos) e a classe B a menos restritiva (serviços com menor severidade).




Figura 2.2 – Classificação de trocadores de calor casco tubos conforme TEMA.

Fonte: Adaptado de TEMA (2007).

A partir desta classificação uma grande quantidade de combinações de extremidades e cascos podem ser utilizadas, tais como: AES, AKT, AJW, BEM, AEP, CFU.

Os defletores citados anteriormente têm as funções de suportar o feixe de tubos, dando rigidez estrutural e evitando a vibração induzida pelo escoamento, promover o escoamento

cruzado do fluido, aumentar o tempo de residência e gerar uma certa turbulência, aumentando o coeficiente de transferência de calor. Os defletores podem ser classificados como tipos transversais e longitudinais. Os defletores transversais podem ser classificados como defletores de placas e de haste (KAKAÇ *et al.*, 2012). A Fig. (2.3) mostra os defletores de placas mais utilizados. As placas possuem cortes, definindo uma janela de escoamento do fluido do casco. Esta janela pode ter de 15 a 45% do diâmetro do casco para defletores segmentados simples (SERTH, 2007), no entanto, o recomendado é de 20 a 35 %. Cortes muito pequenos ou muito grandes prejudicam a eficiência da transferência de calor do lado do casco, devido ao grande desvio de uma situação ideal de escoamento cruzado, conforme mostra a Fig. (2.4).

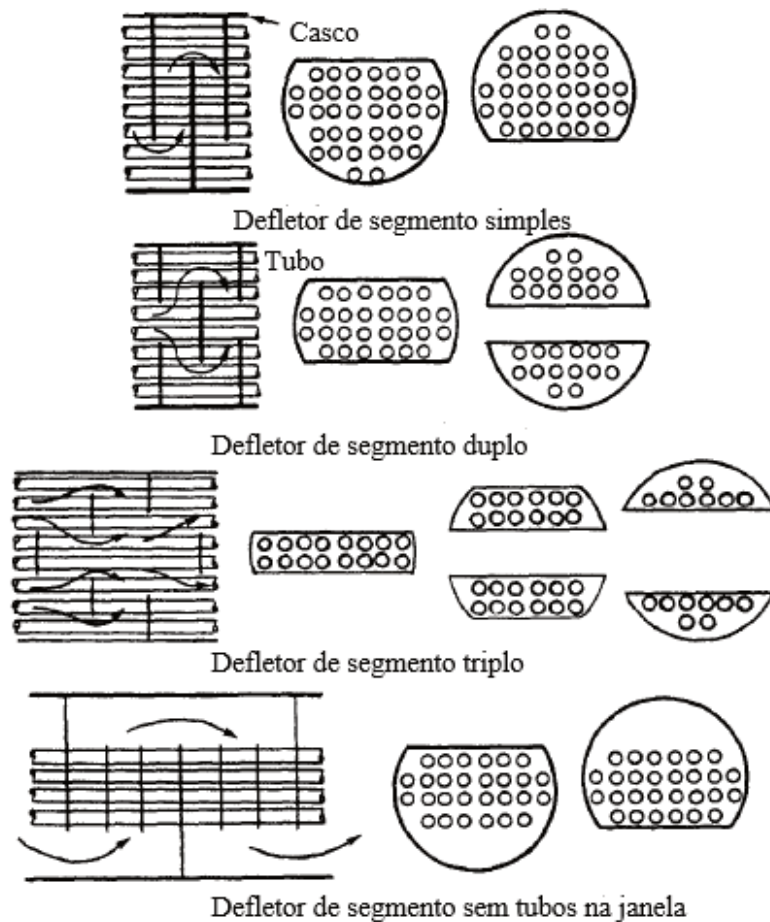


Figura 2.3 – Tipos de defletores.

Fonte: Adaptado de Kakaç *et al.* (2012).

Reduzir o corte dos defletores abaixo de 20 %, para aumentar o coeficiente de transferência e calor do lado do casco, ou aumentar o corte de defletores acima de 35 %, para diminuir a perda de pressão do lado do casco, geralmente levam a projetos inadequados (MUKHERJEE, 1988).




Figura 2.4 – Efeito do corte de defletores.

Fonte: Adaptado de Mukherjee (1988).

Para defletores segmentados duplos ou triplos o valor deve ser de 20 a 30 % do diâmetro do casco (SAUNDERS, 1983).

Conforme a norma TEMA (2007), os tubos podem ser arranjados conforme quatro padrões distintos, como pode ser visto na Fig. (2.5). Esta norma recomenda que o padrão triangular e triangular girado não devem ser aplicados a equipamentos que necessitem de limpeza mecânica do lado do casco ou seja, este padrão é apropriado para fluidos limpos.




Figura 2.5 – Padrões de arranjo de tubos.

Fonte: Adaptado de TEMA (2007).

Os tubos devem estar espaçados com uma distância mínima de centro a centro, ou passo, de 1,25 vezes o diâmetro externo do tubo. Para diâmetro dos tubos de 5/8" (15,9 mm) ou menores, a distância de centro a centro pode ser reduzida para 1,20 vezes o diâmetro externo do tubo. O comprimento e diâmetro dos tubos podem ser utilizados em tamanhos padronizados e a espessura da parede dos tubos é geralmente selecionada com base no custo, margem para corrosão e padronização.

De modo geral os trocadores de calor de tubos retos podem ter qualquer número de passes nos tubos: um, dois, quatro, seis e oito passes são os mais comuns. Um trocador de calor com

tubo tipo “U” deve ter um número par de passes nos tubos, sendo dois e quatro passes os mais usuais (SAUNDERS, 1983).

2.1.2 Métodos de cálculo para o lado do casco

Tendo em vista a complexidade do escoamento do fluido do lado do casco de trocadores de calor casco e tubos, devido aos defletores, alguns métodos de cálculo foram sugeridos para avaliar a transferência de calor e a perda de pressão.

Estes métodos são divididos em quatro grupos conforme mostra a Fig. (2.6).

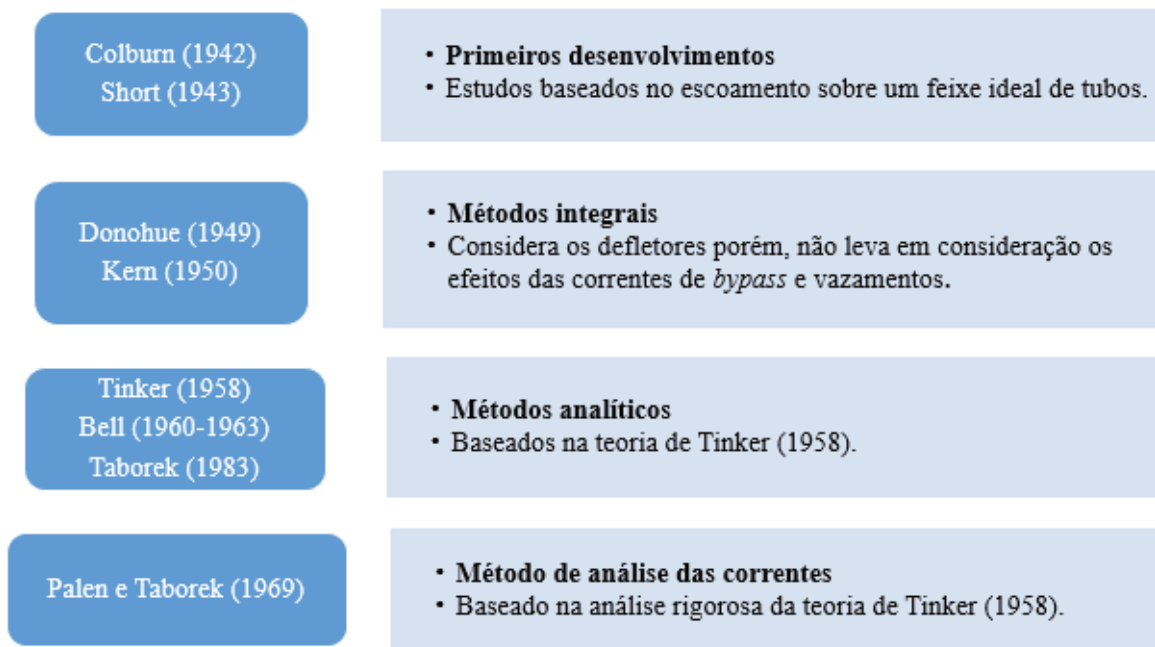


Figura 2.6 – Métodos de cálculo para o lado do casco.

Fonte: Elaborado pelo autor.

Os primeiros desenvolvimentos tiveram início na década de 1930 onde surgiram os primeiros estudos sobre a transferência de calor e perda de pressão para o lado do casco de trocadores de calor casco e tubos, porém não foram considerados os defletores. Estes estudos consideravam o escoamento do fluido sobre um feixe ideal de tubos, ou seja, os tubos ocupando completamente o casco de uma forma uniforme.

Os métodos integrais analisam o escoamento do lado do casco de forma simples sem considerar os efeitos de correntes de vazamento e *bypass* que ocorrem devido as folgas existentes entre o casco e defletor e tubos e defletor. Geralmente estes métodos geram resultados excessivos de perda de pressão. O método proposto por Kern, publicado em 1950,

foi utilizado como um padrão industrial por muitos anos. Neste método tanto a transferência de calor como perda de pressão são calculados com corte de defletores fixo em 25 %.

Os métodos analíticos iniciaram pelo método proposto por Tinker (1958), que sugeriu um modelo onde o escoamento é dividido em frações de fluxo A, B, C, E e F conforme mostra a Fig. (2.7).




Figura 2.7 – Divisão das correntes de escoamento conforme método de Tinker.

Fonte: Thome (2004).

- Corrente A: representa o escoamento nas folgas existentes entre tubos e defletores, conforme mostra a Fig. (2.8).




Figura 2.8 – Corrente de vazamento A.

Fonte: Adaptado de Thome (2004).

- Corrente B: fração do escoamento que faz todo o percurso ideal (escoamento cruzado), conforme mostra a Fig. (2.7).
- Corrente C: perdas no espaço entre os tubos mais externos e o casco, conforme mostra a Fig. (2.9). Estas perdas podem ser reduzidas com a instalação de tiras de selagem, que direcionam o escoamento de volta para o feixe de tubos.

- Corrente E: perdas entre a extremidade do defletor e a parede interna do casco, conforme mostra a Fig. (2.10).
- Corrente F: perdas nas folgas do próprio feixe de tubos, devido à presença de divisões internas, conforme indicado na Fig. (2.7).

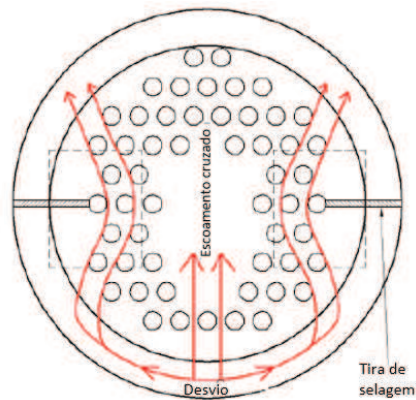


Figura 2.9 – Corrente de vazamento C.

Fonte: Adaptado de Thome (2004).



Figura 2.10 – Corrente de vazamento E.

Fonte: Adaptado de Thome (2004).

A análise original foi considerada complexa e difícil de entender. Além disso, os cálculos iterativos eram demorados e os recursos computacionais da época eram limitados. Desta forma a alternativa adotada foi a simplificação do método.

Bell formulou um método de cálculo na Universidade de Delaware, o qual foi publicado em um relatório preliminar em 1960 e em 1963 no relatório final. Em 1986, o autor publicou uma nova versão do método. Este método é considerado o melhor para projeto, sendo o mais adequado para aplicações gerais de engenharia entre os métodos disponíveis na literatura aberta.

O método citado é não iterativo e baseado nos princípios do modelo de distribuição de correntes de Tinker, utilizando fatores de correção para calcular a perda de pressão total e o coeficiente de transferência de calor. Geralmente o resultado da perda de pressão total do lado do casco calculado por este método permanece em um valor aproximado de 20 a 30 % da perda de pressão total calculada pelos métodos integrais (KAKAÇ *et al.*, 2012).

Taborek (1983) propôs uma nova versão do método Bell para o escoamento monofásico com defletores segmentados simples, para o casco tipo E, sendo posteriormente descritas as modificações dos modelos para os tipos J e F (Fig. 2.2) sem tubos nas janelas dos defletores (THOME, 2004).

Palen e Taborek (1969), juntamente com a empresa de desenvolvimento e pesquisa HTRI (*Heat Transfer Research Inc.*), propuseram uma metodologia baseada na análise das correntes de Tinker e, utilizando um extenso banco de dados experimentais, foram ajustadas correlações. Estas pesquisas evoluíram e deram origem ao desenvolvimento de *softwares* comerciais, com uso também de CFD (*Computational Fluid Dynamics*). Os *softwares* vêm sendo atualizados regularmente usando novos dados de pesquisa, e são amplamente reconhecidos como o padrão da indústria para o projeto, classificação e simulação de equipamentos de transferência de calor, incluindo trocadores de casco e tubo e não-tubulares, refrigeradores de ar e economizadores, conjuntos de recuperação de calor, aquecedores e outros. No entanto, estes programas são orientados para aplicações e empresas, não estando disponíveis na literatura aberta (SERTH, 2007).

2.1.2.1 Método Kern

O método Kern (1987) foi baseado em trabalhos experimentais em trocadores de calor industriais com tolerâncias padrão e corte dos defletores fixo em 25 % fornecendo resultados razoavelmente satisfatórios de coeficiente de transferência de calor e perda de pressão para o lado do casco, pois não levam em consideração os efeitos de vazamento e *bypass* ocasionados pelas folgas que o equipamento possui. A análise do lado do casco se baseia em características do escoamento do fluido e fatores geométricos tais como: diâmetro externo dos tubos, espaçamento entre defletores, arranjo de tubos e espaço livre entre os tubos.

Este método considera a área máxima de escoamento cruzado a fileira de tubos central do casco e o espaçamento entre defletores, já que não existe uma área de escoamento bem definida, pois a mesma varia através do diâmetro do feixe de tubos, ou seja, a cada fileira

longitudinal de tubos há um número diferente de tubos ocasionando um número diferente de passagens entre os tubos. Assim, a área de escoamento do casco é dada por:

$$A_s = \frac{D_s L_{bc} C}{P_t} \quad (2.1)$$

onde, D_s é o diâmetro interno do casco, L_{bc} é o espaçamento entre os defletores, C é a folga entre os tubos adjacentes e P_t é o passo tubular.

O número de Nusselt, Nu_s , é dado por uma correlação como função de Reynolds, Re_s , e Prandtl, Pr_s , conforme McAdams (1942), e válida para Re_s , de 2000 a 1×10^6 . O número de Reynolds é calculado de acordo com a Eq. (2.2):

$$Re_s = \frac{G_s de}{\mu_s} \quad (2.2)$$

e

$$G_s = \frac{\dot{m}_s}{A_s} \quad (2.3)$$

onde, G_s é a velocidade mássica do fluido, de é o diâmetro equivalente, μ_s é a viscosidade do fluido e \dot{m}_s é a vazão mássica do fluido do lado do casco.

O diâmetro equivalente (ou hidráulico), de , depende do arranjo de tubos. Para um arranjo de tubos triangular é dado por:

$$de = \frac{4 \left[0,43 P_t^2 - 0,5 \left(\frac{\pi}{4} d_o^2 \right) \right]}{0,5 \pi d_o} \quad (2.4)$$

onde, d_o é o diâmetro externo dos tubos.

Para um arranjo quadrado é:

$$de = \frac{4 \left[P_t^2 - \left(\frac{\pi}{4} d_o^2 \right) \right]}{\pi d_o} \quad (2.5)$$

O número de Prandtl para o fluido do lado do casco é dado por:

$$\text{Pr}_s = \frac{\mu_s \dot{C}p_s}{k_s} \quad (2.6)$$

onde, Cp_s é o calor específico e k_s é a condutividade térmica.

Assim, a correlação de Nusselt é dada pela seguinte correlação:

$$\text{Nu}_s = 0,36 \text{Re}_s^{0,55} \text{Pr}_s^{0,33} \left(\frac{\mu_s}{\mu_{ws}} \right)^{0,14} \quad (2.7)$$

onde, μ_{ws} é a viscosidade do fluido à temperatura de parede.

E de acordo com o Nu_s , o coeficiente de transferência de calor, h_s , é dado por:

$$\text{Nu}_s = \frac{h_s d_e}{k_s} \quad (2.8)$$

A perda de pressão por atrito no lado do casco, é dada por:

$$\Delta P_s = \frac{f_s G_s^2 (N_b + 1) D_s}{2 \rho_s d_e \left(\frac{\mu_s}{\mu_{ws}} \right)^{0,14}} \quad (2.9)$$

e

$$f_s = \exp(0,576 - 0,19 \ln \text{Re}_s), \quad 400 < \text{Re}_s \leq 1 \times 10^6 \quad (2.10)$$

onde, f_s é o fator de atrito, ρ_s é a massa específica do fluido e, N_b é o número de defletores.

2.1.2.2 Método Bell-Delaware

O método Bell-Delaware baseia-se em calcular o coeficiente de transferência de calor e a perda de pressão do escoamento transversal aos tubos e das janelas dos defletores para um escoamento diferente do ideal. Neste método o escoamento ideal (representado pela corrente B

do método de Tinker, conforme Fig. (2.7), é ajustado por fatores de correção determinados experimentalmente.

Assim, o coeficiente de transferência de calor para o lado do casco é dado por:

$$h_s = h_{id} J_c J_l J_b J_s J_r \quad (2.11)$$

onde, h_{id} é o coeficiente de transferência de calor ideal e os fatores de correção são: J_c devido aos efeitos da configuração dos defletores, J_l devido aos efeitos de vazamento nos defletores, J_b devido aos efeitos de *by-pass* no feixe de tubos, J_s para o espaçamento entre defletores diferente na entrada e/ou saída e J_r para o gradiente de temperatura adverso no escoamento laminar.

A perda de pressão total do lado do casco é a soma da perda de pressão associada com cada seção de escoamento cruzado entre defletores, a perda de pressão associada a cada seção de janela e a perda de pressão para seções de escoamento cruzado em cada extremidade entre o primeiro e o último defletor conforme mostra a Fig. (2.11) (SHAH e SEKULIC, 2003).

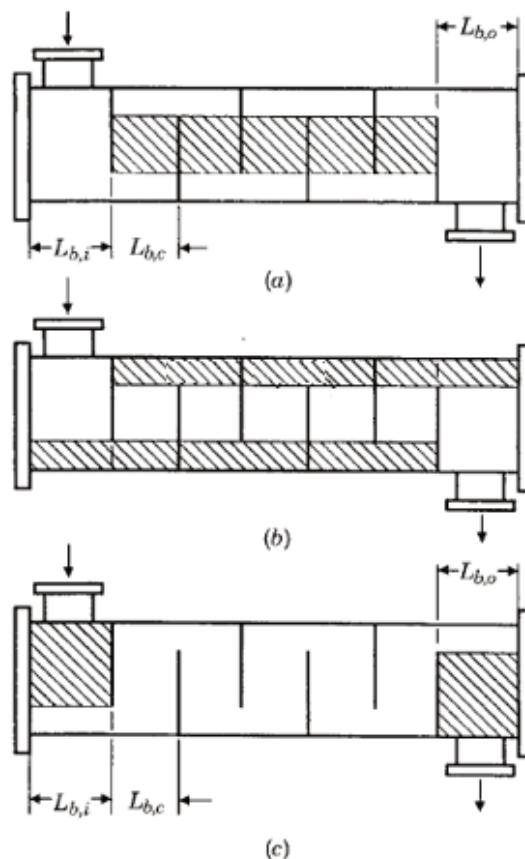


Figura 2.11 – Trocador de calor tipo TEMA E: (a) seção de fluxo cruzado, (b) seção de janelas e (c) seção de fluxo cruzado na entrada e saída.

Fonte: Shah e Sekulic, 2003.

Assim, a perda de pressão total para o lado do casco é dada por:

$$\Delta P_s = [(N_b - 1)\Delta P_{b,id}\zeta_b + N_b\Delta P_{w,id}]\zeta_l + 2\Delta P_{b,id}\left(1 + \frac{N_{r,cw}}{N_{r,cc}}\right)\zeta_b\zeta_s \quad (2.12)$$

onde, N_b é o número de defletores, $\Delta P_{b,id}$ é a perda de pressão referente ao escoamento cruzado ideal entre dois defletores, ζ_b é o fator de correção para efeitos de *by-pass*, $\Delta P_{w,id}$ é a perda de pressão ideal nas janelas dos defletores, ζ_l é o fator de correção para efeitos de vazamento, $N_{r,cw}$ é o número de fileiras reais de escoamento cruzado em cada janela do defletor e $N_{r,cc}$ é o número de fileiras de tubos entre dois cortes do defletor e ζ_s é o fator de correção para seção de entrada e saída com espaçamento dos defletores diferentes dos defletores centrais.

O projeto de trocadores de calor casco e tubos possuem folgas que devem ser conhecidas e consideradas, pois as mesmas são responsáveis pelo surgimento de correntes de vazamento e de *bypass* que por sua vez afetam a transferência de calor.

- Folga entre casco e defletor (δ_{sb}) representado pela corrente E do método de Tinker conforme a Fig. (2.12): esta folga segundo a norma TEMA é função do diâmetro interno do casco (D_s) e é dada por:

$$\delta_{sb} = 2 \text{ mm}, \quad D_s < 400 \text{ mm} \quad (2.13)$$

$$\delta_{sb} = 1,6 + 0,004D_s, \quad D_s \geq 400 \text{ mm} \quad (2.14)$$




Figura 2.12 - Folga entre o casco e defletor.

Fonte: Shah e Sekulic, 2003.

- Folga entre tubo e defletor (δ_{tb}) representado pela corrente A do método de Tinker: esta folga segundo a norma TEMA é função do diâmetro externo do tubo (d_o) e é dada por:

$$0,01d_o \leq \delta_{tb} \leq 0,1d_o \quad (2.15)$$

- Folga entre casco e feixe de tubos (δ_{bb}) representado pela corrente C do método de Tinker: esta folga depende do tipo de feixe utilizado, é calculada pelo diâmetro interno do casco e o diâmetro do círculo circunscrito aos tubos mais externos do feixe (D_{otl}). A Fig. (2.13) mostra os ângulos e diâmetros característicos.

$$\delta_{bb} = D_s - D_{otl} \quad (2.16)$$




Figura 2.13 - Ângulos e diâmetros característicos.

Fonte: Shah e Sekulic, 2003.

A descrição completa do método Bell-Delaware está no apêndice A.

2.1.3 Cálculo para o lado dos tubos

A transferência de calor e a perda de pressão nos tubos podem ser determinadas por diversas correlações que depende do regime de escoamento do fluido que escoar através dos tubos. Este escoamento pode ser laminar, em transição ou turbulento.

A caracterização do escoamento no interior dos tubos é definida pelo número de Reynolds, Re_t , conforme Eq. (2.17).

$$\text{Re}_t = \frac{G_t d_i}{\mu_t} \quad (2.17)$$

onde

$$G_t = \frac{\dot{m}_t}{A_t} \quad (2.18)$$

e

$$A_t = \frac{\pi d_i^2}{4} \frac{N_t}{n} \quad (2.19)$$

onde, G_t é a velocidade mássica do fluido do lado dos tubos, \dot{m}_t é a vazão mássica do fluido do lado dos tubos, d_i é o diâmetro interno dos tubos, μ_t é a viscosidade, N_t é o número de tubos e n é o número de passes nos tubos.

Para um regime de escoamento laminar completamente desenvolvido no interior dos tubos lisos o fator de atrito, f_t , é dado pela Eq. (2.20).

$$f_t = \frac{64}{\text{Re}_t}, \quad \text{Re}_t \leq 2300 \quad (2.20)$$

A correlação para o fator de atrito para o regime de escoamento transição-turbulento é proposta por Petukhov (1970).

$$f_t = (1,82 \log_{10} \text{Re}_t - 1,64)^{-2}, \quad 3000 < \text{Re}_t < 5 \times 10^6 \quad (2.21)$$

A correlação para o número de Nusselt, Nu_t , conforme Stephan e PreuBer (1979) para regime de escoamento laminar em desenvolvimento é válida para ($\text{Re}_t \leq 2300$ e $0,7 < \text{Pr}_t < 7$) e dada por:

$$Nu_t = 3,657 + \frac{0,0677 \left(\text{Re}_t \text{Pr}_t \frac{d_i}{L} \right)^{1,33}}{1 + 0,1 \text{Pr}_t \left(\text{Re}_t \frac{d_i}{L} \right)^{0,3}} \quad (2.22)$$

Para regime de escoamento transição-turbulento uma correlação para o número de Nusselt é proposta por Gnielinski (1976) para $3000 < Re_t < 5 \times 10^6$ e $0,5 \leq Pr_t \leq 2000$, e é dada por:

$$Nu_t = \frac{\left(\frac{f_t}{8}\right)(Re_t - 1000) Pr_t}{1 + 12,7 \sqrt{\frac{f_t}{8}} (Pr_t^{0,67} - 1)} \quad (2.23)$$

onde, Pr_t é o número de Prandtl para o fluido no interior dos tubos.

Para regime de escoamento turbulento e plenamente desenvolvido, Sieder e Tate (1936) propuseram uma correlação para o número de Nusselt válida para $Re_t \geq 10000$, $0,7 \leq Pr_t \leq 16.700$ e $L/D \geq 10$, dada por:

$$Nu_t = 0,027 Re_t^{0,8} Pr_t^{0,33} \left(\frac{\mu_t}{\mu_{wt}}\right)^{0,14} \quad (2.24)$$

onde μ_{wt} é a viscosidade do fluido na temperatura da parede do tubo.

Assim o coeficiente de transferência de calor para o lado dos tubos é calculado por:

$$Nu_t = \frac{h_t d_i}{k_t} \quad (2.25)$$

onde, h_t é o coeficiente de transferência de calor e k_t é a condutividade térmica do fluido.

A perda de pressão para o fluido que percorre os passes do lado dos tubos é calculada pela Eq. (2.26), que considera também a perda no retorno do fluido.

$$\Delta P_t = \frac{G_t^2}{2\rho_t} \left(f_t \frac{L}{d_i} + 4 \right) n \quad (2.26)$$

onde, L é o comprimento dos tubos e n é o número de passes nos tubos.

2.2 ALGORITMOS META-HEURÍSTICOS

Em problemas de engenharia, não-linearidades, descontinuidades e interações complexas entre variáveis de projeto e variáveis operacionais formam um espaço de busca que pode conter diversas soluções ótimas. Tendo em vista a possibilidade de encontrar máximos e mínimos locais (soluções sub-ótimas), os métodos de otimização baseados em gradiente podem não ser bons candidatos como algoritmos de otimização, quando aplicados a uma ampla gama de projetos de engenharia (SERAPIÃO, 2009). A função objetivo pode apresentar um comportamento complexo, como mostra a Fig. (2.14) (SMITH, 2005).

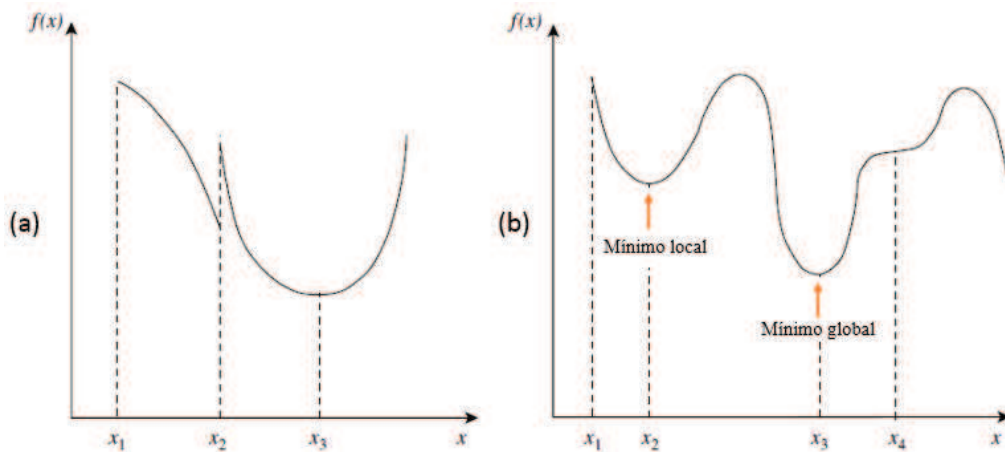


Figura 2.14 – Função descontínua (a) e função multimodal (b).

Fonte: Adaptado de Smith (2005).

Por outro lado, diversos problemas de engenharia também não podem ser tratados através de métodos analíticos devido a dificuldades de formulação da modelagem ou mesmo do esforço matemático exigido na solução, principalmente quando funções não-diferenciáveis ou descontínuas estão envolvidas. Neste contexto, nos últimos anos diversas meta-heurísticas vem sendo adotadas para solucionar problemas de busca e otimização em vários domínios de problemas para os quais soluções robustas são difíceis de encontrar usando abordagens tradicionais, como é o caso da programação matemática (SERAPIÃO, 2009).

