



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

JOSÉ ELOIM SILVA DE MACÊDO

**DESENVOLVIMENTO DE MODELOS DE OTIMIZAÇÃO BASEADOS EM
TÉCNICAS EVOLUTIVAS PARA O PROJETO DE REDES DE DISTRIBUIÇÃO DE
ÁGUA**

Recife

2023

JOSÉ ELOIM SILVA DE MACÊDO

**DESENVOLVIMENTO DE MODELOS DE OTIMIZAÇÃO BASEADOS EM
TÉCNICAS EVOLUTIVAS PARA O PROJETO DE REDES DE DISTRIBUIÇÃO DE
ÁGUA**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de doutor em Engenharia Civil.

Área de Concentração: Tecnologia Ambiental e Recursos Hídricos.

Orientador: Prof. Dr. José Roberto Gonçalves de Azevedo.

Coorientador: Prof. Dr. Saulo de Tarso Marques Bezerra.

Recife

2023

Catálogo na fonte:
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

M141d Macêdo, José Eloim Silva de.
Desenvolvimento de modelos de otimização baseados em técnicas evolutivas para o projeto de redes de distribuição de água / José Eloim Silva de Macêdo. – 2023. 126 f.: il., fig., tab., abrev. e siglas.

Orientador: Prof. Dr. José Roberto Gonçalves de Azevedo.
Coorientador: Prof. Dr. Saulo de Tarso Marques Bezerra.
Tese (Doutorado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil. Recife, 2023.
Inclui referências e apêndice.

1. Engenharia civil. 2. Sistema de distribuição de água. 3. Algoritmo híbrido. 4. Otimização metaheurística. 5. PSO-RC. 6. Ciclos de reinicialização. 7. H-PSOTS. 8. Custo computacional. 9. Particle swarm optimization. 10. Tabu search. I. Azevedo, José Roberto Gonçalves de (Orientador). II. Bezerra, Saulo de Tarso Marques (Coorientador). III. Título.

UFPE

624 CDD (22. ed.)

BCTG/2023-104

JOSÉ ELOIM SILVA DE MACÊDO

**DESENVOLVIMENTO DE MODELOS DE OTIMIZAÇÃO BASEADOS EM
TÉCNICAS EVOLUTIVAS PARA O PROJETO DE REDES DE DISTRIBUIÇÃO DE
ÁGUA**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do título de doutor em Engenharia Civil. Área de concentração: Tecnologia Ambiental e Recursos Hídricos.

Aprovado em: 05/04/2023.

BANCA EXAMINADORA

Prof. Dr. Anderson Luiz Ribeiro de Paiva (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Marco Aurélio Holanda de Castro (Examinador Externo)
Universidade Federal do Ceará

Profa. Dra. Silvanete Severino da Silva (Examinador Externo)
Universidade Federal Rural de Pernambuco

Profa. Dra. Leidjane Maria Maciel de Oliveira (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Artur Paiva Coutinho (Examinador Interno)
Universidade Federal de Pernambuco

AGRADECIMENTOS

À Deus, agradeço por sua presença e amor em minha vida, por oferecer oportunidades e me iluminar no caminho para a realização deste trabalho, mesmo diante das dificuldades encontradas.

À minha mãe e avó (em memória), pelo incondicional amor, incentivo e dedicação para que eu pudesse realizar meus estudos e conquistar tudo o que obtive na minha vida.

À minha esposa, Jéssica Macêdo, por todo o apoio e compreensão durante essa jornada.

A todos os meus familiares, especialmente às minhas irmãs, Silvana, Sofia e Maria Clara, por serem um grande exemplo de sucesso e sabedoria.

À Universidade Federal de Pernambuco, pela qualidade do ensino público que me proporcionou tantas oportunidades.

Por fim, agradeço ao meu orientador José Roberto Gonçalves de Azevedo e coorientador Saulo de Tarso Marques Bezerra, pela disponibilidade para me atender, pelos conhecimentos compartilhados e pela paciência durante esse processo de estudos.

A todos aqueles que contribuíram de forma direta ou indireta para a realização deste trabalho, compartilho essa conquista com muita gratidão.

“Talvez eu não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito. Acredito que eu ainda não sou o que deveria ser, mas Graças a Deus, já não sou o que eu era antes” (KING, 1964, p. 168).