As meta-heurísticas em sua definição original, são métodos de soluções que orquestram uma interação entre os procedimentos de melhoria local e estratégias de alto nível para criar um processo capaz de escapar de ótimos locais e efetuar uma busca robusta em uma região viável (GLOVER; KOCHENBERGER, 2003). Por sua vez, define-se como otimização, o campo de

conhecimentos cujas técnicas visam determinar os extremos (máximos ou mínimos) de funções, em domínios determinados (TAKAHASHI *et al.*, 2012).

Segundo Blum e Roli, (2003) algumas das propriedades fundamentais que caracterizam as meta-heurísticas são:

- Meta-heurísticas são estratégias que “orientam” o processo de busca;
- O objetivo é explorar eficientemente o espaço de busca para encontrar soluções ótimas ou próximas do ótimo;
- As técnicas que constituem algoritmos meta-heurísticos variam desde procedimentos de busca local simples até processos de aprendizagem complexos;
- Os algoritmos meta-heurísticos são aproximativos e não determinísticos.
- Eles podem incorporar mecanismos para evitar ficar “presos” em áreas confinadas (ótimos locais) do espaço de busca;
- As meta-heurísticas não são específicas para resolver um único problema;
- Atualmente, as meta-heurísticas mais avançadas utilizam a experiência de busca (memória) para orientar a busca.

O princípio fundamental das meta-heurísticas utiliza um método construtivo para obtenção de uma população inicial (soluções factíveis iniciais) e uma técnica de busca local para melhorar a solução da população, considerando que os indivíduos (soluções) dessa população são evoluídos considerando regras especificadas que consideram o intercâmbio de informações entre os indivíduos. Este processo encaminha a população em direção a uma solução ótima. Estes algoritmos são conhecidos também como algoritmos de computação evolutiva (SERAPIÃO, 2009).

Segundo Blum e Roli, (2003), as meta-heurísticas podem ser classificadas considerando diversos critérios como por exemplo: quanto a sua origem (inspiradas ou não em processos naturais) ou ainda considerando o número de soluções usadas ao mesmo tempo (solução única e população). Mirjalili *et al.* (2014) classificam de modo geral as meta-heurísticas em solução única e população. As meta-heurísticas de solução única iniciam a busca com uma solução candidata sendo esta solução melhorada ao longo das iterações. No entanto, as meta-heurísticas baseadas em população iniciam a busca com uma população inicial aleatória (soluções múltiplas) e essa população é melhorada ao longo das iterações. Assim, estas têm algumas vantagens em comparação com os algoritmos baseados em solução única: múltiplas soluções candidatas compartilham informações sobre o espaço de busca, o que resulta em “saltos” em direção à região promissora do espaço de busca, múltiplas soluções candidatas possuem maior

facilidade de “escaparem” da convergência prematura em soluções ótimas locais, as meta-heurísticas baseadas na população geralmente conseguem explorar de maneira mais eficiente o espaço de busca desconhecido.

Duas abordagens evolutivas baseadas em populações têm se destacado nos últimos anos: algoritmos evolutivos e algoritmos de enxame (SERAPIÃO, 2009). A Fig. (2.15) mostra alguns destes algoritmos.

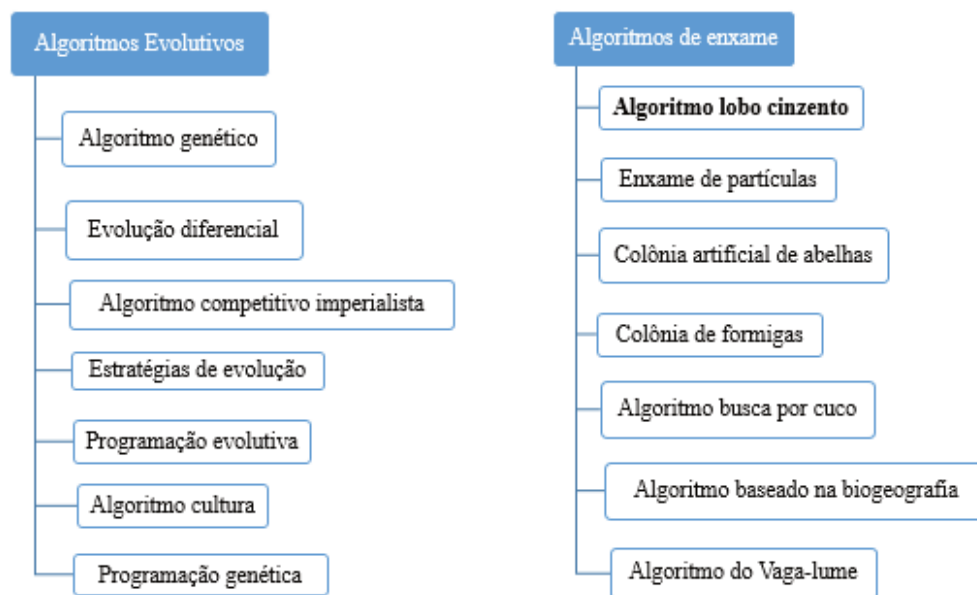


Figura 2.15 – Meta-heurísticas baseadas em população.

Fonte: Elaborado pelo autor.

Em geral estes algoritmos não garantem encontrar uma solução ótima, porém algumas avaliações estatísticas mostram que eles têm alcançado com regularidade a finalidade de retornar soluções de boa qualidade em tempo computacional aceitável (MULATI *et al.*, 2013). Segundo Takahashi *et al.* (2012), tempo computacional aceitável pode ser considerado alguns minutos, algumas horas ou até mesmo alguns dias.

Independente das diferenças entre as meta-heurísticas, uma característica comum é a divisão do processo de busca em duas fases: exploração global (*exploration*) e a exploração local (*exploitaiton*). A fase de exploração global refere-se ao processo de investigar as áreas promissoras do espaço de busca de maneira mais global possível. Nesta fase o algoritmo precisa de operadores estocásticos que, de forma aleatória, busquem globalmente no espaço investigado. A exploração local refere-se à capacidade de pesquisa em torno das regiões promissoras obtidas na fase de exploração global. Encontrar um equilíbrio adequado entre essas duas fases é considerada uma tarefa desafiadora devido à natureza estocástica das meta-

heurísticas (MIRJALILI *et al.*, 2014). A Fig. (2.16) ilustra o processo de busca do algoritmo Otimizador por Lobo Cinzento (GWO). Neste algoritmo metade das iterações é dedicada à pesquisa global e a outra metade das iterações dedicada à pesquisa local de acordo com o operador estocástico A .




Figura 2.16 – Divisão do processo de busca do algoritmo GWO.

Fonte: Adaptado de Faris *et al.* (2017).

Finalmente, as meta-heurísticas possuem habilidades superiores para evitar ótimos locais em comparação com técnicas convencionais de otimização. Esta habilidade é devido à natureza estocástica das meta-heurísticas que lhes permite evitar a estagnação em soluções locais e procurar todo o espaço de busca desconhecido. O espaço de busca de problemas reais geralmente é desconhecido e muito complexo com um grande número de ótimos locais. Desta forma as meta-heurísticas são boas opções para otimizar esses problemas desafiadores.

No entanto, não existe um algoritmo específico para alcançar a melhor solução para todos os problemas de otimização. Alguns algoritmos geram uma solução melhor para determinados problemas particulares. Consequentemente, a busca de novos algoritmos de otimização é um problema de estudo contínuo.

A seguir é apresentada uma breve revisão de alguns dos algoritmos que têm sido utilizados para otimização de trocadores de calor casco e tubos.

2.2.1 Algoritmo Genético – GA

O algoritmo genético (GA) foi desenvolvido no início da década de 1970 por John Holland e seus colaboradores na Universidade de Michigan (GOLDBERG, 1989) e é um método de pesquisa global estocástica. Este algoritmo é iniciado com uma população (geração) de indivíduos que são gerados aleatoriamente. Cada indivíduo (cromossomo) codifica uma única solução possível para um determinado problema e os indivíduos mais aptos são

escolhidos de acordo com uma função de aptidão (*fitness*) pré-definida, que é avaliada para cada membro dessa população. Os indivíduos com altos valores de aptidão representam, portanto, uma melhor solução para o problema, do que indivíduos com valores de aptidão mais baixos. O processo de seleção determina quais indivíduos da população podem participar da fase de reprodução. Os indivíduos são selecionados de acordo com uma probabilidade dada pelos seus valores de aptidão. Após este processo inicial, as operações de cruzamento e mutação são usadas onde os indivíduos na população atual produzem os filhos (descendentes). Após seleção, cruzamento e mutação serem aplicadas à população inicial, uma nova população vai sendo formada e o contador de gerações é incrementado em um. Este processo de seleção, cruzamento e mutação é continuado até que uma condição de término seja atingida (ELATTAR, 2015). O GA possui algumas vantagens tais como: otimiza com variáveis contínuas e discretas, fornece uma lista de variáveis ótimas (não apenas uma única solução), atua com grande número de variáveis, otimiza variáveis com superfície de custos extremamente complexas (HAUPT e HAUPT, 2004).

A Fig. (2.17) mostra o método sequencial do algoritmo genético.

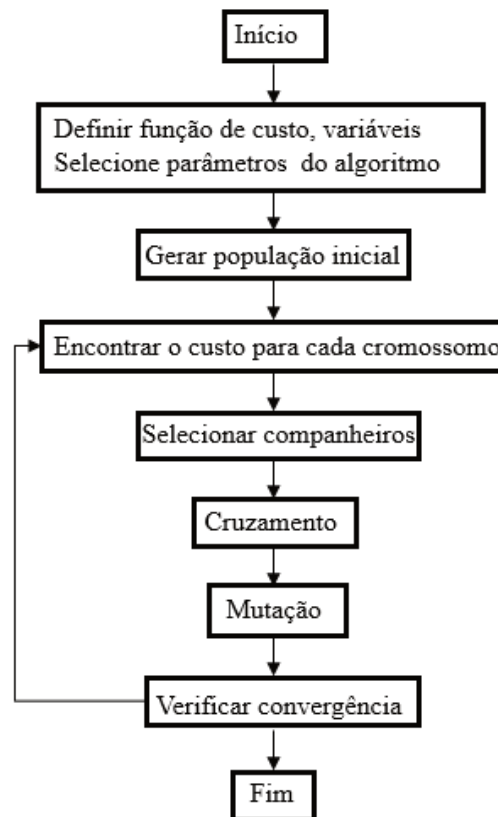


Figura 2.17 - Fluxograma do Algoritmo Genético (GA).

Fonte: Adaptado de Haupt e Haupt (2004).

2.2.2 Algoritmo Enxame de Partículas – PSO

O método estocástico de otimização foi originalmente desenvolvido por Kennedy e Eberhardt (1995). Esta técnica é inspirada no voo de pássaros ou cardumes de peixes, que são denominados de “partículas”. Conforme fluxograma da Fig. (2.18), o início deste método é aleatório, através de um conjunto de partículas com velocidades e posições também aleatórias. Após iniciado os indivíduos são avaliados através da função de avaliação. No algoritmo PSO existe um conjunto de vetores, cujas trajetórias oscilam em torno de uma região definida por cada melhor posição individual (*pbest*) e também pela melhor posição de outros indivíduos (*gbest*). A otimização ocorre por meio de duas características do PSO: a cooperação (aprendizado do grupo) e a competição (aprendizado individual). Estas características são responsáveis por guiar o algoritmo durante a exploração do espaço de busca (ENGELBRECHT, 2005). O PSO analisa o espaço de busca modificando o termo velocidade. Uma abordagem para controlar a busca, ou seja, controlar a velocidade máxima de cada partícula é a implementação de um “peso de inércia”. (KENNEDY e EBERHART, 2001). O fator de inercia (w) tem a função de ajustar a busca. Normalmente seu valor está compreendido entre 0,4 e 0,9. No entanto, quanto maior for seu valor mais global será a busca.

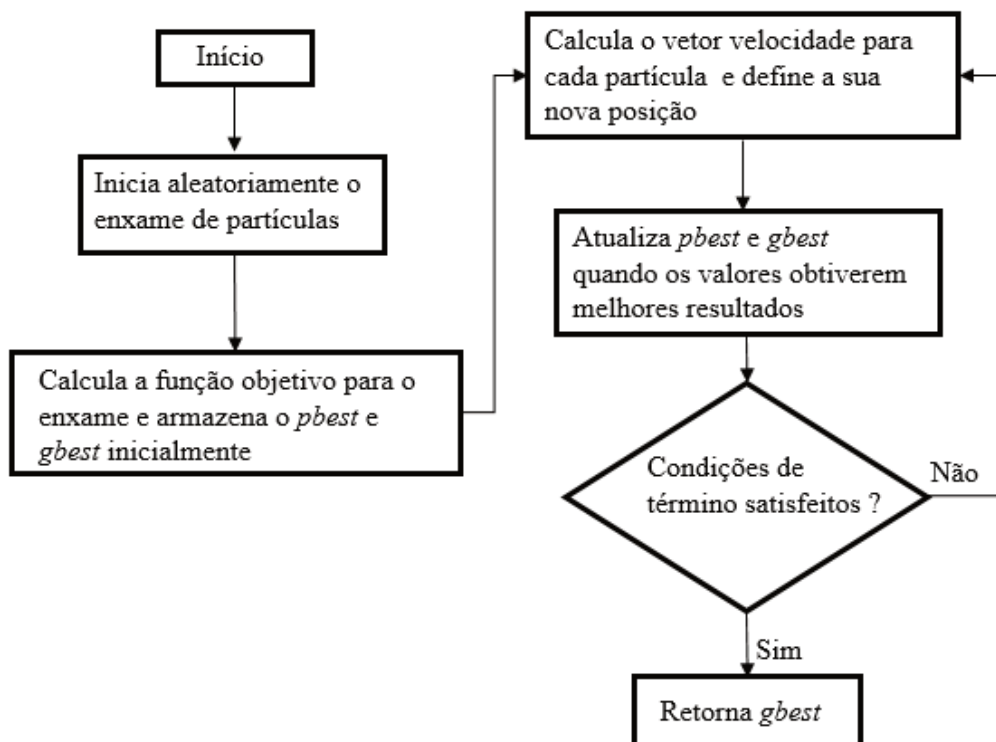


Figura 2.18 - Fluxograma do algoritmo enxame de partículas (PSO).

Fonte: Adaptado de Kennedy e Eberhart (1995).

2.2.3 Algoritmo Evolução Diferencial - DE

O algoritmo evolução diferencial DE proposto por Storn e Price (1995) é um dos mais eficientes algoritmos evolutivos (AE) que utiliza codificação real. Ele se destaca por sua simplicidade de implementação, com poucos parâmetros de controle e com seu notável desempenho em comparação com vários AE em uma ampla variedade de problemas, incluindo problemas de grande porte. Comparado com outros algoritmos evolutivos o DE é muito mais simples de implementar. Quando comparado ao PSO, o algoritmo DE possui melhor desempenho em uma grande variedade de problemas, incluindo problemas unimodal e multimodal. O bom desempenho em termos de precisão, velocidade de convergência torna atrativo para vários problemas de otimização, onde a solução aproximada é obtida em um tempo computacional razoável (DAS e SUGANTHANS, 2011).

O DE possui poucos parâmetros de controle: constante de mutação ou peso aplicado ao vetor de diferença, constante de *crossover* e tamanho da população. O DE busca um ponto ótimo global em um espaço de parâmetros reais iniciando aleatoriamente. Conforme o fluxograma apresentado na Fig. (2.19), os quatro passos básicos do DE consistem em: inicialização aleatória de uma população de busca de vetores variáveis, mutação, *crossover* ou cruzamento, e finalmente a seleção. O *crossover* aumenta a diversidade potencial de uma população. No DE toda a população (pais e filhos) competem entre si, ou seja, aquele que tiver melhor valor da função objetivo é selecionado para a próxima geração (STORN e PRICE, 1997).

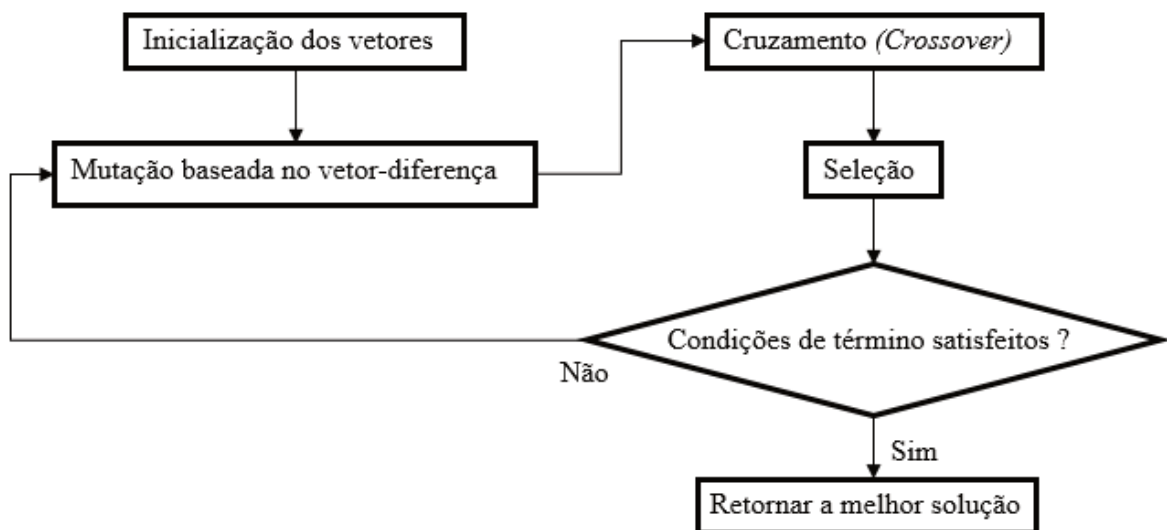


Figura 2.19 - Fluxograma do algoritmo evolução diferencial (DE).

Fonte: Adaptado de Das e Suganthans (2011).

2.2.4 Algoritmo Colônia Artificial de Abelhas - ABC

Este algoritmo proposto por Karaboga (2005) é inspirado na abelha forrageira, ou seja, a abelha que busca e explora recursos alimentares. O objetivo das abelhas é procurar fontes com quantidade elevada de néctar e finalmente o maior néctar como mostra o fluxograma da Fig. (2.20). Neste sistema as abelhas voam ao redor de um espaço de pesquisa multidimensional e algumas escolhem fontes de alimento, dependendo da experiência delas mesmas e de suas companheiras, e ajustam suas posições. Se a quantidade de néctar de uma nova fonte é maior que a anterior elas memorizam a nova fonte e eliminam a anterior (KARABOGA, 2009).

Assim o sistema ABC combina métodos de busca locais realizadas por abelhas empregadas e observadoras e buscas globais gerenciadas por abelhas exploradoras. Este modelo leva ao surgimento da inteligência coletiva (KARABOGA e AKAY, 2009).

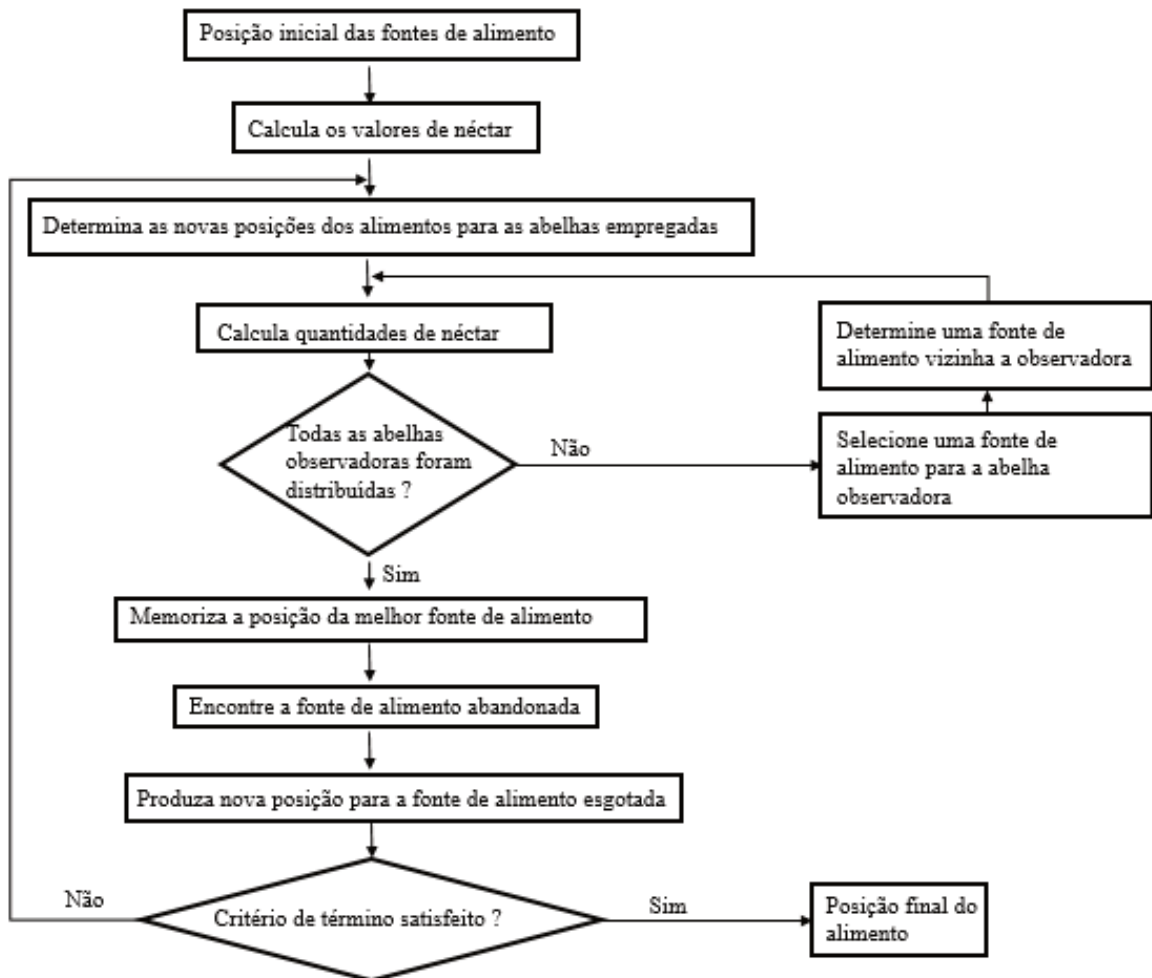


Figura 2.20 - Fluxograma do algoritmo colônia artificial de abelhas (ABC).

Fonte: Adaptado de Karaboga (2009).

2.2.5 Algoritmo Competitivo Imperialista – ICA

Este algoritmo evolutivo proposto por Atashpaz-Gargari e Lucas (2007) é semelhante a outros algoritmos evolutivos. Esse algoritmo começa com uma população inicial aleatória dividindo-se entre colônias e imperialistas. Cada indivíduo da população é chamado de país (em terminologia de otimização, país com menor custo devido ao algoritmo ser de minimização) e este é selecionado para ser o imperialista e o restante são as colônias desse imperialista. As colônias por sua vez, estarão divididas entre os imperialistas de acordo com seu poder. Caso uma colônia de um determinado império tenha menor custo que seu imperialista, ocorre a troca de posição entre a colônia e seu imperialista conforme mostra o fluxograma da Fig. (2.21). Um país imperialista e suas colônias formam um império, onde o poder deste império é a soma do poder das colônias e do país imperialista. Sendo assim, os impérios mais poderosos tendem ao longo do tempo a conquistar os impérios com menor poder, ocorrendo a convergência do conjunto de países a um único império. Este império possuirá todas as colônias em seu domínio estando essas na mesma posição do imperialista. Sendo assim não haverá mais diferenças entre colônia e imperialista levando ao fim da competição. Se compararmos um algoritmo genético clássico com o ICA, percebe-se que os países representam os cromossomos, ou seja, eles representam as possíveis soluções dentro do espaço de busca desconhecido.

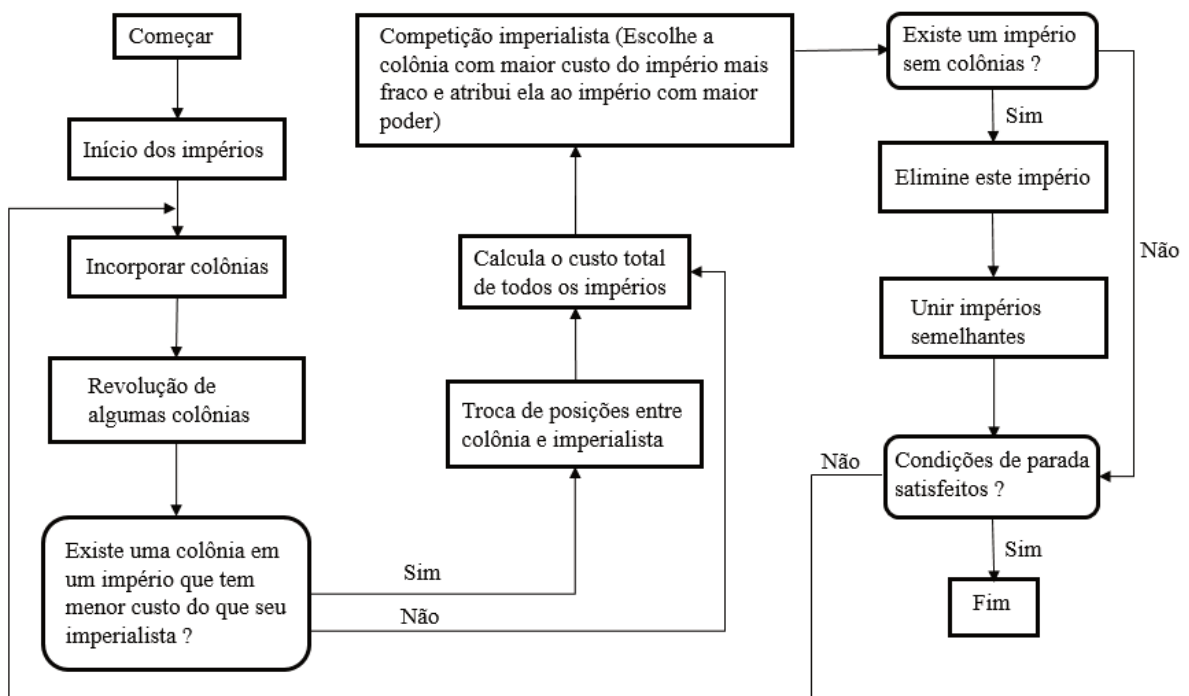


Figura 2.21 - Fluxograma do algoritmo competitivo imperialista (ICA).

Fonte: Adaptado de Atashpaz-Gargari e Lucas (2007).

2.2.6 Algoritmo do Vaga-Lume - FFA

O algoritmo do vaga-lume FFA, proposto por Yang na universidade de Cambridge, em 2007, foi baseado no comportamento idealizado das características piscantes dos vaga-lumes (YANG, 2010b). Por simplicidade, as características intermitentes podem ser idealizadas de acordo as seguintes regras:

- Todos os vaga-lumes são unissex, para que um vaga-lume seja atraído por outros vaga-lumes, independente do sexo;
- A atratividade é proporcional ao seu brilho, portanto para qualquer dois vaga-lumes luminosos, o menos brilhante se moverá para o mais brilhante. A atratividade é proporcional ao brilho e ambos diminuem à medida que a distância aumenta. Caso não haja um mais brilhante que um vaga-lume específico, ele se move aleatoriamente;
- O brilho ou a intensidade da luz de um vaga-lume é afetada pela forma da função objetivo.

No FFA há duas questões importantes: a variação da intensidade de luz e a formulação da atratividade. Por simplicidade, é possível sempre assumir que a atratividade de um vaga-lume é determinada pelo seu brilho ou intensidade da luz que, por sua vez, está associada à função objetivo. Entretanto a atratividade é relativa, ela pode ser vista pelos olhos de quem vê ou julgada pelos outros vaga-lumes, assim, varia com a distância entre os vaga-lumes. Além disso, a intensidade de luz diminui com a distância a partir da sua fonte, e a luz é também absorvida no meio, então se deve permitir a variação da atratividade com o grau de absorção (YANG, 2010b). Conforme fluxograma da Fig. (2.22), é gerado uma população de vaga-lumes e distribuída aleatoriamente no espaço de busca. Em seguida é definida a variação da intensidade de luz (I) e a atratividade (β_f), pois os vaga-lumes deslocam-se em direção a outros que apresentam um brilho maior, ou seja, um valor de aptidão maior.

O FFA foi aplicado para encontrar a melhor solução global em projeto de vasos de pressão, onde apresentou melhores resultados que o algoritmo PSO (YANG, 2010a).

A Fig. (2.22) mostra o fluxograma com as etapas do algoritmo do vaga-lume.

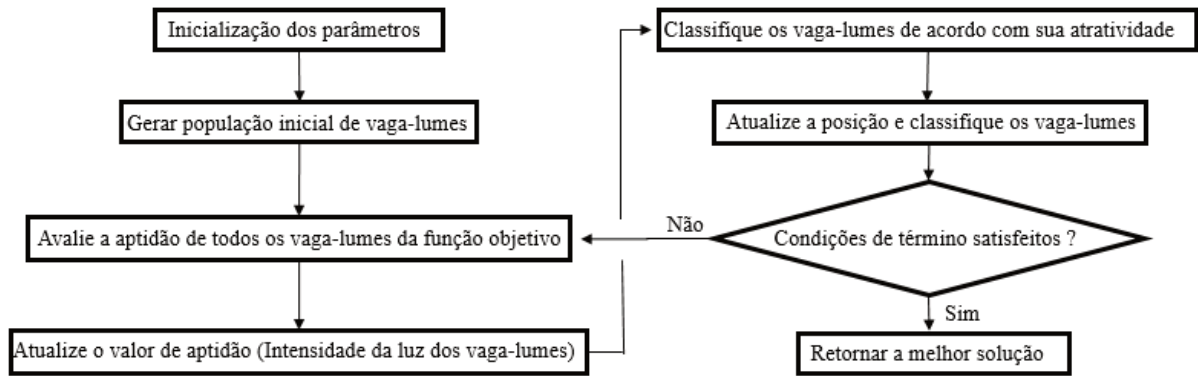


Figura 2.22 - Fluxograma do algoritmo do vaga-lume (FFA).

Fonte: Adaptado de Mohanty (2016a).

2.2.7 Algoritmo Baseado na Biogeografia - BBO

O algoritmo baseado na biogeografia foi proposto por Simon (2008) e possui recursos para identificar o mínimo global em um espaço de busca desconhecido. O conceito do BBO é principalmente baseado na migração e mutação. Este algoritmo é semelhante a outras técnicas de otimização baseadas em população, onde a população de soluções candidatas é representada como vetor de números reais. Cada número real na matriz é considerado como uma variável índice de adequação (SIV), e as variáveis são consideradas independentes do habitat e responsáveis por caracterizar a habitabilidade. Um termo chamado HSI (variável dependente) é usado para representar a qualidade de um conjunto de soluções candidatas. As soluções com HSI elevados representam as melhores soluções quando comparadas a HSI de valores baixos. Conforme o fluxograma da Fig. (2.23), o método inicia com os melhores habitats, ou seja, com valores elevados de HSI disponíveis na iteração corrente. As taxas de emigração e imigração são utilizadas para compartilhar informações probabilísticas entre os habitats. Os habitats com alto HSI geralmente possuem uma grande quantidade de espécies, portanto possuem baixa taxa de imigração, pois provavelmente estão repletos de espécies. Desta forma habitats com alto HSI são mais estáticos quando comparados aos habitats com valores baixos de HSI, que tendem a ter altas taxas de imigração e baixas taxas de emigração tendo em vista o baixo número de espécies. Entretanto, se o HSI de um habitat continuar com valores baixos, suas espécies com o passar do tempo irão se extinguir.

Uma boa solução é análoga a uma ilha (habitat geograficamente isolado) com um alto HSI e solução ruins são representadas por ilhas com baixo HSI. As soluções com HSI alto são mais resistentes que as soluções com baixo. Além disso, as soluções com alto HSI tendem a

compartilhar suas características com soluções de baixo, que recebem recursos provenientes das melhores soluções (SIMON, 2008).

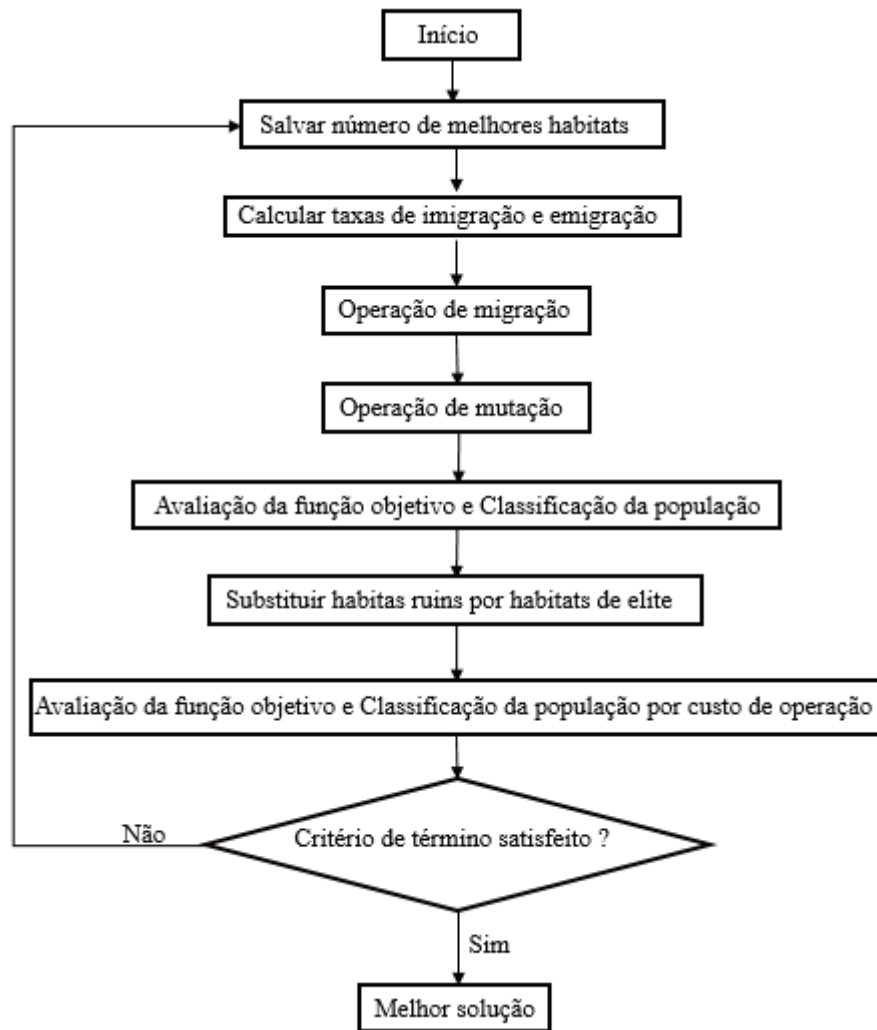


Figura 2.23 - Fluxograma do algoritmo baseado na biogeografia (BBO)

Fonte: Adaptado de Hadidi e Nazari (2013).

2.2.8 Algoritmo de Busca Gravitacional - GSA

O algoritmo GSA proposto por Rashedi *et al.* (2009) é um algoritmo de busca heurística baseado na lei da gravidade e na interação entre corpos. Segundo a lei da gravitação universal de Newton “todas as partículas no universo atraem outras com uma força que é diretamente proporcional ao produto das suas massas e inversamente proporcional ao quadrado da distância entre elas”. Este algoritmo utiliza o conceito de que cada corpo gera uma força de atração proporcional à sua massa. Assim, os corpos são agentes e as massas são dadas pela *fitness function* (função objetivo, que avalia a aptidão do agente). Para que o algoritmo evite ótimos locais, somente as melhores massas (maiores valores da função objetivo) irão atrair as outras

massas. As massas mais pesadas que correspondem as melhores soluções movimentam-se lentamente comparadas as massas mais leves, isso garante as etapas de exploração do algoritmo (RASHEDI *et al.*, 2009). Conforme o fluxograma da Fig. (2.24), o método inicia com uma população aleatória. Em seguida é avaliada a aptidão (massa) de cada agente. Esta etapa é importante, pois os agentes deslocam-se em direção a outros agentes que possuem massas mais pesadas gerando um movimento global. A constante gravitacional é responsável por ajustar a precisão da busca e diminui com o passar do tempo evolutivo.

A Fig. (2.24) mostra as etapas do fluxograma do algoritmo de busca gravitacional.

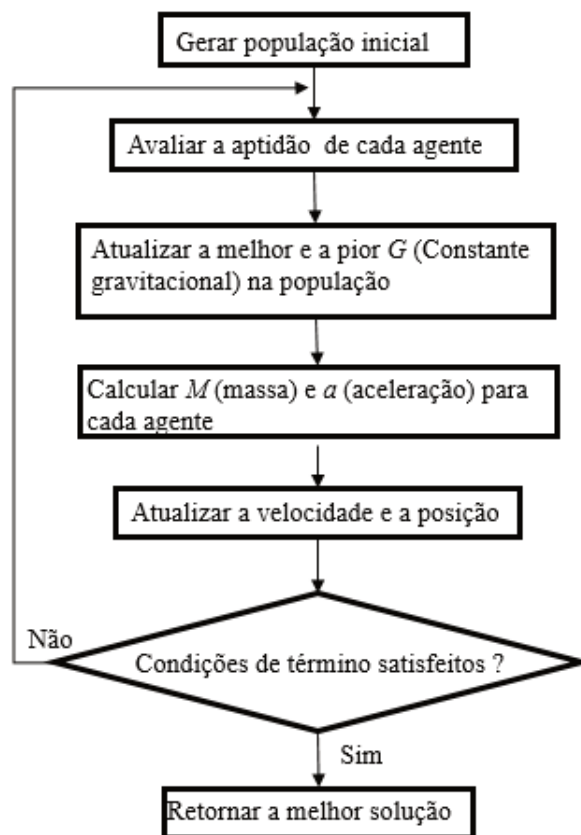


Figura 2.24 - Fluxograma do algoritmo de busca gravitacional.

Fonte: Adaptado de Rashedi *et al.* (2009).

2.2.9 Algoritmo Busca por Cuco - CSA

O algoritmo metaheurístico CSA proposto por Yang e Deb (2009) é baseado na reprodução dos pássaros Cuco, que possuem uma estratégia de reprodução agressiva. Algumas espécies de Cuco colocam seus ovos em ninhos de outras aves para serem chocados. Além disso, para aumentar a probabilidade de ter seus ovos chocados, os Cucos buscam substituir os

ovos dos hospedeiros por seus próprios ovos. Se o pássaro hospedeiro descobrir o ovo de Cucos em seu ninho, o ovo é destruído ou o ninho será abandonado (YANG e DEB, 2010). Quando a população de Cucos é maior que a população máxima, o algoritmo elimina os Cucos que se encontram em área menos promissora, como mostra o fluxograma da Fig. (2.25).

Para simplificar a descrição do método CSA, são utilizadas três suposições:

- Cada cuco coloca um ovo por vez, em um ninho escolhido aleatoriamente;
- Os melhores ninhos com alta qualidade de ovos (soluções) serão transferidos para as próximas gerações;
- O número de ninhos hospedeiros disponíveis é fixo, onde um pássaro hospedeiro pode descobrir um ovo de cuco. Neste caso, o pássaro hospedeiro pode jogar o ovo fora ou abandonar o ninho de modo a construir um ninho novo (diversificação da busca).

Esta diversificação da busca tem o objetivo de evitar ótimos locais. O CSA foi comparado com outros métodos de otimização como enxame de partículas e algoritmo genético na resolução de alguns problemas de otimização com funções objetivos de solução complexa e os resultados mostram a superioridade do CSA comparado a estes métodos (YANG e DEB, 2010).

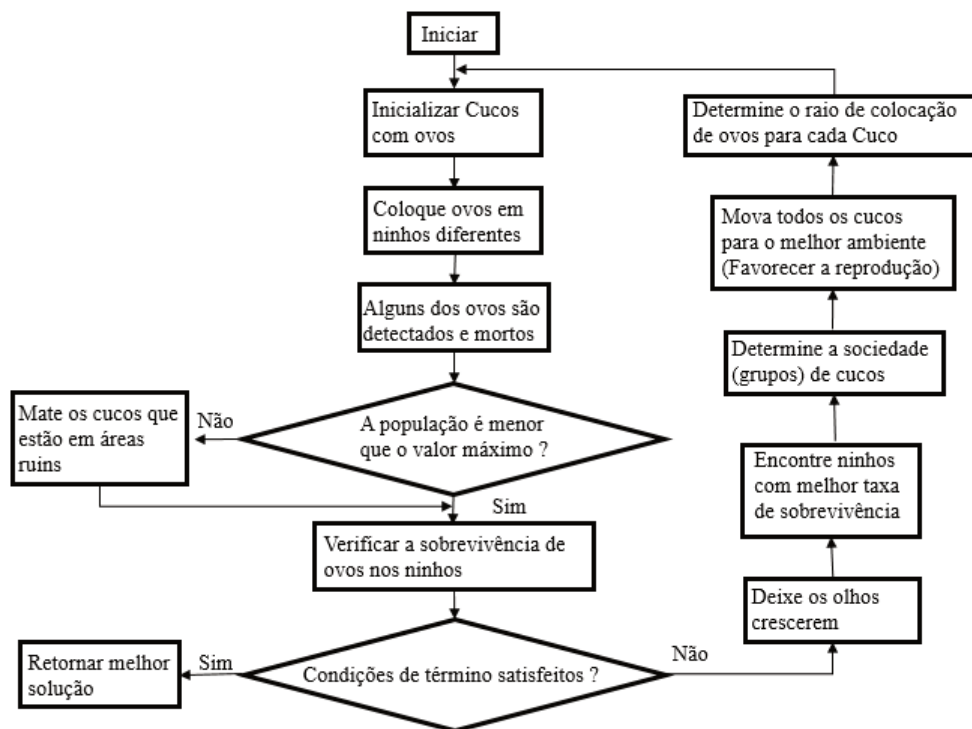


Figura 2.25 - Fluxograma do algoritmo busca por cuco (CSA).

Fonte: Adaptado de Rajabioun (2011).

2.3 ALGORITMO LOBO CINZENTO

A meta-heurística lobo cinzento GWO, proposta por Mirjalili *et al.* (2014), foi baseada no comportamento de caça e hierarquia social dos lobos cinzentos. Os lobos cinzentos (*canis lupus*) pertencem à família dos canídeos e são considerados predadores, estando desta forma no topo da cadeia alimentar. Os lobos cinzentos geralmente preferem viver em grupos com valor médio de 5 a 12 indivíduos e, de particular interesse, eles possuem uma hierarquia social dominante muito rígida como mostra a Fig. (2.26).




Figura 2.26 – Hierarquia do lobo cinzento (dominância diminui de cima para baixo).

Fonte: Adaptado de Mirjalili *et al.* (2014).

Os machos e fêmeas alfa (α) estão no topo da cadeia dominando o resto do grupo e são os únicos que podem acasalar, sendo também responsáveis por inúmeras decisões do grupo. Curiosamente alfa não necessariamente precisa ser o lobo mais forte do grupo, mas o melhor em termos de gerenciamento do grupo. Isso mostra que a organização e a disciplina de um grupo são muito mais importantes do que a sua força. Logo abaixo estão os lobos beta (β) que são subordinados aos lobos α e ajudam estes na tomada de decisões. O lobo β pode ser masculino e feminino, sendo provavelmente o melhor candidato para tornar-se um α caso um dos lobos desta categoria morrer. No terceiro nível da hierarquia encontram-se os lobos delta (δ), que são subordinados aos lobos α e β , mas possuem uma posição dominante em relação aos lobos ômega (ω). O lobo cinzento classificado como ω deve se submeter a todos os outros lobos dominantes (MIRJALILI *et al.*, 2014).

Além da hierarquia social dos lobos, a caça em grupo é outro comportamento social interessante dos lobos cinzentos. De acordo com Muro *et al.* (2011) as principais etapas de caça dos lobos cinzentos são apresentadas na Fig. (2.27) e divididas em:

- (A) localizar, seguir e aproximar da presa.
- (B-D) perseguir, cercar e fatigar a presa até esta parar.
- (E) atacar a presa.




Figura 2.27 – Comportamento de caça de lobos cinzentos.

Fonte: Adaptado de Muro *et al.* (2011).

2.3.1 Modelo matemático e algoritmo

Nesta seção os modelos matemáticos da hierarquia social do algoritmo GWO são definidos.

2.3.1.1 Hierarquia social

Para modelar matematicamente a hierarquia social ao projetar o GWO, a solução de melhor aptidão é considerada como o alfa (α) e a segunda e terceira melhores soluções são beta (β) e delta (δ), respectivamente. As soluções candidatas restantes são assumidas como ômega (ω). No algoritmo GWO, a caçada (otimização) é guiada por α , β e δ . Os lobos ω seguem estes três lobos (MIRJALILI *et al.*, 2014).

2.3.1.2 Cercando a presa

Como já mencionado, os lobos cercam as suas presas durante a caçada. Para modelar matematicamente este comportamento, são propostas as seguintes equações:

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (2.27)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (2.28)$$

onde, \vec{D} é a distância entre o lobo e a presa, \vec{A} e \vec{C} são vetores de coeficientes, \vec{X}_p é o vetor de posição da presa, \vec{X} indica o vetor de posição de um lobo e t é a iteração corrente. Para o cálculo dos vetores \vec{A} e \vec{C} tem-se as seguintes equações:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (2.29)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (2.30)$$

onde, \vec{a} decresce gradualmente e linearmente de 2 para 0 ao longo das iterações, r_1 e r_2 são valores aleatórios no intervalo de [0,1].

Para verificar os efeitos das Eq. (2.27) e (2.28), um vetor de posição bidimensional e alguns dos possíveis vizinhos estão ilustrados na Fig. (2.28).

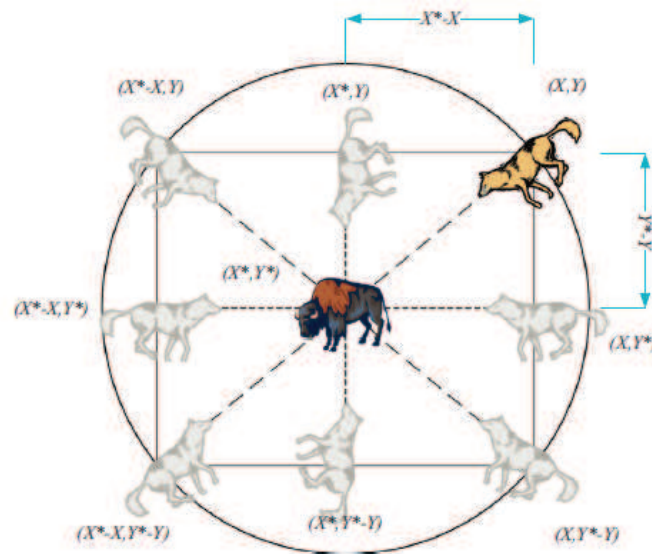


Figura 2.28 – Vetor de posição bidimensional da presa e alguns de seus possíveis locais.

Fonte: Adaptado de Mirjalili *et al.* (2014).

conhecimento sobre a localização potencial da presa. Portanto, são salvas as primeiras três melhores soluções obtidas até o momento e obrigatoriamente os outros agentes (ω) atualizam suas posições de acordo com a média dos melhores agentes de busca. As seguintes equações são propostas:

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \quad \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \quad \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (2.31)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha), \quad \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta), \quad \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad (2.32)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (2.33)$$

A Fig. (2.30) mostra como um agente de busca atualiza sua posição de acordo com o α , β e δ em um espaço de pesquisa 2D. Pode-se observar que a posição final seria em um local aleatório dentro de um círculo que é definido pelas posições de alfa, beta e delta no espaço de busca desconhecido. Em outras palavras, alfa, beta e delta estimam a posição da presa, e outros lobos atualizam suas posições aleatoriamente em torno da presa.

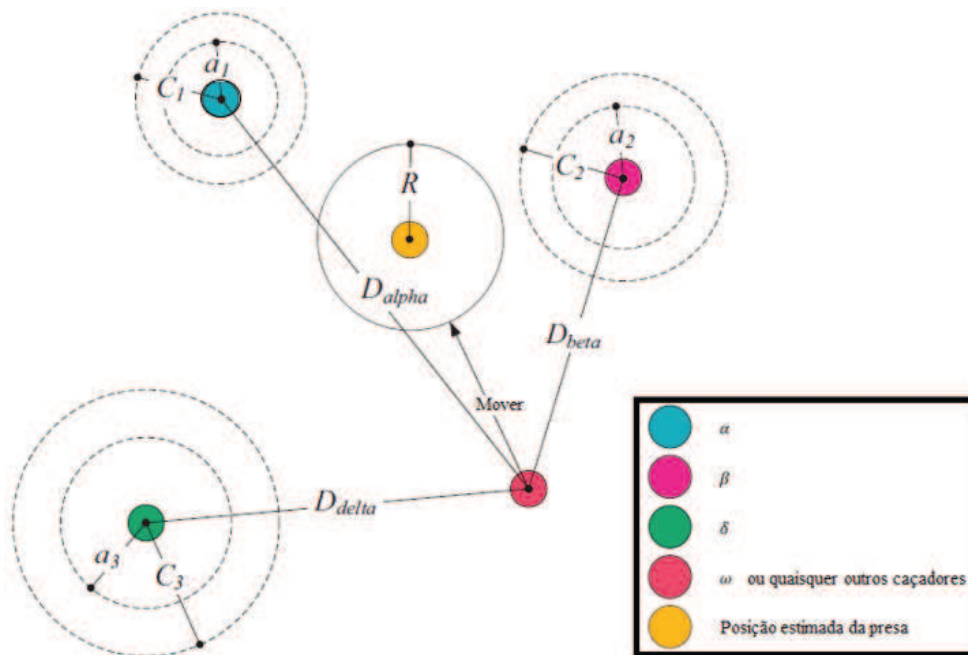


Figura 2.30 – Atualização da posição do algoritmo GWO.

Fonte: Adaptado de Mirjalili *et al.* (2014).

2.3.1.4 Atacar presas

Conforme mencionado acima, os lobos cinzentos terminam a caça atacando a presa quando ela para de se mover. Para modelar matematicamente a aproximação da presa, diminui-se o valor de \vec{a} . Observe que o intervalo de flutuação de \vec{A} também é diminuído por \vec{a} . Em outras palavras \vec{A} é um valor aleatório no intervalo de $[-2\alpha, 2\alpha]$, onde \vec{a} é diminuído de 2 a 0 ao longo das iterações. Quando valores aleatórios de \vec{A} estão entre $[-1, 1]$, a próxima posição de um agente de busca pode estar em qualquer posição entre a posição atual e a posição da presa. A Fig. (2.31) mostra que $|A| < 1$ força os lobos a atacarem em direção à presa.



Figura 2.31 – Lobos atacam em direção a presa.

Fonte: Adaptado de Mirjalili *et al.* (2014).

Com os operadores propostos até agora, o algoritmo GWO permite aos agentes de busca atualizar a sua posição com base na localização do α , β e δ , e atacam a presa. No entanto, o algoritmo GWO é propenso à estagnação em soluções locais com esses operadores. Segundo Mirjalili *et al.* (2014) o mecanismo de cerco proposto mostra a exploração até certo ponto, mas o GWO precisa de mais operadores para enfatizar a exploração.

2.3.1.5 Busca por presas

Os lobos cinzentos procuram principalmente de acordo com a posição do α , β e δ . Eles divergem um do outro para procurar presas e convergem para atacar a presa. Para modelar matematicamente esta divergência, é utilizado o vetor \vec{A} com valores aleatórios superiores a 1 ou inferiores a -1 para obrigar o agente de busca a divergir da presa. Isso enfatiza a exploração

e permite que o algoritmo GWO procure globalmente. A Fig. (2.32) mostra que $|A| > 1$ força os lobos cinzentos a divergir da presa para encontrar uma presa melhor.



Figura 2.32 – Lobos procuram por presas.

Fonte: Adaptado de Mirjalili *et al.* (2014).

Outro componente do GWO que favorece a exploração é o vetor coeficiente \vec{C} . Como pode ser visto na Eq. (2.30), o vetor \vec{C} contém valores aleatórios no intervalo $[0, 2]$. Este componente fornece pesos aleatórios para a presa, a fim de estocasticamente enfatizar ($C > 1$) ou desenfatar ($C < 1$) o efeito de presa na definição da distância lobo-presa, \vec{D} , da Eq. (2.27). Isto ajuda o algoritmo GWO a mostrar um comportamento mais aleatório durante toda a otimização, favorecendo a exploração e evitando pontos ótimos locais.

A Fig. (2.33) mostra o pseudocódigo do algoritmo GWO.

```

Inicializar a população de lobos cinzentos  $X_i (i = 1, 2, \dots, n)$ 
Inicializar:
 $\alpha$  - componente responsável pela exploração
 $A$  e  $C$  - componentes aleatórios que auxiliam as soluções candidatas
Calcular a aptidão (fitness) de cada agente
 $X_\alpha$  - Procura de melhor agente
 $X_\beta$  - Procura do segundo melhor agente
 $X_\delta$  - Procura do terceiro melhor agente
enquanto ( $t < \text{máximo de iterações}$ )
    para agente de procura
        Atualização da posição do agente de procura corrente
    fim do para
    Atualizar  $\alpha$ ,  $A$  e  $C$ 
    Calcula a aptidão de todos os agentes de procura
    Atualiza  $X_\alpha$ ,  $X_\beta$  e  $X_\delta$ 
     $t=t+1$ 
Fim do enquanto
Retorna  $X_\alpha$ 

```

Figura 2.33- Pseudocódigo do algoritmo lobo cinzento.

Fonte: Adaptado de Mirjalili *et al.* (2014).

Para resumir, o processo de busca começa com a geração de uma população aleatória de lobos cinzentos (soluções candidatas). Ao longo das iterações, lobos α , β e δ estimam sua posição provável em relação à presa. As soluções candidatas tendem a divergir quando $|A| > 1$ e convergem para a presa quando $|A| < 1$ finalmente, o algoritmo GWO é encerrado pela satisfação de um critério final. A Fig. (2.34) mostra o fluxograma do algoritmo GWO.

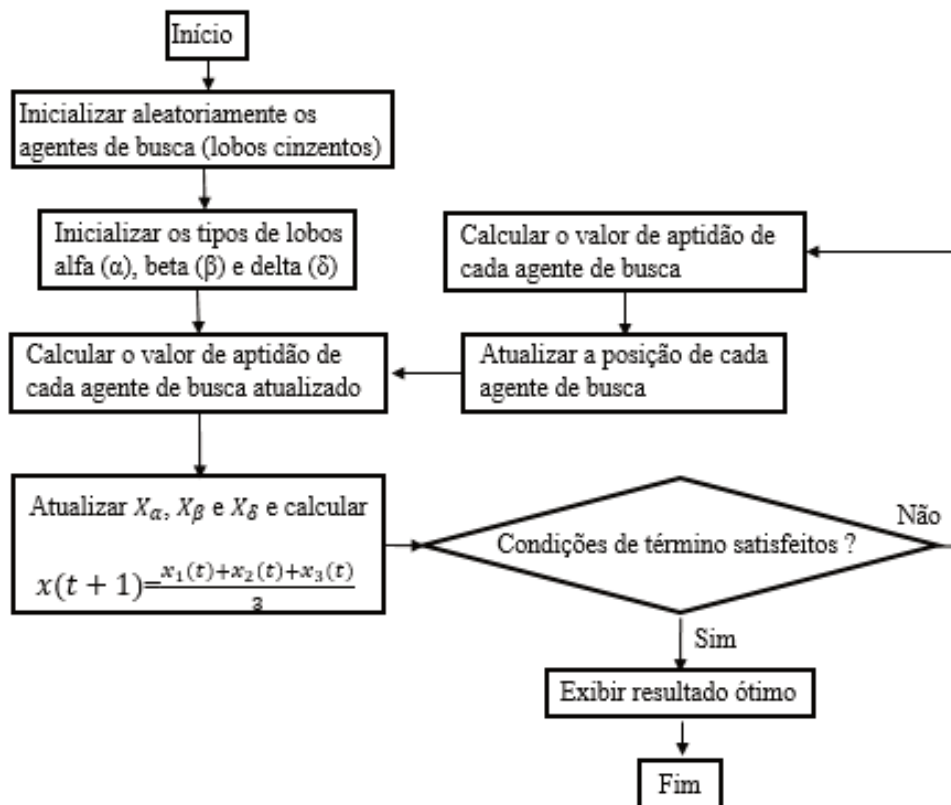


Figura 2.34 – Fluxograma do algoritmo lobo cinzento.

Fonte: Adaptado de Guha *et al.* (2016).

O trabalho de Faris *et al.* (2017), mostra que o algoritmo GWO clássico possui baixa capacidade de lidar com as dificuldades de um cenário de pesquisa multimodal, pois em muitos casos os três lobos α , β e δ tendem a convergir para um mínimo local.

Lu *et al.* (2018) propõem uma nova versão para o algoritmo GWO com objetivo de evitar a estagnação em mínimos locais integrando os autômatos celulares (CA_s) ao GWO clássico passando a se chamar CGWO. Esta matriz de rede de células que são alteradas de acordo com seu estado anterior e o estado das células vizinhas ao longo das iterações favorece a busca local. A população pode ser dividida em muitas subpopulações formando grupos independentes. Cada subpopulação pode se atualizar em sua própria vizinhança. Portanto, diferentes subpopulações têm diferentes direções de pesquisa, o que ajuda a manter a

diversidade da busca por mais tempo. Assim pode-se manter o equilíbrio entre a diversidade e a convergência.

2.4 REVISÃO BIBLIOGRÁFICA – ESTADO DA ARTE

Nos últimos anos diversos trabalhos vêm sendo realizados e publicados sobre a otimização de trocadores de calor casco e tubos utilizando diferentes métodos.

Caputo *et al.* (2008) utilizaram o algoritmo genético (GA) para realizar a otimização de trocadores de calor casco e tubos. Neste caso a função objetivo considerada foi o custo total do equipamento, incluindo o investimento de capital e o custo de operação total descontado relacionado com a potência de bombeamento. A fim de verificar a capacidade do método proposto, três estudos de caso foram investigados. Os resultados mostram que o algoritmo proposto apresenta um bom desempenho com reduções significativas do custo total de projetos tradicionais de trocadores de calor casco e tubos. Em um dos casos abordados a redução do custo total passou de 50 %, comparado ao projeto original.