RESUMO

O crescimento populacional elevado faz com que novos projetos de redes de distribuição de água (RDA) sejam elaborados diariamente. Essas redes são responsáveis por transportar água potável dos reservatórios aos consumidores finais de maneira contínua e ininterrupta, garantindo qualidade, quantidade e pressão adequadas. No entanto, devido aos altos custos de implantação vinculados à complexidade resolutiva desse problema, projetistas e pesquisadores estão desenvolvendo modelos de otimização baseados em algoritmos evolutivos que buscam melhores soluções para o dimensionamento, com o menor custo computacional possível. Sendo assim, esta tese apresenta duas novas metodologias de otimização. A primeira é um modelo híbrido composto pelos algoritmos de otimização *Particle Swarm Optimization* (PSO) e *Tabu Search* (TS), denominado H-PSOTS. Esse modelo objetiva tornar a busca mais eficiente, evitando movimentos repetitivos de busca durante a atualização das soluções. Entretanto, a aleatoriedade na formação do conjunto solução inicial do problema, característica deste tipo de algoritmo, pode levá-lo a uma convergência prematura em um mínimo local e a uma redução na eficiência computacional, tornando a busca mais exaustiva. Para solucionar esse problema, o segundo modelo proposto, denominado PSO-RC, objetiva uma maior exploração global do espaço de busca com ciclos de reinicialização do próprio algoritmo PSO, sem perder informações de buscas anteriores, como a posição do último ótimo local encontrado. Os modelos propostos, juntamente com o PSO convencional, foram aplicados em três problemas de destaque na literatura (*Balerna Network*, *Hanoi Network* e *Rural Network*) e na RDA de Painéis-PE. Ambos os modelos apresentaram tempos de execução menores que o PSO convencional, em todas as redes estudadas. Além disso, apresentaram resultados próximos aos melhores custos ótimos descritos na literatura. O PSO-RC demonstrou efetividade de resposta com uma redução de 38% no número de partículas do enxame em relação ao definido para o PSO convencional e o modelo híbrido. Esse enxame reduzido resultou em um menor tempo de execução nas redes de maior complexidade, além de menor variação da resposta final. Os resultados apontam que os modelos propostos são promissores para a otimização de sistemas complexos.

Palavras-chave: sistema de distribuição de água; algoritmo híbrido; otimização metaheurística; PSO-RC; ciclos de reinicialização; H-PSOTS; custo computacional; particle swarm optimization; tabu search.

ABSTRACT

The high population growth makes new water distribution network (WDN) projects being designed daily. These networks are responsible for continuously and uninterrupted transport of potable water from reservoirs to end consumers, ensuring adequate quality, quantity, and pressure. However, due to the high implantation costs associated with the resolution complexity of this problem, designers and researchers are developing optimization models based on evolutionary algorithms that seek better solutions for sizing, with the lowest possible computational cost. Therefore, this thesis presents two new optimization methodologies. The first is a hybrid model composed of Particle Swarm Optimization (PSO) and Tabu Search (TS) optimization algorithms, called H-PSOTS. This model aims to make the exploration more efficient, avoiding repetitive search movements when updating solutions. However, the randomness in the formation of the set of initial solutions of the problem, characteristic of this type of algorithm, can lead to a premature convergence in a local minimum and to a reduction in the computational efficiency, making the search more exhaustive. To solve this problem, the second proposed model, called PSO-RC, aims for greater global exploration of the search space with cycles of PSO algorithm reinitialization, without losing information from previous searches, such as the position of the last local optimum found. The proposed models, together with the conventional PSO, were applied to three prominent problems in the literature (Balerma Network, Hanoi Network and Rural Network) and in the RDA of Panelas-PE. Both models presented shorter execution times than the conventional PSO, in all studied networks. In addition, they presented results close to the best optimal costs described in the literature. The PSO-RC demonstrated response effectiveness with a 38% reduction in the number of swarm particles in relation to that defined for the conventional PSO and the hybrid model. This reduced swarm resulted in less execution time in networks of greater complexity, in addition to less variation in the final response. The results indicate that the proposed models are promising for the optimization of complex systems.

Keywords: water distribution system; hybrid algorithm; metaheuristic optimization; PSO-RC; reboot cycles; H-PSOTS; computational cost; particle swarm optimization; tabu search.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Representação de uma rede ramificada aleatória.....	22
Figura 2 –	Representação de uma rede malhada simplificada com cinco anéis.....	23
Figura 3 –	Processo iterativo entre o simulador hidráulico Epanet e o Matlab.....	52
Figura 4 –	Fluxograma de processo do Algoritmo Híbrido (H-PSOTS)	56
Figura 5 –	Processo evolutivo do Algoritmo PSO-RC	58
Figura 6 –	Fluxograma de simulação do Algoritmo PSO-RC	60
Figura 7 –	Layout da <i>Balerma Network</i>	61
Figura 8 –	Relação entre número de partículas do enxame, tempo médio de execução e o menor custo ótimo encontrado com o PSO convencional	63
Figura 9 –	Relação entre tamanho da Lista <i>Tabu</i> , tempo médio de execução e custo ótimo do H-PSOTS	64
Figura 10 –	Relação entre número de partículas do enxame, tempo médio de execução e o menor custo ótimo encontrado utilizando o H-PSOTS	66
Figura 11 –	Relação entre número de partículas do enxame, tempo médio de execução e o menor custo ótimo encontrado utilizando o PSO-RC	67
Figura 12 –	Comparação entre a relação enxame, custo ótimo e tempos médio de execução dos algoritmos PSO convencional, H-PSOTS e PSO-RC	69
Figura 13 –	Custo ótimo obtido pelos algoritmo PSO-RC e o número de ciclos executados.....	70
Figura 14 –	Variação do custo final em relação ao enxame do PSO convencional	71
Figura 15 –	Variação do custo final em relação ao enxame do H-PSOTS	71
Figura 16 –	Variação do custo final em relação ao enxame do PSO-RC.....	72
Figura 17 –	Evolução do custo ao longo dos processos de otimização do PSO-RC para a <i>Balerma Network</i>	73
Figura 18 –	Evolução do custo ao longo dos processos de otimização para a <i>Balerma Network</i>	76
Figura 19 –	Diâmetros otimizados da <i>Balerma Network</i> determinados pelo H-PSOTS	79