Outra abordagem de otimização do projeto de trocadores de calor casco e tubos foi realizada por Costa e Queiroz (2008). A função objetivo a minimizar foi a área de transferência de calor levando em consideração as restrições impostas pelas características geométricas. Foram utilizados dois estudos de caso para demonstrar o desempenho do algoritmo proposto pelos autores. Para o lado do casco foi utilizado o método Bell-Delaware (1963) para cálculo do coeficiente de transferência de calor e perda de pressão. O algoritmo proposto para otimização aplicado ao problema envolveu uma pesquisa em tabelas de contagem de tubos com base em um caminho controlado ao longo do espaço das variáveis de projeto. Os resultados mostraram que o trocador de calor otimizado pelo algoritmo proposto resultou em uma área de transferência de calor maior quando comparado com projeto original. Isso ocorreu, pois, o projeto original apresentava a relação entre comprimento dos tubos e diâmetro do casco igual a 2,3. Este resultado é inferior ao mínimo recomendado pela norma TEMA, onde o resultado desta razão deve estar no intervalo de 3 a 15. Este aspecto pode trazer problemas relacionados à distribuição de fluxo. Além disso, a velocidade de escoamento do fluido nos tubos de 0,64 m/s era relativamente baixa e poderia ocasionar problemas de incrustação. Estes fatores salientam a importância de incluir juntamente com as restrições fundamentais da área de superfície mínima e perda de pressão máxima, restrições adicionais para garantir maior viabilidade do projeto.

Guo *et al.* (2009a) utilizaram a taxa de geração de entropia adimensional como função objetivo para otimização de projeto de trocadores de calor casco e tubos. Alguns dos parâmetros geométricos do trocador de calor são considerados como variáveis de projeto tais como: diâmetro externo dos tubos, número de tubos, relação entre o espaçamento dos defletores e diâmetro interno do casco, corte dos defletores e a temperatura de saída do fluido frio. O algoritmo GA foi aplicado para resolver o problema de otimização associado. Os resultados mostraram que esta metodologia aumenta a efetividade do trocador de calor em 52,17% e diminui a potência de bombeamento em 71,43%.

Outra abordagem para otimização de trocadores de calor casco e tubos foi proposta por Guo *et al.* (2009b), onde o número de sinergia dos campos (campo do vetor velocidade e da temperatura) foi empregada como função objetivo. O princípio da sinergia dos campos propõe que a taxa de transferência de calor de um trocador de calor não dependa apenas do gradiente de temperaturas e da magnitude da velocidade do escoamento, mas considera também a sinergia entre eles (GUO *et al.*, 2009b). Esse conceito é uma reinterpretação do número de Stanton, S_t . O algoritmo genético GA foi utilizado para resolver o problema de otimização, que busca a maximização do número de sinergias de campo. Segundo os autores, esta maximização aumenta o processo de transferência de calor. O método Bell-Delaware foi utilizado para o dimensionamento do lado do casco. Os resultados mostraram uma melhora na taxa de transferência de calor elevando em 55,56 % a efetividade e uma redução na potência de bombeamento de 75 % a medida que o número de sinergia dos campos aumenta.

Patel e Rao (2010), usaram o algoritmo enxame de partículas PSO, para otimização do projeto de trocadores de calor casco e tubos do ponto de vista econômico. Três variáveis de projeto foram empregadas na otimização: diâmetro interno do casco, diâmetro externo dos tubos e espaçamento dos defletores. Em dois dos quatro casos de estudo foi observado que o aumento do coeficiente de transferência de calor do lado do casco resultou em um aumento significativo do coeficiente global de transferência de calor, ocasionando uma redução da área dos trocadores de calor. Portanto, o custo total do equipamento é reduzido. O algoritmo PSO apresentou bons resultados de otimização, sendo assim foi classificado pelos autores como uma ferramenta adequada para a otimização de projetos de trocadores de calor casco e tubos, melhor que o algoritmo genético GA quando o objetivo da otimização é custo. Os resultados da minimização da função objetivo obtidos pelo algoritmo PSO nos quatro estudos de caso foram menores em 3,35 %, 1,88 %, 2,52 % e 6,54 % comparado aos resultados do GA.

Sahin *et al.* (2011) mostraram uma nova abordagem de otimização de trocadores de calor casco e tubos utilizando o algoritmo colônia artificial de abelhas (ABC), para minimizar

o custo total do equipamento. Os casos abordados pelo estudo tiveram as velocidades dos fluidos tanto do lado dos tubos, quanto do casco minimizadas ocasionando a redução das perdas de carga em ambos os lados. Assim, o custo operacional reduziu contribuindo para a redução do custo total de projeto. Além disso, o algoritmo ABC é considerado mais rápido e mais exato que os métodos tradicionais de otimização. Os resultados da minimização da função objetivo obtidos pelo algoritmo ABC em três estudos de caso foram menores em 7,78 %, 0,38 % e 6,51% comparado aos resultados do GA.

Outra abordagem para otimização de projeto de trocadores de calor casco e tubos foi proposta por Hadidi *et al.* (2013), com base no algoritmo competitivo imperialista (ICA). Este trabalho considerou o método de Kern (1987) para análise do lado do casco. Considerando o projeto original, o algoritmo apresentou uma redução do custo total de 53 %, o que mostra o potencial do método proposto. Além disso, este algoritmo permite uma solução rápida do problema e permite examinar uma série de alternativas com soluções de boa qualidade, ou seja, gera um histórico de soluções para o problema de projeto

Hadidi e Nazari (2013) utilizaram um algoritmo baseado na biogeografia (BBO), que possui recursos apropriados para identificar o mínimo global em um espaço de busca desconhecido. Este algoritmo foi utilizado para minimizar a função objetivo custo total do trocador de calor casco e tubos. As variáveis de projeto adotadas foram: comprimento dos tubos, diâmetro externo dos tubos, passo e espaçamento dos defletores. Em um dos casos abordados a minimização da função objetivo reduziu o custo total do projeto em 56,1%.

Mohanty (2016a) utiliza o algoritmo do vaga-lume (FFA) para minimizar a função objetivo custo total relacionada ao projeto de dois trocadores de calor casco e tubos. Os resultados são promissores com uma redução do custo operacional total de 77 %, enquanto o custo total chega a ser 29 % menor quando comparado ao projeto original.

Outra abordagem proposta por Mohanty (2016b) utilizou o algoritmo de busca gravitacional (GSA) para minimizar o custo total de dois trocadores de calor casco e tubos e comparou com os resultados obtidos com outros algoritmos tais como: GA, PSO, ABC, BBO, CSA e FFA. Da comparação o autor verificou que o algoritmo GSA pode ser aplicado com sucesso para otimização de trocadores de calor casco e tubos sendo competitivo com outros métodos de otimização. Os resultados das simulações mostram que o custo operacional pode ser reduzido em 61,5 %, enquanto o custo total pode ser reduzido em 22,3 % em comparação com o projeto original.

O presente trabalho, aborda a otimização de parâmetros geométricos de um trocador de calor casco e tubos do ponto de vista econômico utilizando a meta-heurística GWO. É uma

técnica nova de inteligência por enxame ainda não aplicada a trocadores de calor contribuindo assim para o estado da arte. Além disso, este trabalho aborda em um dos casos a utilização de dados discretos para duas variáveis de otimização (número de passes nos tubos e diâmetro externo dos tubos) e para o comprimento dos tubos, já que a grande maioria dos esforços anteriores em otimização de projeto de trocadores de calor adotou apenas valores contínuos para determinar parâmetros como diâmetro e comprimento dos tubos. Segundo SMITH (2005), este tipo de abordagem fornece apenas projetos preliminares de equipamentos de transferência de calor sendo estes valores eventualmente corrigidos para atender aos padrões industriais.

3 MATERIAIS E MÉTODOS

Neste capítulo é descrita a metodologia adotada para atender os objetivos deste trabalho. Os modelos matemáticos foram implementados utilizando o *software* MATLAB[®], tendo em vista que os algoritmos de otimização e as funções de teste encontram-se desenvolvidos nesta linguagem de programação. As etapas seguem o fluxograma da Fig. (3.1) e serão descritas nas próximas seções.

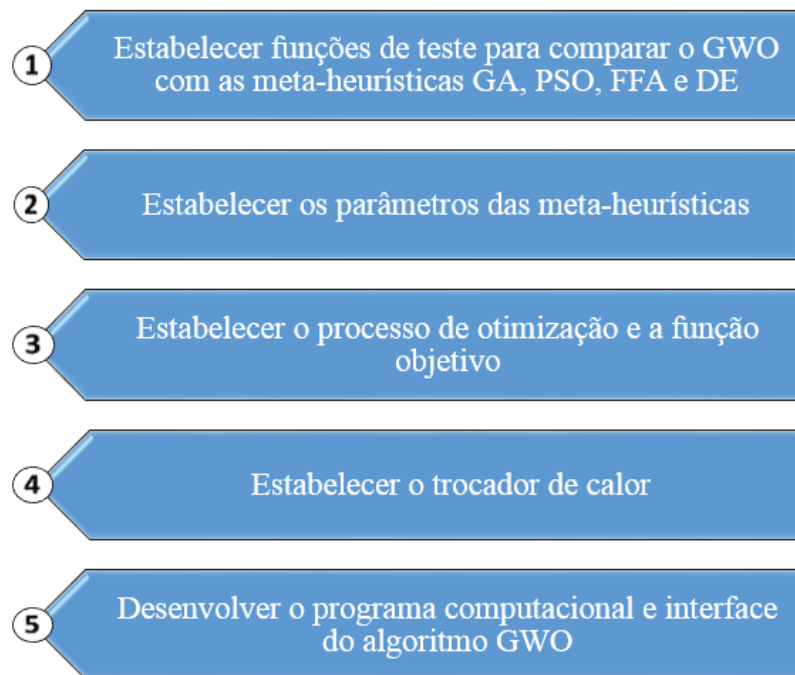


Figura 3.1 – Etapas da metodologia.

3.1 FUNÇÕES DE TESTE

As funções de teste, chamadas também de funções de *benchmarks*, são geralmente utilizadas quando deseja-se comparar o desempenho dos algoritmos de otimização (MOLGA e SMUTNICKI, 2005). Três funções de teste foram selecionadas da literatura para comparar o desempenho do algoritmo GWO com as metaheurísticas GA, PSO, DE e FFA, pois as mesmas já possuem resultados em otimização do projeto de trocadores de calor casco e tubos. Assim, a comparação permitirá uma avaliação preliminar do comportamento e desempenho do algoritmo GWO na otimização do trocador de calor proposto.

As funções de teste clássicas escolhidas foram: *Rosenbrock*, *Griewank* e *Ackley*. Estas funções possuem seu mínimo global em $f(x) = 0$. Foram adotadas 30 dimensões para a realização das simulações para as três funções de teste.

A função de Rosenbrock, conhecida também como vale, consiste em uma função não convexa e unimodal. Seu intervalo é definido entre $[-30, 30]$. O mínimo global está localizado no interior de um vale estreito e parabólico. Os algoritmos de otimização conseguem chegar ao vale com facilidade, porém possuem dificuldades de convergência para o mínimo global (PICHENY *et al.*, 2012). Sua forma analítica é dada por:

$$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2] \quad (3.1)$$

A Fig. (3.2) mostra graficamente a função de Rosenbrock para o caso de duas variáveis no intervalo de $[-2, 2]$.




Figura 3.2 - Função de Rosenbrock.

A função de Griewank é multimodal, possuindo inúmeros ótimos locais. Seu intervalo é definido entre $[-600, 600]$. A interpretação desta função se modifica com a escala. A visão geral sugere uma função convexa, a visão de média escala sugere a existência de mínimos locais e por fim, o exame mais próximo permite identificar uma estrutura complexa de inúmeros mínimos locais (MOLGA e SMUTNICKI, 2005). Sua forma analítica é dada por:

$$f(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \quad (3.2)$$

A Fig. (3.3) mostra graficamente a função de Griewank para o caso de duas variáveis. A figura é representada também no intervalo de $[-10,10]$ com a finalidade de melhorar sua visualização.




Figura 3.3 - Função de Griewank.

A função de Ackley é multimodal e possui vários ótimos locais. Seu intervalo é definido entre $[-32, 32]$. Esta função possui uma complexidade moderada, porém devido ao grande número de mínimos locais estes podem ocasionar convergências prematuras dos algoritmos de otimização (MOLGA e SMUTNICKI, 2005). Sua forma analítica é dado por:

$$f(x) = -20 \exp\left(-0,2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + \exp(1) \quad (3.3)$$

A Fig. (3.4) mostra graficamente a função de Ackley para o caso de duas variáveis. A figura é representada também no intervalo de $[-5, 5]$ com a finalidade de melhorar sua visualização.




Figura 3.4 - Função de Ackley.

3.2 DEFINIÇÃO DE PARÂMETROS DAS META-HEURÍSTICAS

O desempenho das meta-heurísticas é afetado pela seleção dos parâmetros utilizados na simulação computacional (EIBEN *et al.*, 1999).

Para cada meta-heurística a ser analisada neste trabalho são descritos os parâmetros utilizados e os valores selecionados a partir de simulações prévias. Apesar da literatura sugerir valores para a maioria dos parâmetros das diferentes meta-heurísticas, estes resolvem de maneira eficiente grande parte das aplicações, mas nem todas. Por isto, deve-se eventualmente flutuar o valor de um determinado parâmetro avaliando o comportamento do resultado da função objetivo.

Segundo Castro (2001), para o algoritmo genético - GA podemos listar os seguintes parâmetros:

Tamanho da população: populações muito pequenas podem não obter a abrangência total do espaço de busca. As populações muito grandes necessitam muito mais recursos computacionais para a solução do problema, caso contrário a meta-heurística irá necessitar de muito tempo computacional. Neste trabalho, este parâmetro obteve melhores resultados com valor igual a 150 após testes iniciais nas funções de *benchmarks*;

Número de gerações: este parâmetro depende da complexidade do problema devendo ser determinado experimentalmente. Neste trabalho este parâmetro é mantido em 500 para todos os algoritmos com o objetivo de tornar a comparação justa;

Taxa de cruzamento: este parâmetro é responsável por determinar a taxa com que ocorre o cruzamento entre os indivíduos que são selecionados na população. Valores geralmente utilizados são de 0,5 a 0,95;

Taxa de mutação: parâmetro que determina a taxa de uma mutação nos indivíduos da população. Geralmente a taxa de mutação é baixa, pois valores altos ocasionam uma busca essencialmente aleatória prejudicando a convergência em uma solução ótima. Em geral, os valores utilizados são de 0,001 a 0,1;

Critério de parada: geralmente é utilizado o número máximo de gerações, tempo limite de processamento ou ainda o critério de estagnação, ou seja, quando não se observa uma melhora no valor da função objetivo por um número determinado de gerações;

Seleção: a ideia básica deste processo segundo Linden (2006) consiste em permitir que os indivíduos mais aptos tenham maiores chances de reprodução. Em outras palavras este processo escolhe os melhores pais para o processo de reprodução, garantindo assim a evolução dos indivíduos (soluções). Além disso, o método deve permitir que alguns indivíduos menos aptos gerem seus descendentes, mantendo a diversidade entre os indivíduos. Caso apenas os melhores indivíduos reproduzirem, a população tenderá a ser cada vez mais semelhante, impossibilitando que ocorra a evolução.

Existem várias formas de seleção na literatura, no entanto, destaca-se a seleção por roleta e seleção por torneio. A seleção por roleta admite colocar os indivíduos em uma roleta onde a posição de cada indivíduo é proporcional a sua aptidão. Neste caso quanto maior a aptidão do indivíduo mais chances ele tem de ser escolhido.

A seleção por torneio geralmente é utilizada devido a sua simplicidade de aplicação e eficiência, além de preservar melhor a diversidade. Uma das vantagens deste método é que os indivíduos são selecionados aleatoriamente para a competição, não ocorrendo assim nenhum favorecimento aos indivíduos com maior aptidão, como ocorre no caso da seleção por roleta (LINDEN, 2006).

A Tab. (3.1) apresenta os valores dos parâmetros de entrada selecionados para o algoritmo genético (GA).

Tabela 3.1 – Parâmetros de entrada para o algoritmo genético - GA.

Parâmetros de entrada	Valor	Referência
Tamanho da população	150	-
Número máximo de gerações	500	-
Constante de cruzamento	0,7	HAUPT e HAUPT, 2004
Mutação	0,01	HAUPT e HAUPT, 2004
Tipo de seleção	Torneio	LINDEN, 2006

Para a otimização por enxame de partículas (PSO) os parâmetros de entrada são:

Tamanho da população: este parâmetro segundo Marini e Walczak (2015) pode ter um impacto no desempenho do algoritmo PSO. Uma população maior aumenta a diversidade do enxame e sua capacidade de exploração, mas por outro lado pode aumentar a probabilidade de convergência prematura (mínimos locais) e os esforços computacionais. No entanto, na maioria dos casos, foi demonstrado que quando o número de indivíduos é maior que 50, o PSO não é sensível ao tamanho da população. No entanto, as simulações deste trabalho obtiveram melhores resultados quando o tamanho da população é igual a 30.

Parâmetro social (C1) e cognitivo (C2): responsáveis por ajustar o balanço entre a influência social e a aprendizagem individual da partícula. Segundo Kennedy e Eberhart (1995) $C1=C2= 2$ permite obter bons resultados na maioria das aplicações;

Fator de inércia: também chamado de peso de inércia, originalmente foi introduzido como uma constante. No entanto, a implementação de um peso de inércia que decresce linearmente mostrou fornecer resultados muito bons em diversas aplicações reais. Desta forma normalmente valores de $w_{máx} = 0,9$ e $w_{mín} = 0,4$ alcançam os melhores resultados (MARINI e WALCZAK, 2015). Entretanto neste trabalho, o fator inercial mínimo ($w_{mín}$) mantido em 0,2 obteve melhores resultados nas três funções de teste.

A Tab. (3.2) apresenta os valores dos parâmetros de entrada selecionados para o algoritmo enxame de partículas (PSO).

Tabela 3.2 – Parâmetros de entrada para o algoritmo enxame de partículas - PSO.

Parâmetro de entrada	Valor	Referência
Tamanho da população	30	-
Número máximo de gerações	500	-
Fator inercial máximo ($w_{máx}$)	0,9	MARINI e WALCZAK, 2015
Fator inercial mínimo ($w_{mín}$)	0,2	-
Parâmetro social e cognitivo	2	KENNEDY e EBERHART, 1995

Segundo Das e Suganthan (2011), o algoritmo evolução diferencial (DE) possui três principais parâmetros: tamanho da população (NP), fator de escala de mutação (F) e constante de cruzamento ou *crossover* (CR).

Tamanho da população (NP): um valor razoável pode ser escolhido entre 5-D e 10-D, sendo D o número de dimensões do problema.

Fator de escala de mutação (F): uma boa escolha inicial para F é de 0,5, mas este fator pode variar aleatoriamente em um intervalo determinado. Valores típicos de F estão no intervalo $0,4 \leq F \leq 1$. Neste trabalho, este parâmetro obteve melhores resultados com valor de (F_{\min}) = 0,2 após testes iniciais nas funções de *benchmarks*;

Constante de cruzamento ou *crossover* (CR): o cruzamento pode assumir valores no intervalo $0 \leq CR \leq 1$. Valores típicos de CR estão no intervalo $0,3 \leq CR \leq 0,9$.

A Tab. (3.3) apresenta os valores dos parâmetros de entrada selecionados para o algoritmo evolução diferencial (DE).

Segundo Yang (2008), o algoritmo do vaga-lume (FFA) é controlado pelos seguintes parâmetros: parâmetro de randomização (α_r), atratividade mínima (β_f) e coeficiente de absorção de luz (γ). Este algoritmo possui vantagem sobre outras meta-heurísticas, pois não é sensível às variações desses parâmetros.

Parâmetro de randomização (α_r): tem a função de controlar a randomização do movimento durante o tempo. Seu valor está compreendido no intervalo $0 \leq \alpha_r \leq 1$. Segundo Yang (2008) este parâmetro possui desempenho satisfatório para $\alpha_r = 0,5$.

Tabela 3.3 – Parâmetros de entrada para o algoritmo evolução diferencial - DE.

Parâmetros de entrada	Valor	Referência
Tamanho da população (NP)	200	DAS e SUGANTHAN, 2011
Número máximo de gerações	500	-
Fator de escala de mutação (F_{\max})	0,8	DAS e SUGANTHAN, 2011
Fator de escala de mutação (F_{\min})	0,2	-
Constante de cruzamento (CR)	0,2	-

Atratividade mínima (β_f): Segundo Yang (2008) o desempenho satisfatório para $\beta_f = 0,2$.

Coeficiente de absorção de luz (γ): este parâmetro caracteriza a variação da atratividade, e seu valor determina a velocidade de convergência e comportamento do FFA. Para a maioria das aplicações seu valor pode variar de 0,1 a 10 (YANG, 2010a). De acordo com Yang (2008), é satisfatório com $\gamma = 1$.

Neste trabalho, o parâmetro tamanho da população de 15 para o algoritmo FFA obteve melhores resultados após testes iniciais nas funções de *benchmarks*.

A Tab. (3.4) apresenta os valores dos parâmetros de entrada selecionados para o algoritmo do vaga-lume (FFA).

Tabela 3.4 - Parâmetros de entrada para o algoritmo do vaga-lume - FFA.

Parâmetros de entrada	Valor	Referência
Tamanho da população	15	-
Número máximo de gerações	500	-
Parâmetro de randomização (α_r)	0,5	YANG, 2008
Atratividade mínima (β_f)	0,2	YANG, 2008
Parâmetro de absorção (γ)	1	YANG, 2008

Por fim, os parâmetros do algoritmo otimizador por lobo cinzento (GWO) foram definidos segundo (MIRJALILI *et al.*, 2014) e são apresentados na Tab. (3.5).

Tabela 3.5 - Parâmetros de entrada para o algoritmo otimizador por lobo cinzento - GWO.

Parâmetros de entrada	Valor	Referência
Tamanho da população	30	MIRJALILI <i>et al.</i> , 2014
Número máximo de gerações	500	MIRJALILI <i>et al.</i> , 2014

A definição dos parâmetros de entrada das meta-heurísticas GWO, GA, PSO, DE e FFA foi feita considerando vários testes até chegar aos parâmetros que proporcionaram o melhor desempenho para a minimização das três funções de teste. Além disso, é considerada a recomendação de seus respectivos autores. Os parâmetros selecionados são resultados de simulações iniciais independentes considerando populações de diferentes tamanhos.

Para a realização das simulações o critério de convergência é estabelecido em 500 gerações para as três funções de teste. São adotadas 30 simulações independentes por algoritmo para cada função, sendo calculados os valores mínimos e máximos, suas médias e o desvio padrão. Todas as simulações adotam os mesmos parâmetros conforme mostra as Tabs. (3.1) – (3.5).

3.3 OTIMIZAÇÃO E FUNÇÃO OBJETIVO

O procedimento para a identificação do projeto ideal de trocadores de calor casco e tubos segue as seguintes etapas (CAPUTO *et al.*, 2008):

- Estimativa da área de transferência de calor com base nas especificações de projeto;
- Avaliação da função objetivo selecionada;

- Utilização de um algoritmo de otimização para selecionar um novo conjunto de valores para as variáveis de projeto;
- Iteração das etapas anteriores até que a função objetivo atinja um mínimo global.

As variáveis de otimização com valores atribuídos iterativamente pelo algoritmo de otimização foram escolhidas analisando os diferentes trabalhos que compõem a revisão bibliográfica. A Tab. (3.6) mostra as variáveis de otimização adotadas em cada programa computacional.

Tabela 3.6 – Variáveis de otimização para cada programa computacional.

Variáveis de otimização – Método Kern	
d_o (m)	Diâmetro externo dos tubos
D_s (m)	Diâmetro interno do casco
L_{bc} (m)	Espaçamento entre os defletores
Variáveis de otimização – Método Bell-Delaware	
n (-)	Número de passes nos tubos
d_o (m)	Diâmetro externo dos tubos
D_s (m)	Diâmetro interno do casco
L_{bc} (m)	Espaçamento entre os defletores
B_c (%)	Corte dos defletores segmentados

Conforme o fluxograma da Fig. (3.5), a partir dos valores das especificações de projeto como a vazão mássica dos fluídos, condutividade térmica, resistência a incrustação, custo da energia, eficiência de bombeamento etc., e dos parâmetros fixos como o material, o arranjo dos tubos e a alocação das correntes de fluido e ainda dos valores atuais das variáveis de otimização, ou seja, o valor ajustado de cada variável pelo algoritmo de otimização durante determinando número de iterações, a rotina de projeto do trocador de calor determina os coeficientes de transferência de calor, as perdas de pressão e a área de transferência de calor, entre outros. Desta forma, definem-se os detalhes construtivos do trocador de calor. O algoritmo de otimização com base na função objetivo atualiza os valores das variáveis de otimização que são passadas para a rotina de projeto para definir um novo desenho do trocador de calor. O processo é iterativo até que a função objetivo encontre um mínimo global ou um critério de convergência prescrito seja atendido.

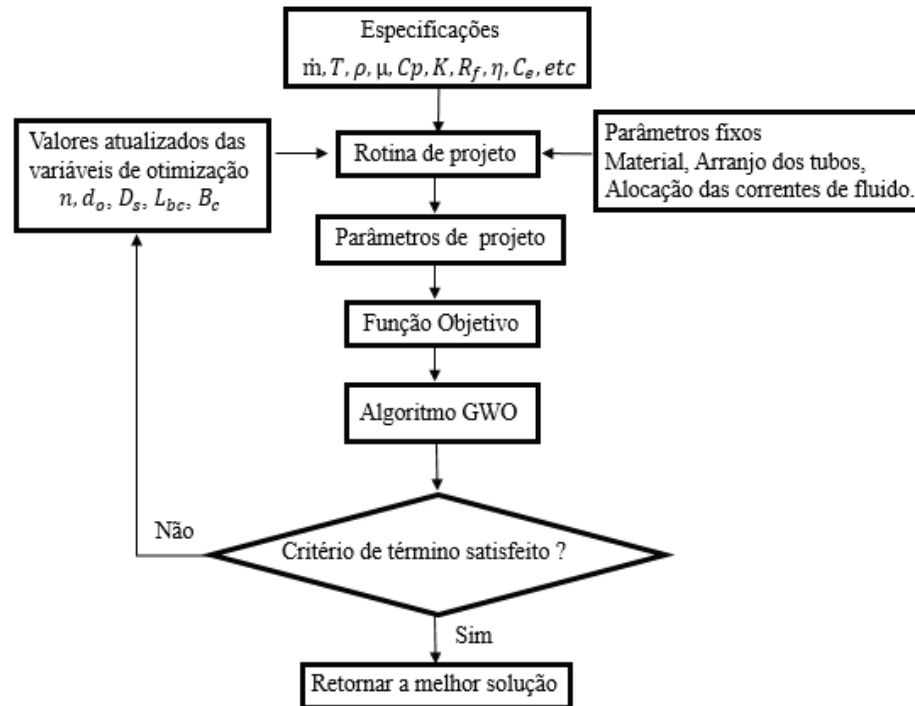


Figura 3.5 – Fluxograma do procedimento de projeto ideal de trocadores de calor.

Fonte: Adaptado de Caputo *et al.* (2008).

As abordagens na escolha da função objetivo variam muito, pois o conceito de um projeto “bom” envolve aspectos que não podem ser facilmente descritos em uma única função objetivo (COSTA e QUEIROZ, 2008).

Segundo Guo *et al.* (2009b), uma variedade de funções objetivo foram propostas nos últimos anos para otimização de trocadores de calor casco e tubos. Desta forma alguns autores utilizaram como função objetivo:

- O investimento de capital;
- O custo de energia relacionado com as perdas de pressão;
- Custo total de projeto;
- Taxa de geração de entropia;
- O número de sinergia dos campos;

Neste trabalho é abordada a análise tradicional relacionada com o custo total de projeto de trocadores de calor casco e tubos, onde o algoritmo de otimização busca minimizar a função objetivo. O modelo matemático que descreve a função objetivo custo total, C_{tot} , é dado por:

$$C_{tot} = C_i + C_{od} \quad (3.4)$$

onde, C_i é o investimento de capital e C_{od} é o custo operacional total descontado.

O investimento de capital é calculado conforme a correlação de Hall (TAAL *et al.*, 2003).

$$C_i = f_1 + f_2 A^{f_3} \quad (3.5)$$

sendo A a área de troca térmica, f_1, f_2 e f_3 são constantes que dependem do tipo de material empregado no projeto.

O custo operacional total é dado por:

$$C_{od} = \sum_{k=1}^{ny} \frac{C_o}{(1+i)^k} \quad (3.6)$$

onde, ny é o tempo de vida útil do equipamento, C_o é o custo anual de operação e i é a taxa de desconto anual.

O custo anual de operação, C_o , é dado em função da potência de bombeamento, P , do custo da energia, C_e e do tempo de operação anual, H , ou:

$$C_o = PC_e H \quad (3.7)$$

onde a potência de bombeamento é:

$$P = \frac{1}{\eta} \left(\frac{\dot{m}_t}{\rho_t} \Delta P_t + \frac{\dot{m}_s}{\rho_s} \Delta P_s \right) \quad (3.8)$$

sendo η a eficiência da bomba.

3.4 TROCADOR DE CALOR PROPOSTO

Um projeto de trocador de calor casco e tubos será otimizado pelo algoritmo GWO e os resultados serão comparados com os resultados utilizando outras meta-heurísticas assim, verificando o desempenho do algoritmo.

O trocador de calor selecionado para o estudo foi originalmente proposto por Sinnott *et al.* (2005), onde o projeto é realizado através do método convencional (não otimizado). Outros nove pesquisadores investigaram este mesmo projeto utilizando diferentes algoritmos meta-heurísticos para obter o projeto de forma otimizada. Este conjunto de dados de resposta será utilizado na comparação de resultados.

O trocador de calor casco e tubos possui um passe no casco e dois passes nos tubos (1:2 - TEMA E) projetado em aço inoxidável tanto casco como tubos, e utilizado para resfriar metanol com água. A corrente de água escoava através dos tubos a uma vazão mássica de 68,9 kg/s, temperatura de entrada de 25 °C e saída de 40 °C, enquanto a corrente de metanol entra no casco com uma vazão mássica de 27,8 kg/s e temperatura de 95 °C, saindo também a 40 °C. A taxa de calor total trocada é de 4,34 MW.

A configuração original é mantida e seus detalhes são apresentados na Fig. (3.6) e na Tab. (3.7).

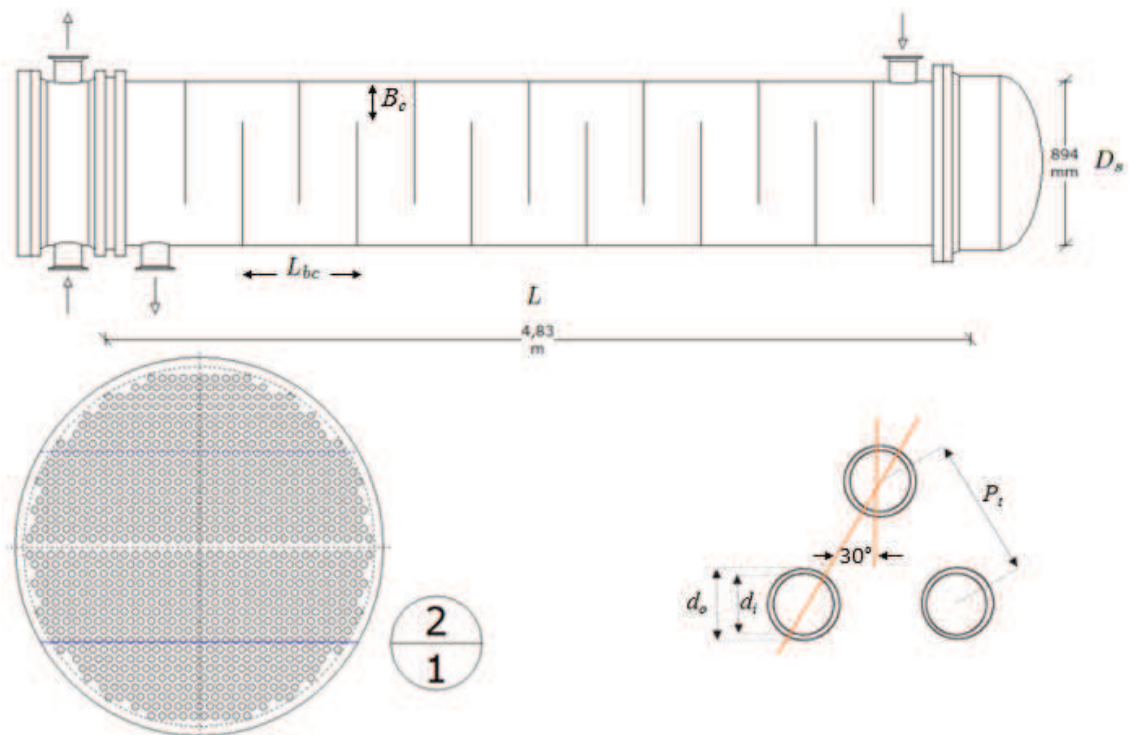


Figura 3.6 - Geometria do trocador de calor casco e tubos tipo TEMA E.

O valor referente a cada parâmetro da geometria é o resultado do cálculo do projeto pelo método convencional, ou seja, sem uso de ferramentas de otimização. É utilizado o arranjo dos tubos triangular 30°, pois o fluido do lado do casco é considerado limpo. O passo dos tubos considera a recomendação de $P_t \geq 1,25d_o$ (SAUNDERS, 1983).

Tabela 3.7 – Geometria do trocador de calor proposto.

Parâmetros		Valor
D_s (m)	Diâmetro interno do casco	0,894
d_o (m)	Diâmetro externo dos tubos	0,02
n (-)	Número de passes nos tubos	2
N_t (-)	Número total de tubos	918
θ (°)	Arranjo dos tubos - triangular	30
P_t (m)	Passo dos tubos	0,025
L (m)	Comprimento dos tubos	4,83
B_c (%)	Corte dos defletores	25
L_{bc} (m)	Espaçamento entre defletores	0,356

Fonte: Adaptado de Sinnott *et al.* (2005).

3.5 CONSTRUÇÃO DO PROGRAMA COMPUTACIONAL E INTERFACE DO ALGORITMO GWO

Dois programas computacionais distintos são desenvolvidos para o dimensionamento de trocadores de calor casco e tubos, utilizando o método de Kern e o método Bell-Delaware.

Os programas incorporam os modelos para análise do lado do casco e dos tubos, que permitem dimensionar de uma forma rápida e otimizada. Além disso, os programas são facilmente editados para acrescentar informações adicionais e testar diferentes correlações.

Para obter a comunicação entre o algoritmo de otimização e os programas de dimensionamento foi utilizado o chamado “arquivo de função” disponível no MATLAB[®], que possui argumentos de entrada e saída que podem conter uma ou mais variáveis.

A primeira linha executável de um arquivo de função deve ser a linha de definição da função, que tem a forma mostrada na Fig. (3.7).

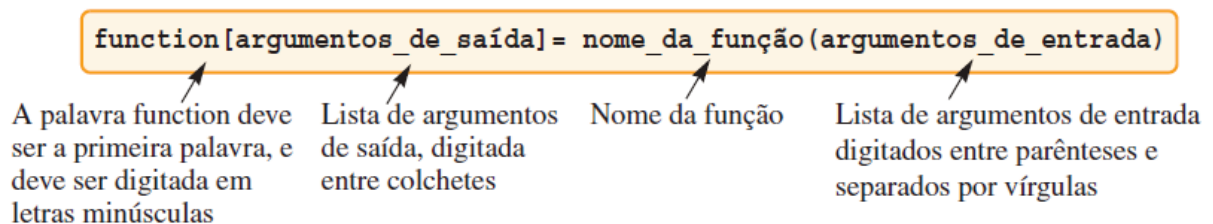


Figura 3.7 - Primeira linha executável de um arquivo de função.

Fonte: Gilat e Subramaniam (2008).

Os argumentos de entrada e saída são usados para transferir dados para dentro e para fora da função. O código que realiza os cálculos no interior do arquivo da função é escrito em termos dos argumentos de entrada e assume que a esses argumentos sejam atribuídos valores numéricos. Os argumentos de saída fazem a transferência da saída da função escrita em arquivo. Para que o arquivo de função funcione, os argumentos de saída devem receber valores no programa computacional escrito no corpo da função.

Após a linha de definição da função, o programa que efetivamente realiza os cálculos é implementado. Em um arquivo de função, as variáveis de entrada recebem valores cada vez que a função é chamada e assim são usadas nos cálculos no interior do arquivo da função. A Fig. (3.8) mostra um exemplo de como devem ser escritas as variáveis de otimização no *New Script* do MATLAB®.

```

1  function [Custo_Total]=Trocaador_de_calor (x)
2  %Variáveis de otimização.
3  n=x(1);    %Número de passes nos tubos.
4  d_o=x(2);  %Diâmetro externo dos tubos.
5  D_s=x(3);  %Diâmetro interno do casco.
6  L_bc=x(4); %Espaçamento dos defletores.
7  B_c=x(5);  %Corte dos defletores.

```

Figura 3.8 - Descrição das variáveis de entrada no *New Script* do MATLAB®.

Durante a implementação do código as variáveis de otimização são escritas nas equações substituindo o nome da variável (símbolo) por seu respectivo: $x(1)$, $x(2)$, $x(3)$, ..., $x(n)$.

Uma vez concluído o arquivo de função deve-se inicializar o algoritmo GWO para inserir os parâmetros iniciais de ajuste que compõe a interface do algoritmo. Os parâmetros são ajustados antes de sua utilização e se mantêm fixos durante as simulações. De acordo com Eiben *et al.* (1999) este método de ajuste é chamado de *offline (Parameter Tuning)*. A Fig. (3.9) mostra os detalhes da interface do algoritmo GWO onde:

- número de lobos cinzentos: é a população aleatória inicial de lobos cinzentos;
- número máximo de iterações: é quantas “gerações” são executadas no algoritmo e neste trabalho este é o critério selecionado para a interrupção na busca;
- limite inferior das variáveis de otimização: são os valores mínimos de cada variável de otimização;
- limite superior das variáveis de otimização: são os valores máximos de cada variável de otimização;

- número de variáveis: é o número total de variáveis de otimização que o código possui;
- função objetivo: é o nome da função. O arquivo (.m) que contém o código deve possuir o mesmo nome da função objetivo;
- valor ótimo de cada variável: é o valor ótimo de cada variável encontrado após o término das iterações;
- valor ótimo da função objetivo: é o valor ótimo do argumento de saída e neste trabalho o argumento de saída selecionado é o custo total do trocador de calor casco e tubos;
- curva de convergência: mostra a evolução da otimização durante o decorrer das iterações;
- a iteração atual é: indica em qual iteração o algoritmo se encontra;
- o valor ótimo atual é: corresponde ao valor ótimo da função objetivo.

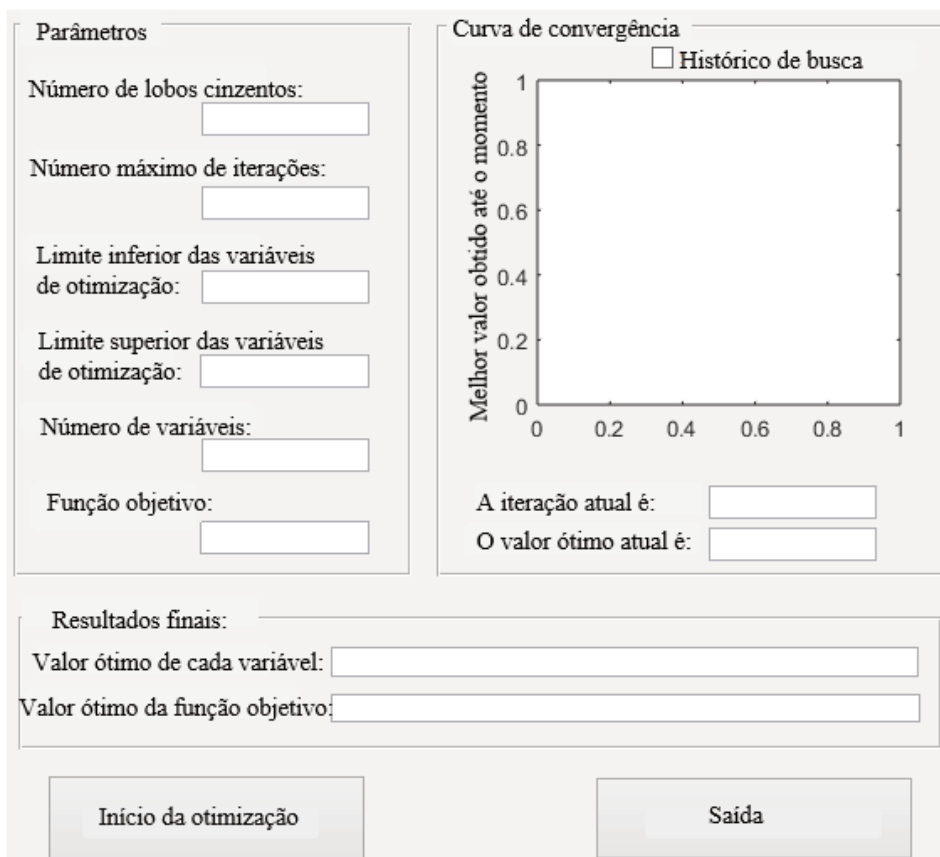


Figura 3.9 - Interface do algoritmo GWO.

Fonte: Adaptado de Mirjalili (2014).

A visualização das respostas do algoritmo GWO são apresentadas na aba *Command Window* do MATLAB[®]. Durante o processo de otimização pode ser visto nesta aba a evolução de cada resposta intermediária caso desejado.

As principais respostas ou saídas do algoritmo de otimização que são investigadas na comparação com o projeto original do trocador de calor proposto, bem como na comparação com os resultados das metaheurísticas apresentadas na revisão bibliográfica, são apresentadas na Tab. (3.8).

Tabela 3.8 – Respostas do algoritmo de otimização.

Respostas	
N_t (-)	Número total de tubos
v_t (m/s)	Velocidade do fluido dos tubos
v_s (m/s)	Velocidade do fluido do casco
Re_t (-)	Número de Reynolds do lado dos tubos
Re_s (-)	Número de Reynolds do lado do casco
h_t (W/m ² K)	Coefficiente de transferência de calor para o lado dos tubos
h_s (W/m ² K)	Coefficiente de transferência de calor para o lado do casco
ΔP_t (Pa)	Perda de pressão do lado dos tubos
ΔP_s (Pa)	Perda de pressão do lado do casco
U (W/m ² K)	Coefficiente global de transferência de calor
L (m)	Comprimento dos tubos
A (m ²)	Área de troca térmica
C_i (€)	Investimento de capital
C_o (€)	Custo anual de operação
C_{od} (€)	Custo operacional total descontado
C_{tot} (€)	Custo total

3.5.1 Métodos para a análise do casco

Os métodos para análise do trocador de calor devem considerar como dados de entrada:

- As propriedades físicas dos fluidos são obtidas considerando a temperatura média dos fluidos, ou seja, a média entre as temperaturas de entrada e saída;

- Os valores das constantes f_1 , f_2 e f_3 para o aço inoxidável (investimento de capital, Eq. 3.5), eficiência de bombeamento, tempo de operação anual, custo da energia, tempo de vida útil do equipamento e taxa de desconto anual, estão de acordo com os artigos que são utilizados na comparação de resultados;
- Os trabalhos publicados e que fazem parte da comparação dos resultados utilizaram o Euro (€) como moeda, desta forma se mantém a mesma moeda para efeitos de comparação dos resultados.

3.5.1.1 Detalhamento para simulação utilizando o método de Kern

Um grande número de trabalhos publicados com o objetivo de otimizar trocadores de calor casco e tubos utilizaram o método Kern para o lado do casco e diversas metaheurísticas foram testadas nos últimos anos com aplicação deste método. Desta forma, para comparar o desempenho do algoritmo GWO com as metaheurísticas de otimização em trocadores de calor este método também será empregado, sem considerar restrições geométricas, como foi adotado em trabalhos anteriores.

As metaheurísticas são:

- Algoritmo genético – GA (CAPUTO *et al.*, 2008);
- Algoritmo enxame de partículas – PSO (PATEL e RAO, 2010);
- Algoritmo colônia artificial de abelhas – ABC (SAHIN *et al.*, 2011);
- Algoritmo competitivo imperialista – ICA (HADIDI *et al.*, 2013);
- Algoritmo baseado na biogeografia – BBO (HADIDI e NAZARI, 2013);
- Algoritmo busca por cuco – CSA (ASADI *et al.*, 2014);
- Algoritmo do vaga-lume – FFA (MOHANTY, 2016a);
- Algoritmo de busca gravitacional – GSA (MOHANTY, 2016b);
- Algoritmo evolução diferencial - DE (VASCONSELOS *et al.*, 2017).

Além disso, os resultados da simulação são comparados com os resultados do projeto original do trocador de calor proposto.

De acordo com Smith (2005), a utilização de variáveis de otimização contínuas oferece apenas projetos preliminares para equipamentos de transferência de calor. Estes valores devem ser eventualmente corrigidos para atender os padrões e normas industriais. Assim, as variáveis de otimização selecionadas para a simulação com o método de Kern são consideradas contínuas,

tendo em vista que se trata de um projeto preliminar e que as publicações usadas no processo de comparação de resultados de otimização também assim consideraram. Na Tab. (3.9) são listadas as variáveis consideradas e os dados de entrada.

Tabela 3.9 – Variáveis de otimização e dados de entrada para o método de Kern.

Variáveis de otimização		Limite inferior	Limite superior
d_o (m)	Diâmetro externo dos tubos	0,006	0,060
D_s (m)	Diâmetro interno do casco	0,5	1,5
L_{bc} (m)	Espaçamento entre os defletores	0,2	0,7
Dados de entrada			
Alocação		Casco	Tubos
Fluido		Metanol	Água
R_f (m ² K/W)	Resistência à incrustação	0,00033	0,00020
a_1 (€)	Constante para aço inoxidável	8000	8000
a_2 (€/m ²)	Constante para aço inoxidável	259,2	259,2
a_3 (-)	Constante para aço inoxidável	0,91	0,91
η (-)	Eficiência de bombeamento	0,7	
H (horas)	Tempo de operação anual	7000	
C_e (€/kWh)	Custo da energia	0,12	
n_y (anos)	Tempo de vida útil do equipamento	10	
i (%)	Taxa de desconto anual	10	

Embora o método de Kern não leve em conta as correntes de vazamento e *bypass*, é um método simples de aplicar e é suficientemente preciso para cálculos de projeto preliminar e para projetos onde a incerteza e outros parâmetros de projeto não justificam o uso de métodos mais elaborados (SINNOTT *et al.*, 2005).

3.5.1.2 Detalhamento para simulação utilizando o método Bell-Delaware

As variáveis de otimização selecionadas inicialmente para a simulação com o método de Bell-Delaware possuem dados contínuos e também dados discretos, tendo em vista que esta simulação possui um conceito mais restritivo com o objetivo de atingir resultados mais

próximos aos padrões e normas como a TEMA. As variáveis de otimização adotadas neste caso, bem como os dados de entrada estão listados na Tab. (3.10).

Tabela 3.10 - Variáveis de otimização e dados de entrada para o método Bell-Delaware.

Variáveis de otimização discretas		Podem variar em:	
n (-)	Número de passes nos tubos	2,4,6 e 8	
d_o (mm)	Diâmetro externo dos tubos	15,88 – 19,05 – 22,23 – 25,40 – 31,75 – 33,10 – 50,80	
Variáveis de otimização contínuas		Limite Inf.	Limite Sup.
D_s (m)	Diâmetro interno do casco	0,5	1,5
L_{bc} (m)	Espaçamento entre os defletores	0,2	0,7
B_c (%)	Corte dos defletores segmentados	15	45
Dados de entrada			
Alocação		Casco	Tubos
Fluido		Metanol	Água
R_f (m ² K/W)	Resistencia à incrustação	0,00033	0,00020
a_1 (€)	Constante para aço inoxidável	8000	8000
a_2 (€/m ²)	Constante para aço inoxidável	259,2	259,2
a_3 (-)	Constante para aço inoxidável	0,91	0,91
η (-)	Eficiência de bombeamento	0,7	
H (horas)	Tempo de operação anual	7000	
C_e (€/kWh)	Custo da energia	0,12	
n_y (anos)	Tempo de vida útil do equipamento	10	
i (%)	Taxa de desconto anual	10	
N_{ss} (-)	Número de pares de tiras de selagem	0	

No processo de otimização utilizando o método Bell-Dellaware o espaço de soluções é restrito por alguns dos padrões da norma TEMA (2007). Os intervalos das restrições são:

$$3 \leq \frac{L}{D_s} \leq 15 \quad (3.9)$$

$$0,2 \leq \frac{L_{bc}}{D_s} \leq 1 \quad (3.10)$$

$$0,3 \leq \frac{L_{bi}}{D_s} = \frac{L_{bo}}{D_s} \leq 1 \quad (3.11)$$

$$0,18 \leq \frac{B_c}{D_s} \leq 0,4 \quad (3.12)$$

$$1,25 \leq \frac{P_t}{d_o} \leq 1,5 \quad (3.13)$$

Além disso, Sinnott et al. (2005) recomendam que a velocidade do fluido do lado dos tubos esteja entre 1 e 2,5 m/s e no lado do casco entre 0,3 e 1 m/s. As velocidades abaixo desses intervalos aumentam a taxa de incrustação e as velocidades superiores a estes intervalos aumentam a erosão e as vibrações.

Os resultados das simulações são comparados com o projeto original do trocador de calor proposto.

Para a realização das simulações o número de iterações estabelecidas como critério de parada do programa e a população aleatória inicial (lobos cinzentos) serão adotadas mediante a análise de desempenho dos resultados do algoritmo GWO nas funções de teste. Serão adotados 10 simulações independentes e o valor médio da função objetivo será adotado para comparação dos resultados.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados obtidos nas simulações sendo divididos em:

- comparação do desempenho do algoritmo GWO com as metaheurísticas GA, PSO, DE e FFA em três funções de teste.
- otimização do trocador de calor casco e tubos utilizando o método de Kern e comparação de resultados.
- otimização do trocador de calor casco e tubos utilizando o método Bell-Delaware e comparação de resultados.

4.1 COMPARAÇÃO DO DESEMPENHO DO ALGORITMO GWO

A Fig. (4.1) mostra as curvas de convergência para a *função de Rosenbrock*. Estas representam o melhor resultado encontrado de cada meta-heurística em 30 simulações. Pode-se observar que o algoritmo GWO possui rápida convergência quando comparado ao restante das meta-heurísticas.




Figura 4.1 -Curvas de convergência das meta-heurísticas para a *função de Rosenbrock*.

O melhor resultado obtido pela implementação do algoritmo GWO foi $f(x) = 26,0709$. Já o melhor resultado encontrado entre todas as meta-heurísticas foi $f(x) = 19,0172$ obtido pelo

algoritmo PSO, porém este algoritmo obteve o pior desempenho, obtendo a maior média e também o maior desvio padrão, entre todas as meta-heurísticas, como mostram os resultados da Tab. (4.1) e da Fig. (4.2). Isto ocorre, porque algumas simulações apresentaram convergência prematura (mínimos locais) ocasionando uma maior dispersão dos resultados. Também como pode ser verificado nestas mesmas figuras, o algoritmo GWO obteve o menor desvio padrão e a segunda menor média. No entanto, o algoritmo FFA obteve a menor média entre todos os algoritmos testados.

Tabela 4.1 - Comparação das meta-heurísticas para a *função de Rosenbrock*.

Algoritmo	μ	σ
GWO	27,16	0,72
GA	45,55	27,85
PSO	72,76	37,38
DE	61,56	19,95
FFA	26,61	1,05

A Fig. (4.2) mostra a mínima, máxima, mediana e a média das meta-heurísticas testadas.




Figura 4.2 - Comparação das meta-heurísticas para a *função de Rosenbrock*.

Trabalhos recentemente publicados também mostram dificuldades em encontrar o mínimo global ($f(x) = 0$) para *função de Rosenbrock*. Segundo Heidari e Pahlavani (2017) o

valor médio encontrado pelo algoritmo GWO foi $f(x)_{\text{médio}} = 24,74$ e desvio padrão = 51,82. O valor médio encontrado pelo algoritmo PSO foi $f(x)_{\text{médio}} = 85,03$ e desvio padrão = 50,40.

Lu *et al.* (2018) obtiveram um valor médio pelo algoritmo GWO de $f(x)_{\text{médio}} = 25,75$ e desvio padrão = 0,73. Além disso, Al-Betar *et al.* (2018) propõem novas versões do algoritmo GWO modificando os métodos de seleção desta meta-heurística. Mesmo assim, o melhor resultado encontrado pelos autores foi $f(x)_{\text{médio}} = 27,40$ e desvio padrão = 0,43 na versão TGWO (seleção por torneio).

A Fig. (4.3) mostra as curvas de convergência para a *função de Griewank*. Estas representam o melhor resultado encontrado de cada meta-heurística em 30 simulações. Mais uma vez o algoritmo GWO apresentou rápida convergência quando comparado ao restante das meta-heurísticas.




Figura 4.3 - Curvas de convergência das meta-heurísticas para a *função de Griewank*.

O melhor resultado obtido pela implementação do GWO foi $f(x) = 1,11 \times 10^{-16}$. Este valor corresponde ao melhor resultado encontrado entre todas as meta-heurísticas simuladas. No entanto, o valor da média e desvio padrão ficaram prejudicados, pois algumas simulações apresentaram convergência prematura (mínimos locais) ocasionando uma maior dispersão dos resultados como mostra a Fig. (4.4). O algoritmo genético, GA, foi a meta-heurística que apresentou a melhor média e o melhor desvio padrão, seguido pelo FFA, conforme mostram a

Tab. (4.2) e Fig. (4.4). O melhor resultado encontrado com relação às outras metaheurísticas foi para o GA de $f(x) = 4,14 \times 10^{-13}$.

Tabela 4.2 - Comparação das meta-heurísticas para a *função de Griewank*.

Algoritmo	μ	σ
GWO	$5,4323 \times 10^{-3}$	$8,7037 \times 10^{-3}$
GA	$1,4212 \times 10^{-8}$	$7,0586 \times 10^{-8}$
PSO	$5,7618 \times 10^{-3}$	$6,5896 \times 10^{-3}$
DE	$2,2724 \times 10^{-3}$	$1,7365 \times 10^{-3}$
FFA	$3,1936 \times 10^{-6}$	$1,3251 \times 10^{-5}$

A Fig. (4.4) mostra a mínima, máxima, mediana e a média das meta-heurísticas testadas pela *função de Griewank*. Pode-se notar que tanto o GA como o FFA possuem todos os pontos dos dados muito próximos de suas médias evidenciando assim os valores baixos de desvio padrão para ambas as meta-heurísticas.




Figura 4.4 - Comparação das meta-heurísticas para a *função de Griewank*.

Trabalhos recentemente publicados também mostram dificuldades em encontrar o mínimo global ($f(x) = 0$) para *função de Griewank*. O melhor resultado encontrado no trabalho de Lu *et al.* (2018) para GWO foi $f(x)_{\text{médio}} = 1,96 \times 10^{-3}$ e desvio padrão = $4,69 \times 10^{-3}$. Al-Betar *et al.* (2018), obtiveram valor médio pela nova versão do GWO, o algoritmo TGWO, igual a $f(x)_{\text{médio}} = 9,14 \times 10^{-4}$ e desvio padrão = $5,03 \times 10^{-3}$.

No resultados do trabalho realizado por Farnad *et al.* (2018), o valor médio encontrado pelo algoritmo DE é igual a $f(x)_{\text{médio}} = 1,48 \times 10^{-3}$ e o desvio padrão = $2,96 \times 10^{-3}$. Para o algoritmo PSO o valor médio encontrado foi de $f(x)_{\text{médio}} = 1,74 \times 10^{-2}$ e o desvio padrão = $2,08 \times 10^{-2}$.

Segundo Al-Betar *et al.* (2018), Apesar do GWO clássico proposto por Mirjalili *et al.* (2014) apresentar boa divisão entre a busca global passando gradualmente para uma busca local, ainda assim é tendencioso a realizar buscas locais. Isto justificaria em alguns casos a convergência prematura em mínimos locais.

No trabalho de Lu *et al.* (2018), o valor médio encontrado pelo algoritmo CGWO (nova versão do algoritmo GWO clássico) para a *função de Griewank* foi de $f(x)_{\text{médio}} = 0$ e desvio padrão = 0, mostrando melhorar a capacidade de lidar com as dificuldades de um cenário de pesquisa multimodal.

A Fig. (4.5) mostra as curvas de convergência para a *função de Ackley* com o melhor resultado encontrado de cada meta-heurística em 30 simulações. Mais uma vez o algoritmo GWO apresentou rápida convergência quando comparado ao restante das meta-heurísticas.




Figura 4.5 - Curvas de convergência das meta-heurísticas para a *função de Ackley*.

O melhor resultado obtido pela implementação do GWO foi $f(x) = 6,83 \times 10^{-14}$. Este valor corresponde ao melhor resultado encontrado entre todas as meta-heurísticas simuladas.

Conforme mostram a Tab. (4.3) e a Fig. (4.6) o algoritmo GWO e o GA obtiveram o menor desvio padrão e a menor média. O FFA também apresentou resultados satisfatórios de média e desvio padrão, muito próximos do GWO e GA. Os resultados do PSO ficaram prejudicados devido a algumas das simulações apresentarem convergência prematura (mínimos locais) ocasionando uma maior dispersão dos resultados como mostra a Fig. (4.6).

Tabela 4.3 - Comparação das meta-heurísticas para a *função de Ackley*.

Algoritmo	μ	σ
GWO	$1,0475 \times 10^{-13}$	$1,9246 \times 10^{-14}$
GA	$1,8744 \times 10^{-7}$	$8,0322 \times 10^{-8}$
PSO	$1,3352 \times 10^{-2}$	$6,4494 \times 10^{-3}$
DE	$4,5661 \times 10^{-3}$	$7,1878 \times 10^{-4}$
FFA	$1,1377 \times 10^{-4}$	$1,0479 \times 10^{-5}$




Figura 4.6 - Comparação das meta-heurísticas para a *função de Ackley*.

Segundo Heidari e Pahlavani (2017) o valor médio encontrado na *função de Ackley* pelo algoritmo GWO foi $f(x)_{médio} = 1,12 \times 10^{-13}$ e desvio padrão = $8,50 \times 10^{-2}$. A nova versão do

algoritmo GWO proposto por Heidari e Pahlavani (2017) modifica a randomização do movimento das soluções alterando a geração de números aleatórios do GWO clássico que utiliza a distribuição uniforme passando a utilizar os voos de Lévy (*Lévy flight*) passando a se chamar LGWO. Nesta versão o LGWO obtém $f(x)_{\text{médio}} = 2,12 \times 10^{-15}$ e desvio padrão = $4,29 \times 10^{-2}$. Existem vários métodos probabilísticos que podem ser utilizados na randomização do movimento de soluções como é o caso da distribuição uniforme (utilizada no GWO clássico), distribuição Gaussiana (Normal), Voos de Lévy etc. No trabalho de Farnad *et al.* (2018), o valor médio encontrado pelo algoritmo PSO é igual a $f(x)_{\text{médio}} = 1,64 \times 10^{-1}$ e desvio padrão de $4,93 \times 10^{-1}$.

Os resultados aproximados de diferentes autores para a mesma função de teste são justificados pela natureza não determinística das meta-heurísticas. Isto ocorre porque estes algoritmos diante dos mesmos parâmetros de entrada podem produzir resultados diferentes, visto que durante seu processamento ocorre a geração de números aleatórios.

Nestes casos abordados o algoritmo GWO mostrou ser capaz de fornecer resultados competitivos em comparação com as outras meta-heurísticas, evidenciando possuir potencial de apresentar bons resultados na otimização de trocadores de calor casco e tubos.

4.2 OTIMIZAÇÃO DO TROCADOR DE CALOR - MÉTODO DE KERN

Para a realização das simulações o número de iterações estabelecido como critério de parada do programa e a população aleatória inicial (lobos cinzentos) foram adotados mediante a análise (desempenho) dos resultados do algoritmo GWO nas três funções de teste.

As simulações, considerando o tamanho da população aleatória inicial de 30 (lobos cinzentos), apresentaram o melhor desempenho na minimização da função objetivo nas três funções de teste. No entanto, o algoritmo GWO possui uma característica de rápida convergência como observado nos resultados das funções de teste. Desta forma, o número máximo de iterações estabelecido para estas simulações foi 100, após alguns testes da função objetivo custo total.

A Fig. (4.7) mostra as curvas de convergência da função objetivo custo total. O algoritmo GWO neste caso convergiu em menos de 20 iterações em todas as simulações, como representado na figura. Pode ser observado o comportamento estocástico do GWO na seleção dos valores iniciais das variáveis de otimização, ou seja, o início da pesquisa começa em diferentes regiões do espaço de busca.




Figura 4.7 – Curvas de convergência do algoritmo GWO para o método de Kern.

No entanto, o valor ótimo de cada variável de otimização, selecionada após 100 iterações pelo algoritmo GWO em cada simulação, apresentam valores muito próximos. A Fig. (4.8) mostra os valores ótimos das variáveis de otimização, diâmetro externo dos tubos, diâmetro interno do casco e espaçamento entre os defletores, correspondente a dez simulações independentes. Apesar do comportamento estocástico desta meta-heurística, os resultados ótimos encontrados para as variáveis de otimização apresentam baixa variabilidade.

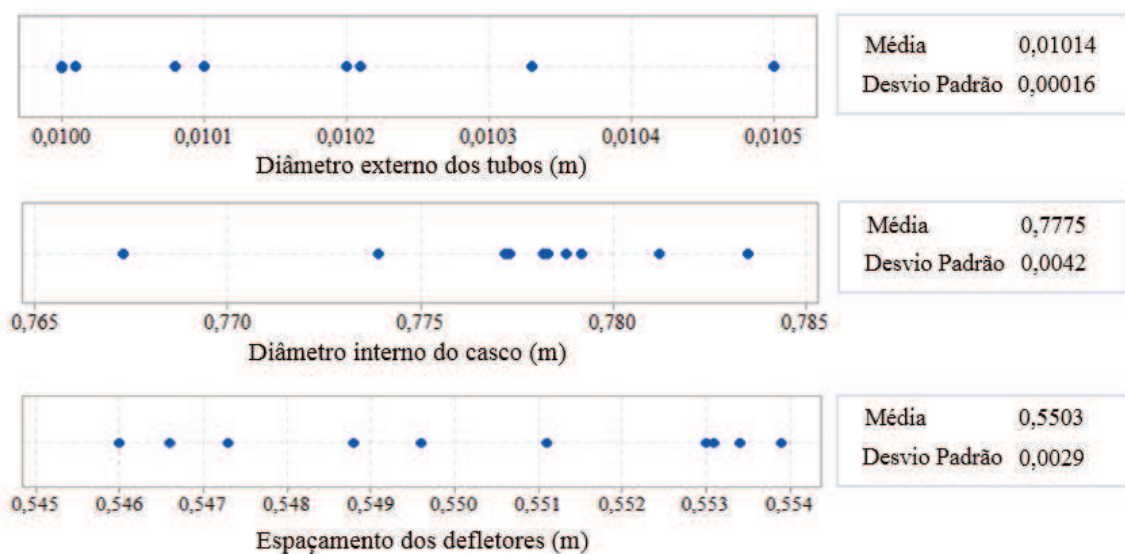


Figura 4.8 – Resultados ótimos das variáveis de otimização.

A Fig. (4.9) mostra o histórico de busca, ou seja, o histórico de soluções ao longo das iterações. Segundo Mirjalili *et al.* (2014), no GWO metade das iterações é dedicada à pesquisa global quando $|A| > 1$ e o restante das iterações é dedicado à pesquisa local quando $|A| < 1$. Pode ser observado na Fig. (4.9) que no início das iterações o GWO procura de forma mais global possível passando de forma gradual para uma pesquisa local, ou seja, busca melhorar o resultado já encontrado.




Figura 4.9 - Histórico de busca do algoritmo GWO para o método de Kern.

Como o tamanho da população aleatória inicial é igual a 30 e o número de iterações é igual a 100, temos 3000 avaliações da função objetivo custo total.

A Tab. (4.4) mostra os resultados das simulações e os dados de projeto conforme SINNOTT *et al.* (2005) além de mostrar os resultados de cada meta-heurística publicada. É realizada a comparação de resultados considerando os valores médios das dez simulações com o projeto original e com resultados de otimização de diferentes meta-heurísticas.

O apêndice B mostra em detalhes os resultados de cada simulação deste trabalho utilizando o algoritmo GWO.

Tabela 4.4 – Resultados para o projeto original e as meta-heurísticas GA, ICA, PSO, ABC, BBO, GSA, CSA, DE, FFA e GWO.

	Projeto original	GA	ICA	PSO	ABC	BBO	GSA	CSA	DE	FFA	GWO
d_o (m)	0,020	0,016	0,015	0,015	0,0104	0,010	0,015	0,0151	0,0114	0,01575	0,01014
D_s (m)	0,894	0,830	0,879	0,810	1,3905	0,801	0,842	0,826	0,729	0,858	0,7775
L_{bc} (m)	0,356	0,500	0,500	0,424	0,4669	0,500	0,486	0,414	0,450	0,402	0,5503
N_t (-)	918	1567	1752	1658	1528	3587	1806	1754	2405	1692	3464
v_t (m/s)	0,750	0,69	0,69	0,67	0,36	0,77	0,678	0,65	0,88	0,656	0,773
v_s (m/s)	0,580	0,44	0,42	0,53	0,118	0,46	0,453	0,56	0,57	0,54	0,433
Re_t (-)	14925	10936	10429	10503	-	7643	10118	10031	10004	10286	7804,52
Re_s (-)	18381	11075	9917	12678	-	7254	10662	13716	8875	12625	6891,97
h_t (W/m ² K)	3812	3762	3864	3721	3818	4314	4029	6104	9381	6228	4286,33
h_s (W/m ² K)	1573	1740	1740	1950,8	3396	2197	2060	2083	2414	1991	2062,26
U (W/m ² K)	615	660	677	713,9	832	755	732,6	848,2	887	876,4	737,24
A (m ²)	278,60	262,8	256,6	243,2	230,109	229,95	236,9	209,1	195,8	202,3	235,594
L (m)	4,830	3,379	3,107	3,115	3,963	2,04	2,783	2,332	2,274	2,416	2,135
ΔP_t (Pa)	6251	4298	5122	4171	3043	6156	4501	4186	4600	4246	6768,43
ΔP_s (Pa)	35789	13267	12367	20551	8390	13799	12458	22534	22829	18788	11259,40
C_o (€)	2111	947	975	1038,7	1014,5	984	813,2	1174,4	-	1040	930,35
C_{od} (€)	12973	5818	5995	6778,2	6233,8	6046	4673	7281,4	7514,38	6446	5716,6
C_i (€)	51507	49259	48370	46453	44559	44536	45439	40343,7	39562,8	39336	45351,4
C_{tot} (€)	64480	55077	54366	53231	50793	50582	50112	47625,1	47077,2	45782	51068

Em todos os casos abordados na Tab (4.4) o número de passes nos tubos (n) é igual a 2 passes e o corte dos defletores (B_c) é igual a 25 %.

Os resultados comparados ao projeto original Fig. (3.6) mostram um aumento no espaçamento dos defletores de 54,57 %, além de uma redução do comprimento dos tubos em 55,80 % ocasionando uma redução de 13 para 3 defletores.

Além disso, ocorre uma redução de 49,29 % do diâmetro externo dos tubos e 13,03 % do diâmetro interno do casco. Desta forma, o algoritmo GWO utiliza a estratégia de aumentar o número de tubos em 277 %. Este valor é 3,42 % menor que o número de tubos encontrado pelo algoritmo BBO. No entanto, este valor ficou bem acima dos resultados encontrados pelo restante das meta-heurísticas como mostra a Fig. (4.10).




Figura 4.10 - Número total de tubos segundo cada meta-heurística.

Devido a redução do diâmetro externo dos tubos, a velocidade do fluido do lado dos tubos aumenta em 3 % quando comparada ao projeto original. No entanto, a diferença na velocidade do fluido não é significativa, pois o maior número de tubos acabou compensado em parte a redução do diâmetro externo dos tubos. Devido principalmente ao aumento acentuado do número total de tubos o número de Reynolds é reduzido em 47,71 % comparado ao projeto original. Os resultados do número de Reynolds, considerando a melhor solução em cada simulação deste trabalho, permanecem no intervalo de 7589 a 7997 com valor médio igual a

7804,52. Este resultado é 2,11 % maior comparado ao resultado encontrado pelo algoritmo BBO.

Posteriormente, o coeficiente de transferência de calor para o lado dos tubos é obtido pelo algoritmo GWO sendo maior em 12,44 %, 13,94 %, 10,93 %, 15,19 %, 12,27 % e 6,39 % comparado ao projeto original, GA, ICA, PSO, ABC e GSA respectivamente. No entanto, apresentou resultado inferior em 0,64 %, 29,78 %, 54,31 % e 31,18 % comparado as meta-heurísticas BBO, CSA, DE e FFA respectivamente como mostra a Fig. (4.11).




Figura 4.11- Coeficiente de transferência de calor do lado dos tubos de cada meta-heurística.

O algoritmo DE possui o maior coeficiente de transferência de calor do lado dos tubos. Este resultado é justificado em parte por este algoritmo obter a maior velocidade do fluido entre todos os métodos de otimização, além de manter o número de Reynolds > 10000 , com diâmetros externo e interno dos tubos entre os menores valores.

Do lado do casco, a velocidade do fluido é reduzida em 25,31 % comparado ao projeto original. O algoritmo GWO aumenta o espaçamento dos defletores em 54,57 % compensando a redução de 13,03 % do diâmetro interno do casco. Além disso, ocorre redução do passo tubular devido a redução do diâmetro externo dos tubos pois $P_t = 1,25d_o$. Desta forma, a área de escoamento (Eq. 2.1) aumenta e a velocidade do fluido diminui.

O número de Reynolds do lado do casco diminui em 62,50 % comparado ao projeto original, devido à redução da velocidade do fluido e também da redução do diâmetro equivalente (Eq. 2.4), já que este diminui com a redução do diâmetro externo dos tubos. Esta

redução do número de Reynolds prejudica o coeficiente de transferência de calor do lado do casco. No entanto, com a redução do diâmetro equivalente o coeficiente de transferência de calor do lado do casco permanece acima do resultado obtido pelo projeto original como mostra a Fig. (4.12).

O coeficiente de transferência de calor do lado do casco obtido pelo algoritmo GWO foi maior que o coeficiente do projeto original, GA, ICA, PSO, GSA e FFA em 31,10 %, 18,52 %, 18,52 %, 5,71 %, 0,11 % e 3,58 %, respectivamente. No entanto, ficou abaixo em 39,27 %, 6,13 %, 1 %, 14,57 % comparado ao algoritmo ABC, BBO, CSA e DE, respectivamente, conforme mostra a Fig. (4.12). O resultado satisfatório do coeficiente de transferência de calor do lado do casco ocorre devido ao algoritmo GWO reduzir o diâmetro externo dos tubos e consequentemente seu diâmetro equivalente compensado em parte o valor baixo do número de Reynolds do lado do casco favorecendo assim transferência de calor (Eq. 2.8).




Figura 4.12 – Coeficiente de transferência de calor do lado do casco de cada meta-heurística.

Uma vez calculado o coeficiente de transferência de calor do lado dos tubos, h_t , e do lado do casco, h_s , é obtido o coeficiente global de transferência de calor, U , que teve um aumento de 19,88 %, 11,70 %, 8,90 %, 3,27 % e 0,63 % em relação ao projeto original, GA, ICA, PSO e GSA que por sua vez, leva a redução da área de troca térmica em 15,44 %, 10,35%, 8,19 %, 3,13 % e 0,55 % comparado ao projeto original, GA, ICA, PSO e GSA. No entanto, as meta-heurísticas ABC, BBO, CSA, DE e FFA obtiveram área de troca térmica menor comparado ao resultado do GWO justificado pelo valor mais alto do coeficiente global de transferência de calor obtido por estes métodos de otimização, como mostra a Fig. (4.13). Os

percentuais em vermelho na Fig. (4.13) referem-se aos resultados onde o algoritmo GWO foi superado pelo respectivo algoritmo de otimização utilizado para comparação.

As simulações com o método Kern não consideram a condição de que a área geométrica deve ser maior que a área de troca térmica com o objetivo de tornar a comparação justa com o restante dos trabalhos publicados e que fazem parte da comparação dos resultados. Neste caso, o algoritmo GWO obteve a área geométrica igual a área de troca térmica.




Figura 4.13 – Área de troca térmica e coeficiente global de transferência de calor de cada meta-heurística.

O algoritmo GWO utiliza a estratégia de elevar a velocidade do fluido do lado dos tubos, elevando assim a transferência de calor. No entanto, esta velocidade do fluido mais alta somada à redução do diâmetro dos tubos, acaba aumentando a perda de pressão, mesmo que o comprimento dos tubos seja reduzido em 55,80 % comparado ao projeto original. Os resultados de perda de pressão considerando a melhor solução em cada simulação deste trabalho permanecem no intervalo de 6,57 a 7,21 kPa com valor médio igual a 6,77 kPa. Este resultado é o maior valor encontrado comparado ao projeto original e outros métodos de otimização, conforme mostra a Fig. (4.14). No entanto, este valor de perda de pressão está bem abaixo da perda de pressão admissível de 70 kPa. Desta forma, é possível afirmar que a perda de pressão admissível é excessiva para o caso abordado nesta dissertação e que a minimização do custo total de projeto, C_{tot} , é obtido com perda de pressão, ΔP_t , 90,33% menor que a perda de pressão admissível.




Figura 4.14 – Perda de pressão do lado dos tubos de cada meta-heurística.

O algoritmo GWO utiliza a estratégia de reduzir a velocidade do fluido do lado do casco reduzindo consideravelmente a perda de pressão. A velocidade do fluido do lado do casco foi maior somente comparado aos resultados dos algoritmos ICA e ABC. Comparado ao projeto original a redução de perda de pressão chega a 68,54 %, como mostra a Fig. (4.15). Outro fator que contribuiu para a redução da perda de pressão foi o aumento do espaçamento entre os defletores que foi maior comparado a todas as meta-heurísticas analisadas. A Fig. (4.15) mostra a comparação dos resultados de perda de pressão do lado do casco. Somente a otimização utilizando o algoritmo ABC apresentou uma perda de pressão menor que o algoritmo GWO, que pode ser justificada em parte pela velocidade do fluido ser a menor entre todos os métodos de otimização, conforme mostrado na Fig. (4.15) e Tab. (4.4).




Figura 4.15 – Perda de pressão do lado do casco de cada meta-heurística.

Após calcular a área de troca térmica é possível obter o resultado do custo de investimento de capital. Comparado o resultado do algoritmo GWO ao projeto original, GA, ICA, PSO e GSA foi possível reduzir o custo em 11,95 %, 7,93 %, 6,24 %, 2,37 % e 0,19%, respectivamente. No entanto, o algoritmo GWO obteve o investimento de capital superior para o restante das meta-heurísticas.

O custo anual de operação e o custo operacional total descontado depende da perda de pressão do lado dos tubos e do lado do casco. Apesar da perda de pressão do lado dos tubos ter aumentado em relação ao projeto original e todos os métodos de otimização, a perda de pressão do lado do casco foi reduzida consideravelmente. Desta forma, o custo anual de operação, obtido pelo algoritmo GWO foi menor que o projeto original e o restante das metaheurísticas, exceto para o algoritmo GSA onde o resultado do algoritmo GWO foi 14,41% superior. Portanto, o custo operacional total descontado foi menor que o projeto original e o restante das metaheurísticas exceto para o algoritmo GSA onde o algoritmo GWO obteve resultado 22,33%, superior.

No geral, a redução combinada do investimento de capital e do custo operacional total descontado obtido pelo algoritmo GWO levaram a uma redução de custo total de 20,80%, 7,28%, 6,07 % e 4,06 % comparado ao projeto original, GA, ICA e PSO, respectivamente. Por outro lado, o custo total foi maior em 0,54 %, 0,96 %, 1,91 %, 7,27 %, 8,48 % e 11,55% comparado aos métodos ABC, BBO, GSA, CSA, DE e FFA respectivamente. A Fig. (4.16) mostra a comparação do custo total que inclui o investimento de capital e o custo operacional

total descontado para o projeto original e todos os métodos de otimização em ordem decrescente de custo total.

O desenho do trocador de calor obtido pelo algoritmo GWO utilizando o método Kern sem restrições encontra-se no apêndice C.




Figura 4.16 – Custo total de cada meta-heurística.

A estratégia de otimização utilizada pelo algoritmo GWO é muito parecida com o algoritmo BBO obtendo uma diferença de apenas 0,96 % no resultado da função objetivo custo total. Além disso, as variáveis de otimização obtiveram diferença de apenas 2,94 %, 10,06 % e 1,43 % para o diâmetro interno do casco, espaçamento dos defletores e diâmetro externo dos tubos, respectivamente. Estas diferenças são as menores encontradas entre todos os métodos de otimização. No caso do algoritmo ABC o resultado da função objetivo apresenta diferença de apenas 0,54 %. No entanto, as variáveis de otimização diâmetro interno do casco, espaçamento dos defletores e diâmetro externo dos tubos possuem diferença de 44,09 %, 17,86 % e 2,47%, respectivamente.

Outro ponto a ser observado é a estratégia de otimização adotada pelo algoritmo GWO. O investimento de capital intimamente ligado à área de troca térmica possui redução de apenas 11,95 %, enquanto que o custo operacional apresenta redução de 55,93 % comparado ao projeto original como mostra a Fig. (4.17).




Figura 4.17 – Estratégia de otimização adotada pelo algoritmo GWO.

Este resultado indica que a otimização do trocador de calor deve ser pesquisada pelo algoritmo de otimização principalmente em função das perdas de pressão, através da escolha adequada das velocidades dos fluidos, espaçamento dos defletores, comprimento dos tubos e demais parâmetros que afetam as perdas de pressão favorecendo assim, a redução do custo relacionado com a energia (perdas por bombeamento). No entanto, caso o custo da energia seja muito baixo esta situação pode se inverter.

Assim, se compararmos a diferença do investimento de capital entre o algoritmo GWO e o algoritmo ABC temos um aumento do investimento de capital de 792,4 € e uma redução do custo anual de operação de 84,15 €. Portanto, o período necessário para compensar o investimento de capital mais elevado é de 9,42 anos. Para o algoritmo BBO a diferença do investimento de capital comparado ao algoritmo GWO é de 815,4 € e a redução do custo anual de operação é de 53,65 €. Portanto, o período necessário para compensar o investimento de capital mais elevado é de 15,20 anos.

Por fim, é comparado o número de iterações para convergência de cada meta-heurística. Segundo Mirjalili *et al.* (2014), o algoritmo GWO é um algoritmo de rápida convergência identificando o ótimo global em um número de iterações bastante reduzido. Este comportamento é observado em todas as simulações realizadas. Comparado ao restante das meta-heurísticas somente o algoritmo PSO obteve convergência com um número de iterações menor que o obtido pelo algoritmo GWO como mostra a Fig. (4.18). A literatura não possui dados para a iteração de convergência dos algoritmos GA e ABC.




Figura 4.18 – Número de iterações para convergência de cada meta-heurística.

4.3 OTIMIZAÇÃO DO TROCADOR DE CALOR - MÉTODO BELL DELAWARE

O número máximo de iterações estabelecido para estas simulações permaneceu em 500, após alguns testes da função objetivo custo total. Apesar do algoritmo GWO possuir mecanismo de rápida convergência, neste caso abordado foi necessário um número maior de iterações.

Na Fig. (4.19) se apresentam as curvas de convergência da função objetivo custo total. O algoritmo GWO neste caso convergiu em menos de 20 iterações em todas as simulações. No entanto, é observado ao longo das iterações uma sensível minimização da função objetivo. Pode ser observado novamente o comportamento estocástico do GWO na seleção dos valores iniciais das variáveis de otimização, ou seja, o início da pesquisa começa em diferentes regiões do espaço de busca.




Figura 4.19 - Curvas de convergência do algoritmo GWO para o método Bell-Delaware.

Os valores ótimos de cada variável de otimização em dez simulações independentes apresentam baixa variabilidade apesar deste comportamento estocástico do GWO, como apresentado na Fig. (4.20).




Figura 4.20 - Resultados ótimos das variáveis de otimização.

Em todas as simulações o algoritmo GWO mantém o número de passes nos tubos igual a dois, pois o aumento do número de passes nos tubos aumenta sensivelmente o coeficiente global de transferência de calor resultando em uma ligeira redução da área de troca térmica e, portanto, redução do investimento de capital. No entanto, ocorre aumento acentuado da perda de pressão do lado dos tubos ocasionando o aumento acentuado do custo operacional e consequentemente aumento da função objetivo custo total. A Fig. (4.21) mostra as curvas de convergência da função objetivo custo total para diferentes números de passes nos tubos.




Figura 4.21 - Curvas de convergência da função objetivo para diferentes números de passes nos tubos.

Outra variável de otimização que permanece em todas as simulações é o diâmetro externo dos tubos que mantém o valor de 15,88 mm. Isto ocorre principalmente pela redução do coeficiente global de transferência de calor e, conseqüentemente, aumento da área de troca térmica resultando em um aumento do investimento de capital e do custo total, não compensada neste caso pela ligeira redução do custo operacional à medida que o diâmetro externo dos tubos aumenta. A Fig. (4.22) mostra as curvas de convergência da função objetivo custo total para diferentes diâmetros externos de tubos.




Figura 4.22 - Curvas de convergência da função objetivo para diferentes diâmetros externos dos tubos.

A Fig. (4.23) mostra o histórico de soluções ao longo das iterações. Mais uma vez é observado que no início das iterações o GWO procura de forma mais global possível passando de forma gradual para uma pesquisa local.




Figura 4.23 - Histórico de busca do algoritmo GWO para o método de Bell-Delaware.

Como o tamanho da população aleatória inicial é igual a 30 e o número de iterações é igual a 500, temos 15000 avaliações da função objetivo custo total.

A Tab. (4.5) mostra os valores médios de dez simulações e os dados do projeto original (SINNOTT *et al.*, 2005) para comparação. É realizada a comparação de resultados considerando os valores médios das dez simulações com o projeto original.

A justificativa para a diferença nos resultados obtidos pelo método Kern e pelo método Bell-Delaware está associado principalmente a utilização das restrições geométricas. Estas são responsáveis por “orientar” o algoritmo GWO a obter resultados dentro dos padrões da norma (TEMA 2007). Outros fatores que contribuem para a diferença nos resultados são: utilização de restrições para velocidade dos fluidos e a utilização de dados discretos para o diâmetro externo dos tubos utilizados nas simulações com o método Bell-Delaware.

O apêndice B mostra em detalhes os resultados de cada simulação deste trabalho utilizando o algoritmo GWO.

Tabela 4.5 - Resultados do projeto original e do algoritmo GWO.

	Projeto original Sinnott <i>et al.</i> (2005)	Resultados pelo Algoritmo GWO (método Bell-Delaware)	Resultados pelo Algoritmo GWO (método Kern)
n (-)	2	2	2
d_o (m)	0,020	0,01588	0,01014
D_s (m)	0,894	0,7217	0,7775
L_{bc} (m)	0,356	0,4722	0,5503
B_c (%)	25	28,61	25
N_t (-)	918	1090	3464
v_t (m/s)	0,750	1,0025	0,773
v_s (m/s)	0,580	0,5195	0,433
Re_t (-)	14925	15845	7804,52
Re_s (-)	18381	18199,1	6891,97
h_t (W/m ² K)	3812	5447,61	4286,33
h_s (W/m ² K)	1573	1927,0	2062,26
U (W/m ² K)	615	752,74	737,24
A (m ²)	278,60	230,72	235,594
L (m)	4,830	4,877	2,135
ΔP_t (kPa)	6,251	13,158	6,768
ΔP_s (kPa)	35,789	12,004	11,259
C_o (€)	2111	1423,86	930,35
C_{od} (€)	12973	8749,15	5716,6
C_i (€)	51507	44647,70	45351,4
C_{tot} (€)	64480	53396,85	51068

Os resultados comparados ao projeto original mostram um aumento no espaçamento dos defletores, L_{bc} , de 32,63 %, além de um aumento do comprimento dos tubos, L , em 0,97 % ocasionando uma redução de 13 para 9 defletores, N_b . Além disso, os diâmetros externo dos tubos e o interno do casco reduzem 20,60% e 19,28%, respectivamente, e o número total de tubos aumenta em 18,69 % respeitando a condição de que a área geométrica deve ser maior que a área de troca térmica. Neste caso, a área geométrica é 14,94 % maior que a área de troca térmica.

O aumento do número de tubos, a redução do diâmetro externo dos tubos e o número de passes do lado dos tubos é condicionado pela restrição para velocidade do fluido do lado dos tubos que deve permanecer entre $1 \leq v_t \leq 2,5$ m/s. Em todas as simulações a velocidade do fluido busca manter-se no limite inferior da restrição imposta, pois valores elevados de velocidade do fluido ocasionam aumento da perda de pressão (aumento do custo operacional) não compensado pelo aumento do coeficiente de transferência de calor (redução do investimento de capital) aumentando assim o custo total, conforme mostram as curvas da Fig. (4.24).




Figura 4.24 - Curvas de convergência da função objetivo para diferentes velocidades do fluido do lado dos tubos.

Com a redução do diâmetro dos tubos ocorre aumento da velocidade do fluido em 33,67%, portanto, o número de Reynolds aumenta em 6,16 %.

Os resultados do número de Reynolds considerando a melhor solução em cada simulação permanecem no intervalo de 15.807 a 15.972, com valor médio igual a 15.845, ou seja, regime de escoamento turbulento plenamente desenvolvido. Como resultado da redução do diâmetro externo dos tubos e aumento do Re, o coeficiente de transferência de calor para o lado dos tubos, h_t , é 42,91 % maior.

A velocidade do fluido mais alta acaba favorecendo a transferência de calor. Por outro lado, favorece também o aumento da perda de pressão em 110,49 %. Outros fatores que contribuem para este aumento acentuado é a redução do diâmetro dos tubos e o aumento do

comprimento dos tubos. Os resultados de perda de pressão considerando a melhor solução em cada simulação permanecem no intervalo de 13,10 kPa a 13,35 kPa com valor médio igual a 13,16 kPa. Este resultado permanece bem abaixo da perda de pressão admissível de 70 kPa. Desta forma, é possível afirmar que a perda de pressão admissível é excessiva para este caso abordado nesta dissertação e que a minimização do custo total de projeto, C_{tot} , é obtido com perda de pressão, ΔP_t , 81,20 % menor que a perda de pressão admissível.

Do lado do casco, a velocidade do fluido é reduzida em 10,43 %. O algoritmo GWO aumenta o espaçamento dos defletores em 32,63 % compensando a redução de 19,28 % do diâmetro interno do casco. Além disso, ocorre redução do passo transversal e do passo tubular devido à redução do diâmetro externo dos tubos, pois $X_t = P_t = 1,25d_o$ para arranjo de tubos triangular 30°. Desta forma, a área de fluxo cruzado entre defletores (Eq. A.12) aumenta ocasionando a redução da velocidade do fluido.

Os resultados do número de Reynolds considerando a melhor solução em cada simulação permanecem no intervalo de 17.690 a 19.513 (valor médio de 18.199). O coeficiente de transferência de calor ideal é calculado, Eq. (2.11), e os valores médios para os fatores de correção na transferência de calor, considerando a melhor solução em cada simulação, permanecem nos intervalos recomendados pelo método: $J_c = 1,02$ (0,65 – 1,175), $J_l = 0,85$ (0,7 a 0,9), $J_b = 0,84$ (0,7 a 0,9), $J_s = 1$ (0,85 a 1) e $J_r = 1$ (0,4 a 1).

O fator de correção total da transferência de calor, J_{total} , dado pela Eq. (A.30) deve permanecer entre 0,4 e 1, ou segundo Shah e Sekulic (2003), este valor deve ser aproximadamente igual a 0,6. A Fig. (4.25) mostra a melhor solução encontrada após 500 iterações em cada simulação.




Figura 4.25 - Resultados do fator de correção total na transferência de calor.

Assim, o valor médio de J_{total} é igual a 0,7298, e os resultados mostraram que o processo de otimização mantém os fatores de correção na transferência de calor dentro dos limites estabelecidos para um bom projeto.

O coeficiente de transferência de calor real para o lado do casco, para a melhor solução em cada simulação permanece no intervalo de 1.902,8 a 1.988 W/m²K, com valor médio igual a 1.927 W/m²K, o qual é 22,50 % maior comparado ao coeficiente do projeto original.

Posteriormente, é calculada a perda de pressão ideal e os fatores de correção, Eq. (2.12), os quais também permanecem nos intervalos recomendados pelo método. Os valores médios para os fatores de correção, considerando a melhor solução em cada simulação, são: $\zeta_b = 0,6$ (0,5 a 0,8), $\zeta_l = 0,5$ (0,4 a 0,5) e $\zeta_s = 2$ (0,5 a 2). Da mesma forma que com o coeficiente de transferência de calor, estes resultados mostram que o processo de otimização mantém os fatores de correção na perda de pressão dentro dos limites estabelecidos para um bom projeto.

Assim, é calculada a perda de pressão real para o lado do casco e novamente o algoritmo GWO utiliza a estratégia de reduzir a velocidade do fluido do lado do casco, reduzindo consideravelmente a perda de pressão. Outro fator que contribuiu para a redução da perda de pressão foi o aumento do espaçamento entre os defletores que foi maior em 32,63 % e, conseqüentemente, reduziu de 13 para 9 defletores. Os resultados considerando a melhor solução em cada simulação permanecem no intervalo de 11,16 a 13,55 kPa, com valor médio igual a 12,0 kPa. Este resultado é 66,46 % menor comparado ao projeto original. Novamente a perda de pressão permanece bem abaixo da perda de pressão admissível de 70 kPa. Assim, é possível afirmar novamente que a perda de pressão admissível é excessiva para este caso abordado nesta dissertação e que a minimização do custo total de projeto, C_{tot} , é obtido com perda de pressão, ΔP_s , 82,60 % menor que a perda de pressão admissível.

Uma vez calculado o coeficiente de transferência de calor do lado dos tubos e do lado do casco é obtido o coeficiente global de transferência de calor, 22,4 % maior que o valor do projeto original, e a área de troca térmica, que diminuiu em 17,18 %.

Os resultados do coeficiente global de transferência de calor, considerando a melhor solução em cada simulação, permanecem no intervalo de 748,96 a 761,72 W/m²K, com valor médio igual a 752,74 W/m²K. Os valores para área de troca térmica ficaram no intervalo de 227,99 a 231,87 m², com valor médio igual a 230,72 m².

O resultado do investimento de capital ficou 13,32 % menor. O custo anual de operação e o custo operacional total descontado dependem da perda de pressão do lado dos tubos e do lado do casco. Apesar da perda de pressão do lado dos tubos ter aumentado, a perda de pressão do lado do casco foi reduzida, desta forma, o custo anual de operação reduziu 32,55%.

No geral, a redução combinada do investimento de capital e do custo operacional total descontado levaram a uma redução de custo total de 17,19 %. A Fig. (4.26) mostra a

comparação do custo total, que inclui o investimento de capital e o custo operacional total descontado.




Figura 4.26 – Comparação do custo total.

O desenho do trocador de calor obtido pelo algoritmo GWO utilizando o método Bell-Delaware com restrições geométricas e de velocidade dos fluidos encontra-se no apêndice C.

5 CONCLUSÕES

No presente trabalho, o algoritmo GWO é aplicado para obter o projeto ótimo de um trocador de calor do tipo casco e tubos. O objetivo do processo de otimização é a minimização da função objetivo custo total, que inclui o investimento de capital e o custo operacional total descontado. Os resultados são comparados com o projeto original e outros métodos de otimização. A metodologia proposta é aplicada considerando no primeiro caso o método de Kern para o dimensionamento do lado do casco. Já a segunda abordagem adota o método Bell-Delaware para o dimensionamento do lado do casco incluindo restrições geométricas de acordo com a norma TEMA juntamente com restrições para velocidade dos fluidos. Além disso, o algoritmo otimizador por lobo cinzento GWO é comparado com os algoritmos GA, PSO, DE e FFA em três funções de teste da literatura para testar seu desempenho.

O desempenho do algoritmo GWO como ferramenta de otimização foi avaliado através de três funções de teste. Na *função de Rosenbrock* o algoritmo GWO superou os algoritmos GA, PSO e DE e ficou apenas 2,03% acima do melhor resultado médio, $f(x)_{\text{médio}}$, encontrado pelo algoritmo FFA. Além disso, apresentou o menor desvio padrão entre todos os métodos de otimização mostrando ser um método que possui baixa variabilidade nos resultados. Comparando os resultados da média deste trabalho, $f(x)_{\text{médio}}$, obtido pela aplicação do algoritmo GWO com os resultados encontrados nos trabalhos de Heidari e Pahlavani (2017) e Lu *et al.* (2018), que tratam de novas versões do algoritmo GWO, a diferença no resultado da função objetivo, $f(x)$, é 8,9 % e 5,2 %, maior respectivamente. Os resultados do algoritmo GWO na *função de Ackley* mostram novamente a eficácia do método diante de outras meta-heurísticas. O melhor resultado médio e o menor desvio padrão mostram a baixa variabilidade dos mesmos, e a comparação dos resultados médios com os do trabalho de Heidari e Pahlavani (2017) a diferença no resultado da função objetivo, $f(x)$, é 6,92% menor. No entanto, os resultados das 30 simulações do algoritmo GWO na *função de Griewank* mostraram alta variabilidade no resultado da função objetivo, $f(x)$, que possivelmente se deve a principal desvantagem desta meta-heurística. O algoritmo GWO possui baixa capacidade de lidar com as dificuldades de um cenário de pesquisa multimodal (FARIS *et al.* 2017).

Na otimização do trocador de calor utilizando o método Kern o algoritmo GWO apresentou resultados próximos aos encontrados pelo algoritmo BBO (Hadidi e Nazari, 2013), ou seja, mostra uma estratégia bastante parecida durante o processo de otimização. A diferença do resultado da função objetivo custo total, C_{tot} , foi de 0,96 %. Comparado ao projeto original o coeficiente global de transferência de calor, U , aumentou 19,88 % ocasionando a redução da

área de troca térmica, A , em 15,44 %. Desta forma, o investimento de capital, C_i , é reduzido em 11,95 %. O custo anual de operação, C_o , é reduzido em 55,93 %, principalmente pela redução acentuada da perda de pressão do lado do casco, ΔP_s , de 68,54 %, compensando o aumento de 8,28 % da perda de pressão do lado dos tubos, ΔP_t . Assim, a função objetivo custo total, C_{tot} , tem redução de 20,80 %, mostrando o potencial do método proposto.

A comparação dos resultados do algoritmo GWO com todos os algoritmos meta-heurísticos mostram que apesar dos projetos otimizados variarem de algoritmo para algoritmo as diferenças entre os resultados da função objetivo custo total geralmente são pouco significativos para a maioria dos estudos. Desta forma, as diferenças no resultado da função objetivo custo total permaneceu entre 0,54 % (algoritmo ABC) a 11,55 % (algoritmo FFA). Portanto, é possível afirmar que todas as meta-heurísticas apresentadas neste trabalho são adequadas para obter resultados satisfatórios na otimização do projeto de trocadores de calor casco e tubos considerando como função objetivo o custo total do equipamento.

No segundo caso com a utilização do método Bell-Delaware o coeficiente global de transferência de calor, U , aumentou 22,40 % ocasionando a redução da área, A , em 17,18 %. Desta forma, o investimento de capital é reduzido em 13,32 % e o custo anual de operação é reduzido em 32,55 %, principalmente pela redução acentuada da perda de pressão do lado do casco que foi menor em 66,46 %, compensando o aumento de 110,49 % da perda de pressão do lado dos tubos. Esse aumento acentuado da perda de pressão do lado dos tubos decorrente da maior velocidade do fluido em 33,67 %, devido à restrição $1 \leq v_t \leq 2,5$ m/s, que manteve durante as dez simulações deste trabalho a velocidade do fluido no intervalo 1,0003 a 1,0046 m/s. A função objetivo custo total reduziu em 17,19 %, mostrando novamente o potencial do método proposto.

A otimização manteve o corte dos defletores, B_c , no intervalo de 27,9 a 28,9% permanecendo dentro dos limites estabelecidos para um bom projeto segundo Mukherjee, (1998) e Serth, (2007). Tanto os fatores de correção na transferência de calor, quanto na perda de pressão permaneceram em todas as simulações dentro de seus limites, não violando as recomendações do método Bell-Delaware. Mesmo com as dificuldades de um espaço de busca restrito (restrições geométricas e de velocidade dos fluidos) o algoritmo GWO manteve soluções de boa qualidade com resultado da função objetivo custo total no intervalo de 53.343 a 53.548 €.

É difícil garantir a melhor solução por um algoritmo, devido à natureza estocástica das meta-heurísticas. No entanto, estas têm encontrado boas soluções com baixo custo computacional em diversas aplicações (GOLDBERG, 1989).

A pequena variação dos resultados considerando dez simulações para ambos os estudos indicam que o algoritmo GWO é estável e pode produzir consistentemente soluções de boa qualidade. É também um algoritmo bastante simples com poucos parâmetros de entrada favorecendo o entendimento e aplicação em diversas áreas do conhecimento. Além disso, o algoritmo GWO permite solucionar rapidamente o problema do projeto ótimo permitindo examinar várias alternativas de soluções de boa qualidade.

Por fim, considerando os resultados obtidos pelo algoritmo GWO pode-se concluir que é um método eficaz e suficientemente preciso para obtenção do projeto ideal de trocadores de calor casco e tubos do ponto de vista econômico comparado a outros algoritmos de otimização.

5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Como sugestão para trabalhos futuros, sugere-se:

- Aplicação de outros algoritmos evolutivos ou baseados em inteligência de enxame para resolver o problema de projeto ótimo.
- Aplicação das novas versões do algoritmo GWO: LGWO, TGWO e CGWO propostas por Heidari e Pahlavani (2017), Al-Betar *et al.* (2018) e Lu *et al.* (2018), respectivamente.
- Aplicação da abordagem multiobjetivo considerando como função objetivo a área de troca térmica e a potência de bombeamento total.

REFERÊNCIAS

- AL-BETAR, M. A., AWADALLAH, M. A.; FARIS, H.; ALJARAH, I.; HAMMOURI, A. I.; Natural selection methods for grey Wolf Optimizer. **Expert Systems with Applications**, v. 113, p. 481-499, 2018.
- ASADI, M.; SONG, Y.; SUNDEN, B.; XIE, G. Economic optimization design of shell and tube heat exchangers by a cuckoo search algorithm. **Applied Thermal Engineering**, v. 73, p. 1032-1040, 2014.
- ATASHPAZ-GARGARI, E.; LUCAS, C. Imperialist Competitive Algorithm: an algorithm for optimization inspired by imperialistic competition. **IEEE Congress on Evolutionary Computation** p. 4661-4667, 2007.
- BELL, K.J. Final report of the cooperative research program on shell and tube heat exchangers network. University of Delaware Engineering Experimental Station Bulletin No. 5, Newark, Delaware, 1963.
- BELL, K.J. Delaware method for shell side design. Heat exchanger sourcebook. Hemisphere, Chapter 6, p. 129-166, 1986.
- BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and Conceptual Comparison. **ACM Computing Surveys**. v. 35, p. 268-308, 2003.
- CAPUTO, A. C.; PELAGAGGE, P. M.; SALINI, P. Heat exchanger design based on economic optimization, **Applied Thermal Engineering**, v. 28, p. 1151-1159, 2008.
- CASTRO, R. E. **Otimização de estruturas, com multi objetivos via algoritmo genético de Pareto**. Tese (Doutorado), Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, 202 p., 2001.
- COLBURN, A. P. Heat transfer by natural and forced convection. Engineering Bulletin Purdue University, Research Series, v. 26, p. 47-50, 1942.
- COSTA, A. L. H.; QUEIROZ, E. M. Design optimization of shell and tube heat exchangers. **Applied Thermal Engineering**, v. 28, p. 1798-1805, 2008.
- DAS, S.; SUGANTHAN, P. Differential evolution: A survey of the state of the art, Evolutionary Computation, **IEEE Transactions on Evolutionary Computation**, v.15(1), p. 4-31, 2011.
- DONOHUE, D. A. Heat transfer and pressure drop in heat exchangers. **Industrial and Engineering Chemistry**, v. 41(11), p. 2499-2511, 1949.
- EIBEN, A.; HINTERDING, R.; MICHALEWICZ. Parameter control in evolutionary algorithms. **IEEE Transactions on Evolutionary Computation**, v. 3(2), p. 124-141, 1999.
- ELATTAR, E. E. A hybrid genetic algorithm and bacterial foraging approach for dynamic economic dispatch problem. **International Journal of Electrical Power & Energy Systems**, v. 69 p. 18-26, 2015.

ENGELBRECHT, A. P. **Fundamentals of computational swarm intelligence**. Hoboken, John Wiley & Sons, 672 p., 2005.

FARIS, H.; ALJARAH, I.; AL-BETAR, M. A.; MIRJALILI, S. Grey wolf optimizer: a review of recent variants and applications. **Neural Computing and Applications**, p. 1-23, 2017.

FARNAD, B.; JAFARIAN, A.; BALEANU, D. A new hybrid algorithm for continuous optimization problem. **Applied Mathematical Modelling**, v. 55 p. 652-673, 2018.

GILAT, A.; SUBRAMANIAM, V. **Métodos Numéricos para Engenheiros e Cientistas: uma introdução com aplicações usando o MATLAB**. Bookman, 479 p., 2008.

GLOVER, F.; KOCHENBERGER, G. A. **Handbook of metaheuristics**. Kluwer Academic. Boston, 2003.

GNIELINSKI, V. New equations for heat and mass transfer in turbulent pipe and channel flow. **International Chemical Engineering**, Vol.16, No.2, p.359-368, 1976.

GOLDBERG, D. E. **Genetic algorithms in search, optimization, and machine learning**. Addison-Wesley, 412 p., 1989.

GUHA, D.; ROY, K. P.; BANERJEE, S. Load frequency control of interconnected power system using grey wolf optimization. **Swarm and Evolutionary Computation**, v. 27 p. 97-115, 2016.

GUO, J.; CHENG, L.; XU, M. Optimization design of shell and tube heat exchanger by entropy generation minimization and genetic algorithm, **Applied Thermal Engineering**, v. 29, p. 2954-2960, 2009a.

GUO, J.; XU, M.; CHENG, L. The application of field synergy number in shell-and-tube heat exchanger optimization design. **Applied Energy**, v. 86, p. 2079-2087, 2009b.

HADIDI, A.; HADIDI, M.; NAZARI, A. A new design approach for shell and tube heat exchangers using imperialist competitive algorithm (ICA) from economic point of view, **Energy Conversion and Management**, v. 67, p. 66-74, 2013.

HADIDI, A.; NAZARI, A. Design and economic optimization of shell and tube heat exchangers using biogeography based (BBO) algorithm. **Applied Thermal Engineering**, v. 51, p. 1263-1272, 2013.

HASSANIN, M. F.; SHOEB, A. M.; HASSANIEN, A. E. Grey wolf optimizer-based back-propagation neural network algorithm, in Proceedings of 12 th **International Computer Engineering Conference (ICENCO)**. p. 213-218, 2016.

HAUPT, R. L.; HAUPT, S. E. **Practical Genetic Algorithms**. 2^a ed. John Wiley & Sons; 2004.

HEIDARI, A. A.; PAHLAVANI, P. An efficient modified grey wolf optimizer with Lévy flight for optimization tasks. **Applied Soft Computing** v. 60 p.115-134, 2017.

JEGEDE, F. O.; POLLEY, G. T. Optimum heat exchanger design. **Chemical Engineering Research and Design** v. 70, (Part A), p. 133-141, 1992.

KAKAÇ, S.; LIU, H. PRAMUANJAROENKIJ, A. **Heat Exchangers: selection, rating and thermal design**. 3ª Ed., New York: CRC Press; 2012.

KARABOGA, N. A new design method based on Artificial Bee Colony algorithm for digital IIR filters. **Journal of the Franklin Institute** v. 346 (4), p. 328-348, 2009.

KARABOGA, D.; AKAY, B. A comparative study of artificial Bee Colony Algorithm. **Applied Mathematics and Computation**, v. 214, p. 108-132, 2009.

KENNEDY, J.; EBERHART, R. Particle swarm optimization, in: **Proceedings of the IEEE International Conference on Neural Networks**, Perth, Australia, p. 1942-1948, 1995.

KENNEDY, J.; EBERHART, R. C. **Swarm Intelligence**, Morgan Kaufmann Publishers, ISBN 1-55860-595-599, 2001.

KERN, D. Q. **Processos de Transmissão de Calor**. Editora Guanabara, Rio de Janeiro, 1987.

LINDEN, R. **Algoritmos Genéticos: Uma importante ferramenta da inteligência computacional**. Rio de Janeiro, RJ: Editora Brasport, 348 p., 2006.

LOPES, H. S.; TAKAHASHI, R. H. C. **Computação Evolucionária em Problemas de Engenharia**. Curitiba: Omnipax, 385 p., 2011.

LU, C.; GAO, L.; YI, J.; Grey wolf optimizer with cellular topological structure. **Expert Systems with Applications**. v. 107, p.89-114, 2018.

MARINI, F.; WALCZAK, B. Particle swarm optimization (PSO). A tutorial. **Chemometrics and Intelligent Laboratory Systems**. v. 149, p.153-165, 2015.

MCADAMS, W. H.; Heat Transmission, 2d ed., McGraw-Hill Book Company, Inc., New York, 1942.

MIRJALILI, S. List of projects: Grey wolf Optimizer, 2014. Disponível em: <<http://www.alimirjalili.com/projects.html>>. Acesso em: 21 de Junho de 2017.

MIRJALILI, S.; MIRJALILI, M. S.; LEWIS, A. Grey Wolf Optimizer. **Advances in Engineering Software**, v. 69, p. 46-61, 2014.

MOHANTY, D. K. Application of firefly algorithm for design optimization of a shell and tube heat exchanger from economic point of view, **Applied Thermal Sciences**, v. 102, p. 228-238, 2016a.

MOHANTY, D.K. Gravitational search algorithm for economic optimization design of a shell and tube heat exchanger. **Applied Thermal Engineering**, v.107, p. 184-193, 2016b.

MOLGA, M.; SMUTNICKI, C. Test functions for optimization needs. Disponível em: <http://new.zsd.iar.pwr.wroc.pl/files/docs/functions.pdf>, 43p. 2005.

MUKHERJEE, R. Effectively design shell and tube heat exchangers. **Chemical Engineering Progress**, v.94, p.21-37, 1988.

MULATI, M. H.; COSTANTINO, A. A.; SILVA, A. F., **Otimização por Colônia de Formigas. Meta-Heurística em Pesquisa Operacional**. Curitiba: Omnipax, 472 p., 2013.

MURO, C.; ESCOBEDO, R.; SPECTOR, L.; COPPINGER, R. Wolf-pack (Canis lupus) hunting strategies emerge from simple rules in computational simulations. **Behavioural Processes**. v. 88, p. 192-197, 2011.

NASCIMENTO, M. H. R. **Uma nova solução para a otimização do despacho econômico e ambiental utilizando metaheurísticas da computação bio-inspiradas**. Tese (Doutorado em Engenharia Elétrica), Universidade Federal do Pará (UFPA), Belém, 234 p., 2016.

PALEN, J. M.; TABOREK, J. Solution of shell side flow pressure drop and heat transfer by stream analysis method, **Chemical Engineering Program Symposium Series**, v. 65(92), p. 53-63, 1969.

PATEL, V. K.; RAO, R.V. Design optimization of shell and tube heat exchanger using particle swarm optimization technique. **Applied Thermal Engineering**, v. 30, p. 1417-1425, 2010.

PETUKHOV, B. S. Heat transfer and friction in turbulent pipe flow with variable physical properties. *Advances in heat transfer*. New York: Academic Press, v. 6, p. 503-564, 1970.

PICHENY, V.; WAGNER, T.; GINSBOURGER, D. A benchmark of kriging-based infill criteria for noisy optimization. HAL Id: hal-00658212. Disponível em: <https://hal.archives-ouvertes.fr/hal-00658212>, 15p., 2012.

PINTO, F. B. **Metaheurísticas de otimização aplicadas à sintonia dos ganhos de controlador PID multivariável**. Dissertação (Mestrado em Engenharia Elétrica) Universidade Federal do Paraná (UFPR), Curitiba, 94 p., 2016.

RAJABIOUN, R. Cukoo optimization algorithm, **Applied Soft Computing**, v. 11, p. 5508-5518, 2011.

RASHEDI, E. H.; NEZAMABADI-POUR.; SARYAZDI, S. GSA: gravitational search algorithm, **Information Sciences**, v. 179 p. 2232-2248, 2009.

REIS, S. C. **Estudo de meta-heurísticas para alocação de controladores FACTS**. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal do Paraná (UFPR), Curitiba, 129 p., 2017.

SAHIN, A.S.; KILIC, B.; KILIC, U. Design and economic optimization of shell and tube heat exchangers using Artificial Bee Colony (ABC) algorithm. **Energy Conversion and Management**, vol. 52, p. 3356-3362, 2011.

SAUNDERS, E. A. D. **Heat Exchanger Design Handbook**. New York, NY: Hemisphere Pub. Co, 2080 p., 1983.

SAXENA, A.; SHEKHAWAT, S. Ambient air quality classification by grey wolf optimizer based support vector machine. **Journal of Environmental and Public Health**, 12 p., 2017.

SERAPIÃO, A. B. S. Fundamentos de otimização por inteligência de enxames: Uma visão geral. **Revista Controle & Automação**. v. 20, p. 271-304, 2009.

SERTH, R. W. **Process Heat Transfer: Principles and Applications**. Academic Press, 755 p., 2007.

SHAH, K. R.; SEKULIC, P. D. **Fundamentals Heat Exchanger Design**, John Wiley and Sons, New York, 941 p., 2003.

SHORT, B. E. **Heat transfer and pressure drop in heat exchangers**. Austin, University of Texas, 1943.

SIEDER, E.; TATE, G. Heat transfer and pressure drop of liquids in tubes. **Industrial and Engineering Chemistry**, v. 28, p. 1429-1435, 1936.

SIMON, D. Biogeography-based optimization, **IEEE Transactions on Evolutionary Computation**, v. 12, p. 702-713, 2008.

SINNOTT, R. K.; COULSON, J. M.; RICHARDSON, J. F. **Chemical Engineering**, v. 6, Butterworth Heinemann; 1038 p., 2005.

SMITH, R. **Chemical Process Design and Integration**, 1st ed., Wiley, UK, 687 p., 2005.

SONG, X.; TANG, L.; ZHAO, S.; ZHANG, X.; LI, L.; HUANG, J.; CAI, W. Grey wolf optimizer for parameter estimation in surface waves. **Soil Dynamics and Earthquake Engineering**, v. 75, p. 147-157, 2015.

STEPHAN, K.; PREUBER, P. Wärmeübergang und maximale Wärmestromdichte beim Behältersieden binärer und ternärer Flüssigkeitsgemische. **Chemie Ingenieur Technik**, v. 51, p.37, 1979.

STORN, R.; PRICE, K. Differential evolution a simple and efficient adaptive scheme for global optimization over continuous spaces, **Journal of Global Optimization**, v. 11, p. 341-359, 1997.

TAAL, M.; BULATOV, I.; KLEMES, J.; STEHLIK, P. Cost estimation and energy price forecast for economic evaluation of retrofit projects, **Applied Thermal Engineering**, v. 23, p. 1819-1835, 2003.

TABOREK, J. Shell and tube heat exchanger: single phase flow. In: **Heat exchanger Design Handbook**. Cap. 3, Hemisphere Publishing Corp. Washington, 1983.

TAKAHASHI, R.; CUNHA, A. G.; ANTUNES, C. H. **Manual de Computação Evolutiva e Meta-Heurística**. Editora: Universidade de Federal de Minas Gerais (UFMG), 447 p., 2012.

TEMA, **Standards of the Tubular Exchanger Manufacturers Association** (9° ed.). New York, 2007.

TINKER, T. Shell side characteristics of shell and tube heat exchangers: a simplified rating system for commercial heat exchangers. **Transactions of the ASME**, v. 80, p. 36-52, 1958.

THOME, J. R., Engineering Data Book III, Chapter 3: Single-Phase Shell-Side Flows and Heat Transfer, Wolverine Tube, Inc, Lausanne, 2004.

VASCONSELOS, E. H.; AMOROSO, A. L.; MARIANE, V. C.; COELHO, L. S. Economic optimization design for shell and tube heat exchanger by a Tsallis differential evolution. **Applied Thermal Engineering**, v. 111, p. 143-151, 2017.

YANG, X. S. **Nature-inspired Metaheuristic Algorithms**, University of Cambridge, United Kingdom, Luniver Press, 1^a ed., p.116., 2008.

YANG, X. S.; DEB, S. Cuckoo search via Lévy flights. In: **Proceedings of World Congress on Nature & Biologically Inspired Computing**. IEEE Publications, USA, p. 210-214, 2009.

YANG, X. S. Nature-Inspired Metaheuristic Algorithms, University of Cambridge, United Kingdom, Luniver Press, 2^a ed., 148 p., 2010a.

YANG, X. S. Firefly Algorithm, Stochastic Test Functions and Design Optimization, **International Journal of Bio-Inspired Computation**, v.2(2), p. 78-84, 2010b.

YANG, X. S.; DEB, S. Engineering optimization by cuckoo search. **International Journal of Mathematical Modelling and Numerical Optimization**, v.1, n. 4, p. 330-343, 2010.

ZHANG, S.; ZHOU, Y.; LI, Z.; PAN, W. Grey wolf optimizer for unmanned combat aerial vehicle path planning. **Advances in Engineering Software**, v. 99, p. 121-136, 2016.

APÊNDICE A

O apêndice A trata da descrição detalhada do método Bell-Delaware (1963).

Fatores de correção para o coeficiente de transferência de calor para o lado do casco.

J_c – Fator de correção devido aos efeitos da configuração dos defletores (corte e espaçamento do defletor). Valores típicos de J_c para um trocador de calor bem projetado deve estar compreendido entre 0,65 e 1,175.

$$J_c = 0,55 + 0,72F_c \quad (\text{A.1})$$

onde, F_c é a fração total de tubos em uma seção de fluxo cruzado e é dado por:

$$F_c = 1 - 2F_w \quad (\text{A.2})$$

O parâmetro F_w é a fração de tubos na janela do defletor e é dado por:

$$F_w = \frac{\theta_{ctl}}{2\pi} - \frac{\sin(\theta_{ctl})}{2\pi} \quad (\text{A.3})$$

onde,

$$\theta_{ctl} = 2 \cos^{-1} \left(\frac{D_s - 2l_c}{D_{ctl}} \right) \quad (\text{A.4})$$

sendo, l_c a altura da janela e D_{ctl} é o diâmetro do círculo formado pelo centro dos tubos mais externos do feixe e é calculado por:

$$D_{ctl} = D_{otl} - d_o \quad (\text{A.5})$$

onde, D_{otl} é o diâmetro do círculo circunscrito aos tubos mais externos do feixe de tubos.

J_l – Fator de correção devido aos efeitos de vazamento nos defletores. Valores típicos de J_l para um trocador de calor bem projetado deve estar compreendido entre 0,7 e 0,9.

$$J_l = 0,44(1 - R_s) + [1 - 0,44(1 - R_s)] \exp(-2,2R_{lm}) \quad (\text{A.6})$$

onde, R_s é a razão da área de vazamento casco defletor e a soma das áreas de vazamento e R_{lm} é a razão entre as áreas de vazamento e a área de fluxo cruzado.

$$R_s = \frac{A_{osb}}{A_{osb} + A_{otb}} \quad (\text{A.7})$$

$$R_{lm} = \frac{A_{osb} + A_{otb}}{A_{ocr}} \quad (\text{A.8})$$

sendo, A_{osb} é a área de vazamento entre o casco e o defletor e A_{otb} é a área de vazamento entre o tubo e o defletor.

$$A_{osb} = \pi D_s \frac{\delta_{sb}}{2} \left(1 - \frac{\theta_b}{2\pi} \right) \quad (\text{A.9})$$

$$\theta_b = 2 \cos^{-1} \left(1 - \frac{2l_c}{D_s} \right) \quad (\text{A.10})$$

$$A_{otb} = \frac{\pi d_o \delta_{tb} N_t (1 - F_w)}{2} \quad (\text{A.11})$$

$$A_{ocr} = \left[D_s - D_{oil} + \frac{D_{ctl}}{X_t} (X_t - d_o) \right] L_{bc} \quad (\text{A.12})$$

A_{ocr} é a área de fluxo cruzado entre defletores válida para arranjo triangular 30° e quadrado 90°. Para arranjo quadrado girado 45° e triangular girado 60° temos:

$$A_{ocr} = \left[D_s - D_{otl} + 2 \frac{D_{ctl}}{X_t} (P_t - d_o) \right] L_{bc} \quad (\text{A.13})$$

onde, X_t é o passo transversal dos tubos.

J_b - Fator de correção devido aos efeitos de *by-pass* no feixe de tubos. Valores típicos de J_b para um trocador de calor bem projetado deve estar compreendido entre 0,7 e 0,9.

Para $N_{ss}^+ \geq 1/2$ temos:

$$J_b = 1 \quad (\text{A.14})$$

Para $N_{ss}^+ < 1/2$ temos:

$$J_b = \exp \left[- C_b R_b \left(1 - \sqrt[3]{2N_{ss}^+} \right) \right] \quad (\text{A.15})$$

onde, o parâmetro C_b depende do regime de escoamento do fluido no lado do casco.

Para $Re_s \leq 100$ temos:

$$C_b = 1,35 \quad (\text{A.16})$$

Para $Re_s > 100$ temos:

$$C_b = 1,25 \quad (\text{A.17})$$

R_b é a razão de *by-pass* para a área de fluxo cruzado e é dado por:

$$R_b = \frac{A_{obp}}{A_{ocr}} \quad (\text{A.18})$$

onde, A_{obp} é a área de *by-pass* para o fluxo cruzado e é dado por:

$$A_{obp} = L_{bc} (D_s - D_{otl} + 0,5N_p W_p) \quad (\text{A.19})$$

onde, N_p é o número de divisores de passes no espelho estacionário e W_p é a divisão interna que normalmente é considerada igual ao diâmetro externo dos tubos conforme mostra a Fig. (2.13).

N_{ss}^+ é a razão entre o número de pares de tiras de selagem e o número de fileiras de tubos entre dois cortes do defletor. Os pares de tiras de selagem são utilizados quando a diferença do diâmetro interno do casco e o feixe de tubos exceder 30 mm.

$$N_{ss}^+ = \frac{N_{ss}}{N_{rec}} \quad (\text{A.20})$$

onde, N_{rec} é dado por:

$$N_{rec} = \frac{D_s - 2l_c}{X_l} \quad (\text{A.21})$$

sendo, X_l é o passo longitudinal dos tubos. O passo transversal e longitudinal depende do tipo de arranjo de tubos como mostra a Fig. (A.1).

Padrões de arranjo de tubos.	Triangular 30°	Triangular girado 60°	Quadrado 90°	Quadrado girado 45°
Passo transversal X_t	p_t	$\sqrt{3} p_t$	p_t	$\sqrt{2} p_t$
Passo longitudinal X_l	$\left(\frac{\sqrt{3}}{2}\right) p_t$	$\frac{p_t}{2}$	p_t	$\frac{p_t}{\sqrt{2}}$

Figura A.1 - Propriedades geométricas para tubos de trocadores de calor casco e tubos.

Fonte: Adaptado de Shah e Sekulic, 2003.

J_s - Fator de correção para o espaçamento entre defletores diferente na entrada e/ou saída. Valores típicos de J_s para um trocador de calor bem projetado deve estar compreendido entre 0,85 e 1.

$$J_s = \frac{N_b - 1 + (L_i^+)^{(1-N)} + (L_o^+)^{(1-N)}}{N_b - 1 + L_i^+ + L_o^+} \quad (\text{A.22})$$

onde, N_b , L_i^+ e L_o^+ é dado por:

$$N_b = \frac{L - L_{bi} - L_{bo}}{L_{bc}} + 1 \quad (\text{A.23})$$

sendo, L_{bi} o espaçamento dos defletores na entrada do casco e L_{bo} o espaçamento dos defletores na saída do casco.

$$L_i^+ = \frac{L_{bi}}{L_{bc}} \quad (\text{A.24})$$

$$L_o^+ = \frac{L_{bo}}{L_{bc}} \quad (\text{A.25})$$

O parâmetro N depende do regime de escoamento do fluido no lado do casco. Para regime de escoamento laminar N é igual a 0,3 e para regime de escoamento turbulento N é igual a 0,6.

J_r - Fator de correção para o gradiente de temperatura adverso no fluxo laminar. Valores típicos de J_r para um trocador de calor bem projetado deve estar compreendido entre 0,4 e 1.

Para $Re_s \geq 100$ temos:

$$J_r = 1 \quad (\text{A.26})$$

Para $Re_s \leq 20$ temos:

$$J_r = \left(\frac{10}{N_{rc}} \right)^{0,18} \quad (\text{A.27})$$

onde, N_{rc} é o número total de fileiras de tubos cruzadas através de uma seção de defletores e é dado por:

$$N_{rc} = N_{rcc} + N_{rcw} \quad (\text{A.28})$$

sendo, N_{rcw} o número de fileiras de tubos no escoamento cruzado em cada janela do defletor.

$$N_{rcw} = \frac{0,8}{X_l} \left[l_c - \frac{1}{2} (D_s - D_{ctl}) \right] \quad (\text{A.29})$$

Então o fator de correção total na transferência de calor é dado por:

$$J_{total} = J_c J_l J_b J_s J_r \quad (\text{A.30})$$

Quando J_{total} tiver valor menor que 0,4 deverá ser reavaliado o projeto quanto aos parâmetros construtivos. Valor típico de J_{total} para um trocador de calor bem projetado deve ser aproximadamente igual a 0,6 (SHAH e SEKULIC, 2003).

Coefficiente de transferência de calor ideal para o lado do casco.

A transferência de calor para o escoamento ideal sobre um feixe de tubos é dada por:

$$h_{id} = j_{id} C p_s \left(\frac{\dot{m}_s}{A_{ocr}} \right) \left(\frac{k_s}{C p_s \mu_s} \right)^{2/3} \left(\frac{\mu_s}{\mu_{ws}} \right)^{0,14} \quad (\text{A.31})$$

onde j_{id} e a são:

$$j_{id} = a_1 \left(\frac{1,33}{p_t / d_o} \right)^a (\text{Re}_s)^{a_2} \quad (\text{A.32})$$

$$a = \frac{a_3}{1 + 0,14 (\text{Re}_s)^{a_4}} \quad (\text{A.33})$$

As constantes a_1 , a_2 , a_3 e a_4 podem ser encontradas na Fig. (A.2).

Arranjo tubular	Número de Reynolds	a_1	a_2	a_3	a_4	b_1	b_2	b_3	b_4
30°	10 ⁵ -10 ⁴	0.321	-0.388	1.450	0.519	0.372	-0.123	7.00	0.500
	10 ⁴ -10 ³	0.321	-0.388			0.486	-0.152		
	10 ³ -10 ²	0.593	-0.477			4.570	-0.476		
	10 ² -10	1.360	-0.657			45.100	-0.973		
	<10	1.400	-0.667			48.000	-1.000		
45°	10 ⁵ -10 ⁴	0.370	-0.396	1.930	0.500	0.303	-0.126	6.59	0.520
	10 ⁴ -10 ³	0.370	-0.396			0.333	-0.136		
	10 ³ -10 ²	0.730	-0.500			3.500	-0.476		
	10 ² -10	0.498	-0.656			26.200	-0.913		
	<10	1.550	-0.667			32.00	-1.000		
90°	10 ⁵ -10 ⁴	0.370	-0.395	1.187	0.370	0.391	-0.148	6.30	0.378
	10 ⁴ -10 ³	0.107	-0.266			0.0815	+0.022		
	10 ³ -10 ²	0.408	-0.460			6.0900	-0.602		
	10 ² -10	0.900	-0.631			32.1000	-0.963		
	<10	0.970	-0.667			35.0000	-1.000		

Figura A.2 – Constantes empíricas para o cálculo do coeficiente de transferência de calor e perda de pressão para o lado do casco.

Fonte: Adaptado de Kakaç e Liu (2000).

Uma vez conhecido o coeficiente de transferência de calor ideal e o fator de correção total na transferência de calor, pode ser encontrado o coeficiente de transferência de calor real para o lado do casco:

$$h_s = h_{id} J_{total} \quad (\text{A.34})$$

Perda de pressão ideal para o lado do casco.

A perda de pressão para o escoamento ideal sobre o feixe de tubos é dada por:

$$\Delta P_{b,id} = \frac{4 f_{id} G_s^2 N_{rec}}{2 \rho_s} \left(\frac{\mu_w}{\mu_m} \right)^{0,14} \quad (\text{A.35})$$

onde, μ_m é a viscosidade média do fluido do lado do casco e f_{id} é o fator de atrito que é dado por:

$$f_{id} = b_1 \left(\frac{1,33}{P_i / d_o} \right)^b (\text{Re}_s)^{b_2} \quad (\text{A.36})$$

$$b = \frac{b_3}{1 + 0,14(\text{Re}_s)^{b_4}} \quad (\text{A.37})$$

As constantes b_1 , b_2 , b_3 e b_4 podem ser encontradas na Fig.(A.2).

Perda de pressão real para o lado do casco.

A perda de pressão real para o lado do casco considera os seguintes fatores de correção:

ζ_b - Fator de correção devido aos efeitos de *by-pass* no feixe de tubos. Valores típicos de ζ_b para um trocador de calor bem projetado deve estar compreendido entre 0,5 e 0,8.

Para $N_{ss}^+ < 1/2$ temos:

$$\zeta_b = \exp \left\{ -DR_b \left[1 - (2N_{ss}^+)^{1/3} \right] \right\} \quad (\text{A.38})$$

O parâmetro D depende de Re_s . Para $\text{Re}_s \leq 100$ o parâmetro D é igual a 4,5 e para $\text{Re}_s > 100$ o parâmetro D é igual a 3,7.

Para $N_{ss}^+ \geq 1/2$ temos:

$$\zeta_b = 1 \quad (\text{A.39})$$

ζ_l - Fator de correção devido aos efeitos de vazamento nos defletores. Valores típicos de ζ_l para um trocador de calor bem projetado deve estar compreendido entre 0,4 e 0,5.

$$\zeta_l = \exp \left[-1,33(1 + R_s)R_{lm}^p \right] \quad (\text{A.40})$$

onde p é:

$$p = [-0,15(1 + R_s) + 0,8] \quad (\text{A.41})$$

ζ_s - Fator de correção para o espaçamento entre defletores diferente na entrada e/ou saída. Valores típicos de ζ_s para um trocador de calor bem projetado deve estar compreendido entre 0,5 e 2.

$$\zeta_s = \left(\frac{L_{bc}}{L_{bo}} \right)^{2-n'} + \left(\frac{L_{bc}}{L_{bi}} \right)^{2-n'} \quad (\text{A.42})$$

O parâmetro n' depende do regime de escoamento do fluido no lado do casco. Para regime de escoamento laminar n' é igual a 1 e para regime de escoamento turbulento n' é igual a 0,2.

A perda de pressão real para o lado do casco é determinada pela soma de três fatores:

ΔP_{cr} – Perda de pressão na seção central (fluxo cruzado): ocorre entre as extremidades do defletor conforme mostra a Fig. (2.11).

$$\Delta P_{cr} = \Delta P_{b,id} (N_b - 1) \zeta_b \zeta_l \quad (\text{A.43})$$

ΔP_w – Perda de pressão na seção das janelas dos defletores: ocorre na seção das janelas dos defletores como mostra a Fig. (2.11). A correlação proposta depende do regime de escoamento.

Para o escoamento laminar:

$$\Delta P_w = N_b \left(26 \frac{G_w}{\rho_s} \mu_s \left[\frac{N_{rcw}}{P_t - d_o} + \frac{L_{bc}}{D_h^2} \right] + 2 \frac{G_w^2}{2\rho_s} \right) \zeta_l \quad (\text{A.44})$$

Para o escoamento turbulento:

$$\Delta P_w = N_b (2 + 0,6N_{rcw}) \frac{G_w^2}{2\rho_s} \zeta_l \quad (\text{A.45})$$

onde, D_h é o diâmetro equivalente (ou hidráulico) da janela e é dado por:

$$D_h = \frac{4A_{ow}}{\pi d_o N_{tw} + \pi D_s \frac{\theta_b}{360}} \quad (\text{A.46})$$

sendo, N_{tw} é o número de tubos na seção da janela do defletor.

$$N_{tw} = F_w N_t \quad (\text{A.47})$$

Já G_w é o fluxo mássico considerando a média geométrica da área de fluxo cruzado e a área de fluxo na janela do defletor.

$$G_w = \frac{\dot{m}_s}{(A_{ocr} A_{ow})^{1/2}} \quad (\text{A.48})$$

sendo, A_{ow} a área de fluxo na janela do defletor dada por:

$$A_{ow} = A_{frw} - A_{frit} \quad (\text{A.49})$$

onde, A_{frw} é a área total da janela do defletor e A_{frit} é a área ocupada pelos tubos na janela do defletor dadas por:

$$A_{frw} = \frac{D_s^2}{4} \left[\frac{\theta_b}{2} - \left(1 - \frac{2l_c}{D_s} \right) \sin \left(\frac{\theta_b}{2} \right) \right] \quad (\text{A.50})$$

$$A_{frit} = \frac{\pi}{4} d_o^2 F_w N_t \quad (\text{A.51})$$

ΔP_{i-o} – Perda de pressão nas seções de entrada e saída do trocador de calor: ocorre nas seções de entrada e saída do fluido entre o espelho estacionário e o primeiro defletor como mostra a Fig. (2.11) e é dada por:

$$\Delta P_{i-o} = 2\Delta P_{b,id} \left(1 + \frac{N_{rcw}}{N_{rec}} \right) \zeta_b \zeta_s \quad (\text{A.51})$$

Uma vez conhecida a perda de pressão ideal e os fatores de correção ζ_b , ζ_l e ζ_s pode ser determinada a perda de pressão real para o lado do casco:

$$\Delta P_s = \Delta P_{cr} + \Delta P_w + \Delta P_{i-o} \quad (\text{A.52})$$

APÊNDICE B

Tabela B.1 - Simulações utilizando o método de Kern.

	Simulação 1	Simulação 2	Simulação 3	Simulação 4
n (-)	2	2	2	2
d_o (m)	0,01000	0,01000	0,01033	0,01008
D_s (m)	0,7812	0,7673	0,7788	0,7772
L_{bc} (m)	0,5531	0,5511	0,5496	0,5534
B_c (%)	25	25	25	25
N_t (-)	3612	3469	3339	3509
v_t (m/s)	0,7627	0,7941	0,7731	0,7727
v_s (m/s)	0,429	0,4383	0,433	0,4309
Re_t (-)	7589	7900,3	7945,9	7750,1
Re_s (-)	6727,2	6873,6	7013,6	6811
h_t (W/m ² K)	4233,8	4399,1	4281,7	4285,1
h_s (W/m ² K)	2064,3	2088,9	2044,7	2061,9
U (W/m ² K)	735,478	744,6756	734,7533	737,0899
A (m ²)	236,1271	233,2107	236,36	235,6107
L (m)	2,0807	2,1394	2,1807	2,1202
ΔP_t (Pa)	6567,9	7209,3	6753,4	6766,4
ΔP_s (Pa)	10951	11550	11283	11084
C_o (€)	903,7551	973,7214	930,1697	923,372
C_{od} (€)	5553,2	5983,1	5715,5	5673,7
C_i (€)	45428	45007	45462	45354
C_{tot} (€)	50981,2	50990,1	51177,5	51027,7

Tabela B.2 - Simulações utilizando o método de Kern.

	Simulação 5	Simulação 6	Simulação 7	Simulação 8
n (-)	2	2	2	2
d_o (m)	0,0105	0,01010	0,01001	0,0102
D_s (m)	0,7835	0,7792	0,7773	0,7783
L_{bc} (m)	0,546	0,553	0,5473	0,5539
B_c (%)	25	25	25	25
N_t (-)	3265	3498	3564	3429
v_t (m/s)	0,7654	0,769	0,7714	0,7721
v_s (m/s)	0,4333	0,4302	0,4357	0,4299
Re_t (-)	7996,6	7743,4	7682,9	7836,5
Re_s (-)	7134,1	6826,5	6838,8	6875,7
h_t (W/m ² K)	4237,9	4264,9	4279,5	4279,6
h_s (W/m ² K)	2030,6	2056,4	2081	2048,3
U (W/m ² K)	731,2965	735,6337	739,3022	735,1371
A (m ²)	237,4772	236,0771	234,9057	236,2366
L (m)	2,2049	2,1226	2,0955	2,1495
ΔP_t (Pa)	6583	6688,6	6731,4	6749,5
ΔP_s (Pa)	11353	11050	11399	11042
C_o (€)	920,5618	916,3709	933,0895	920,5037
C_{od} (€)	5656,5	5630,7	5733,4	5656,1
C_i (€)	45623	45421	45252	45444
C_{tot} (€)	51279,5	51051,7	50985,4	51100,1

Tabela B.3 - Simulações utilizando o método de Kern.

	Simulação 9	Simulação 10
n (-)	2	2
d_o (m)	0,01021	0,01000
D_s (m)	0,7782	0,7739
L_{bc} (m)	0,5466	0,5488
B_c (%)	25	25
N_t (-)	3420	3537
v_t (m/s)	0,7727	0,7789
v_s (m/s)	0,4357	0,4363
Re_t (-)	7849,8	7750,1
Re_s (-)	6976,7	6842,5
h_t (W/m ² K)	4282,3	4319,4
h_s (W/m ² K)	2062,8	2083,7
U (W/m ² K)	737,907	741,1218
A (m ²)	235,6105	234,3289
L (m)	2,1474	2,1086
ΔP_t (Pa)	6746,2	6888,6
ΔP_s (Pa)	11449	11433
C_o (€)	936,1117	945,8362
C_{od} (€)	5752	5811,8
C_i (€)	45354	45169
C_{tot} (€)	51106	50980,8

Tabela B.4 - Simulações utilizando o método Bell-Delaware

	Simulação 1	Simulação 2	Simulação 3	Simulação 4
n (-)	2	2	2	2
d_o (m)	0,01588	0,01588	0,01588	0,01588
D_s (m)	0,7220	0,7221	0,7211	0,7224
L_{bc} (m)	0,4846	0,4839	0,4615	0,4420
B_c (%)	28,80	28,79	28,35	28,77
N_t (-)	1091	1091	1087	1092
v_t (m/s)	1,0016	1,0014	1,0046	1,0004
v_s (m/s)	0,5052	0,5059	0,5312	0,5537
Re_t (-)	15827	15822	15874	15807
Re_s (-)	17697	17722	18609	19394
h_t (W/m ² K)	5442,6	5441,4	5455,6	5437,2
h_s (W/m ² K)	1903,2	1904,4	1947,1	1982,6
U (W/m ² K)	749,0067	749,1594	756,0335	760,8739
A (m ²)	231,8621	231,8149	229,7071	228,2458
L (m)	4,8770	4,8770	4,8770	4,8770
ΔP_t (Pa)	13131	13124	13201	13102
ΔP_s (Pa)	11159	11181	12997	13487
C_o (€)	1389	1389,2	1465,7	1477,5
C_{od} (€)	8534,9	8537,2	9006	9078,8
C_i (€)	44812	44806	44501	44290
C_{tot} (€)	53346,9	53343,2	53507	53368,8

Tabela B.5 - Simulações utilizando o método Bell-Delaware.

	Simulação 5	Simulação 6	Simulação 7	Simulação 8
n (-)	2	2	2	2
d_o (m)	0,01588	0,01588	0,01588	0,01588
D_s (m)	0,7223	0,7220	0,7216	0,7191
L_{bc} (m)	0,4394	0,4720	0,4848	0,4836
B_c (%)	28,87	28,30	28,83	28,73
N_t (-)	1091	1091	1089	1081
v_t (m/s)	1,0009	1,0016	1,0003	1,0108
v_s (m/s)	0,5570	0,5187	0,5053	0,5083
Re_t (-)	15815	15826	15849	15972
Re_s (-)	19513	18169	17701	17804
h_t (W/m ² K)	5439,4	5442,3	5448,6	5482,5
h_s (W/m ² K)	1988	1926	1903,6	1909,4
U (W/m ² K)	761,7230	752,5051	749,2058	750,9034
A (m ²)	227,9914	230,7842	231,8005	231,2765
L (m)	4,8770	4,8770	4,8770	4,8770
ΔP_t (Pa)	13114	13129	13163	13347
ΔP_s (Pa)	13551	12650	11157	11269
C_o (€)	1480,9	1447	1391,3	1409
C_{od} (€)	9099,5	8890,9	8549	8657,8
C_i (€)	44253	44657	44803	44728
C_{tot} (€)	53352,5	53547,9	53352	53385,8

Tabela B.6 - Simulações utilizando o método Bell-Delaware.

	Simulação 9	Simulação 10
n (-)	2	2
d_o (m)	0,01588	0,01588
D_s (m)	0,7220	0,7217
L_{bc} (m)	0,4849	0,4848
B_c (%)	27,90	28,74
N_t (-)	1091	1091
v_t (m/s)	1,0018	1,0018
v_s (m/s)	0,5050	0,5050
Re_t (-)	15829	15829
Re_s (-)	17690	17692
h_t (W/m ² K)	5443,2	5443,3
h_s (W/m ² K)	1902,8	1902,9
U (W/m ² K)	748,9662	748,9846
A (m ²)	231,8747	231,8690
L (m)	4,8770	4,8770
ΔP_t (Pa)	13134	13135
ΔP_s (Pa)	11413	11174
C_o (€)	1399,1	1389,9
C_{od} (€)	8597,2	8540,2
C_i (€)	44814	44813
C_{tot} (€)	53411,2	53353,2

Tabela B.7 - Simulações utilizando o método Bell-Delaware.

Valores de referência segundo (TEMA, 2007)		Simulação 1	Simulação 2	Simulação 3
L/D_s	3 - 15	5,9011	5,8975	5,8716
L_{bc} / D_s	0,2 - 1	0,6712	0,6701	0,64
$L_{bi} / D_s = L_{bo} / D_s$	0,3 - 1	0,6712	0,6701	0,64
B_c / D_s	0,18 - 0,40	0,3989	0,3987	0,3931
P_t / d_o	1,25 - 1,5	1,25	1,25	1,25
Valores de referência segundo (SINNOTT <i>et al.</i> , 2005)		Simulação 1	Simulação 2	Simulação 3
v_t (m/s)	1 - 2,5	1,0016	1,0014	1,0046
v_s (m/s)	0,3 - 1	0,5052	0,5059	0,5312
Valores de referência segundo (SHAH e SEKULIC, 2003 e THOME, 2004)		Simulação 1	Simulação 2	Simulação 3
J_c (-)	0,65 - 1,175	1,02	1,02	1,02
J_l (-)	0,7 - 0,9	0,8522	0,8519	0,8457
J_b (-)	0,7 - 0,9	0,8433	0,8433	0,8431
J_s (-)	0,85 - 1	1	1	1
J_r (-)	0,4 - 1	1	1	1
J_{total} (-)	0,4 - 1	0,7330	0,7328	0,7273
ζ_b (-)	0,5 - 0,8	0,6038	0,6039	0,6035
ζ_l (-)	0,4 - 0,5	0,5	0,5	0,5
ζ_s (-)	0,5 - 2	2	2	2
Valores de referência segundo (MUKHERJEE, 1998).		Simulação 1	Simulação 2	Simulação 3
B_c (%)	20 - 35	28,80	28,79	28,35

Tabela B.8 - Simulações utilizando o método Bell-Delaware.

Valores de referência segundo (TEMA, 2007)		Simulação 4	Simulação 5	Simulação 6
L/D_s	3 - 15	5,7987	5,7965	5,8731
L_{bc} / D_s	0,2 - 1	0,6118	0,6084	0,6537
$L_{bi} / D_s = L_{bo} / D_s$	0,3 - 1	0,6118	0,6084	0,6537
B_c / D_s	0,18 - 0,40	0,3983	0,3997	0,392
P_t / d_o	1,25 - 1,5	1,25	1,25	1,25
Valores de referência segundo (SINNOTT <i>et al.</i> , 2005)		Simulação 4	Simulação 5	Simulação 6
v_t (m/s)	1 - 2,5	1,0004	1,0009	1,0016
v_s (m/s)	0,3 - 1	0,5537	0,5570	0,5187
Valores de referência segundo (SHAH e SEKULIC, 2003 e THOME, 2004)		Simulação 4	Simulação 5	Simulação 6
J_c (-)	0,65 - 1,175	1,02	1,02	1,02
J_l (-)	0,7 - 0,9	0,8394	0,8386	0,8486
J_b (-)	0,7 - 0,9	0,8434	0,8434	0,8433
J_s (-)	0,85 - 1	1	1	1
J_r (-)	0,4 - 1	1	1	1
J_{total} (-)	0,4 - 1	0,7221	0,7214	0,7300
ζ_b (-)	0,5 - 0,8	0,6040	0,6039	0,6038
ζ_l (-)	0,4 - 0,5	0,5	0,5	0,5
ζ_s (-)	0,5 - 2	2	2	2
Valores de referência segundo (MUKHERJEE, 1998).		Simulação 4	Simulação 5	Simulação 6
B_c (%)	20 - 35	28,77	28,87	28,30

Tabela B.9 - Simulações utilizando o método Bell-Delaware.

Valores de referência segundo (TEMA, 2007)		Simulação 7	Simulação 8	Simulação 9
L/D_s	3 - 15	5,9141	5,9644	5,9025
L_{bc} / D_s	0,2 - 1	0,6719	0,6725	0,6716
$L_{bi} / D_s = L_{bo} / D_s$	0,3 - 1	0,6719	0,6725	0,6716
B_c / D_s	0,18 - 0,40	0,3995	0,3995	0,3864
P_t / d_o	1,25 - 1,5	1,25	1,25	1,25
Valores de referência segundo (SINNOTT <i>et al.</i> , 2005)		Simulação 7	Simulação 8	Simulação 9
v_t (m/s)	1 - 2,5	1,0003	1,0108	1,0018
v_s (m/s)	0,3 - 1	0,5053	0,5083	0,5050
Valores de referência segundo (SHAH e SEKULIC, 2003 e THOME, 2004)		Simulação 7	Simulação 8	Simulação 9
J_c (-)	0,65 - 1,175	1,02	1,02	1,02
J_l (-)	0,7 - 0,9	0,8523	0,8524	0,8522
J_b (-)	0,7 - 0,9	0,8432	0,8428	0,8433
J_s (-)	0,85 - 1	1	1	1
J_r (-)	0,4 - 1	1	1	1
J_{total} (-)	0,4 - 1	0,7330	0,7327	0,7331
ζ_b (-)	0,5 - 0,8	0,6037	0,6027	0,6038
ζ_l (-)	0,4 - 0,5	0,5	0,5	0,5
ζ_s (-)	0,5 - 2	2	2	2
Valores de referência segundo (MUKHERJEE, 1998).		Simulação 7	Simulação 8	Simulação 9
B_c (%)	20 - 35	28,83	28,73	27,90

Tabela B.10 - Simulações utilizando o método Bell-Delaware.

Valores de referência segundo (TEMA, 2007)		Simulação 10
L/D_s	3 - 15	5,9027
L_{bc} / D_s	0,2 - 1	0,6715
$L_{bi} / D_s = L_{bo} / D_s$	0,3 - 1	0,6715
B_c / D_s	0,18 - 0,40	0,398
P_t / d_o	1,25 - 1,5	1,25
Valores de referência segundo (SINNOTT <i>et al.</i> , 2005)		Simulação 10
v_t (m/s)	1 - 2,5	1,0018
v_s (m/s)	0,3 - 1	0,5050
Valores de referência segundo (SHAH e SEKULIC, 2003 e THOME, 2004)		Simulação 10
J_c (-)	0,65 - 1,175	1,02
J_l (-)	0,7 - 0,9	0,8522
J_b (-)	0,7 - 0,9	0,8433
J_s (-)	0,85 - 1	1
J_r (-)	0,4 - 1	1
J_{total} (-)	0,4 - 1	0,7330
ζ_b (-)	0,5 - 0,8	0,6038
ζ_l (-)	0,4 - 0,5	0,5
ζ_s (-)	0,5 - 2	2
Valores de referência segundo (MUKHERJEE, 1998).		Simulação 10
B_c (%)	20 - 35	28,74

APÊNDICE C




Figura C.1 – Desenho do trocador de calor otimizado pelo algoritmo GWO utilizando o método Kern sem restrições.




Figura C.2 – Desenho do trocador de calor otimizado pelo algoritmo GWO utilizando o método Bell-Delaware com restrições.