Figura 20 –	Pressões nodais da <i>Balerna Network</i> determinados pelo H-PSOTS	80
Figura 21 –	Layout da <i>Hanoi Network</i>	81
Figura 22 –	Variação do custo obtidos no PSO convencional, HPSOTS e PSO-RC para a <i>Hanoi Network</i>	83
Figura 23 –	Evolução do custo ao longo dos processos de otimização para a <i>Hanoi Network</i>	84
Figura 24 –	Layout da <i>Rural Network</i>	87
Figura 25 –	Variação do custo obtidos no PSO convencional, HPSOTS e PSO-RC para a <i>Rural Network</i>	89
Figura 26 –	Evolução do custo ao longo dos processos de otimização para a <i>Rural Network</i>	90
Figura 27 –	Diâmetros otimizados da <i>Rural Network</i> determinados pelo H- PSOTS	92
Figura 28 –	Pressões nodais da <i>Rural Network</i> determinados pelo H-PSOTS	92
Figura 29 –	Localização da cidade de Panelas-PE para o estudo da rede real a ser testada.....	93
Figura 30 –	Rede de distribuição de água da Rede Panelas	94
Figura 31 –	Variação do custo obtidos no PSO convencional, HPSOTS e PSO-RC para a Rede Panelas	96
Figura 32 –	Evolução do custo ao longo dos processos de otimização para a Rede Panelas	97
Figura 31 –	Diâmetros otimizados da Rede Panelas determinados pelo H- PSOTS	99
Figura 32 –	Pressões nodais da Rede Panelas determinados pelo H-PSOTS	99

LISTA DE TABELAS

Tabela 1 –	Custo de aplicação das tubulações por metro para a <i>Balerna Network</i>	62
Tabela 2 –	Parâmetros definidos para o PSO convencional, H-PSOTS e PSO-RC	76
Tabela 3 –	Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na <i>Balerna Network</i>	77
Tabela 4 –	Resultados descritos na literatura para o dimensionamento ótimo da <i>Balerna Network</i>	78
Tabela 5 –	Dados referentes a <i>Hanoi Network</i>	82
Tabela 6 –	Custo das tubulações para a <i>Hanoi Network</i>	83
Tabela 7 –	Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na <i>Hanoi Network</i>	85
Tabela 9 –	Resultados do dimensionamento ótimo da <i>Hanoi Network</i> – Diâmetros.....	86
Tabela 8 –	Resultados descritos na literatura para o dimensionamento ótimo da <i>Hanoi Network</i>	86
Tabela 10 –	Custo das tubulações para a <i>Rural Network</i>	88
Tabela 11 –	Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na <i>Rural Network</i>	90
Tabela 12 –	Resultados descritos na literatura para o dimensionamento ótimo da <i>Rural Network</i>	91
Tabela 14 –	Custos dos tubos de PVC PBA e PVC DEFoFo (Rede Painelas).....	95
Tabela 15 –	Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na Rede Painelas.....	97

LISTA DE ABREVIATURAS E SIGLAS

ACO	<i>Ant Colony Optimization</i> [= Otimização por Colônia de Formiga]
AE	Algoritmo Evolutivo
ANN	<i>Artificial Neural Network</i> [= Rede Neural Artificial]
BCO	<i>Bee Colony Optimization</i> [= Otimização por Colônia de Abelhas]
CA	Critério de Aspiração
CSO	<i>Cauchy Swarm Optimization</i> [= Otimização de Enxame de Cauchy]
DE	<i>Differential Evolution</i> [= Evolução Diferencial]
DLL	<i>Dynamic-Link Library</i> [= Biblioteca de Link Dinâmico]
DNSO	<i>Dynamic Swarm Hybrid Optimization</i> [= Otimização Híbrida por Enxame Dinâmico]
DSO	<i>Damping Swarm Optimization</i> [= Otimização de enxame de amortecimento]
EA	<i>Evolutionary Algorithm</i> [= Algoritmo Evolutivo]
EPA	<i>Environment Protection Agency</i> [= Agencia de Proteção Ambiental]
ETA	Estação de Tratamento de Água
EV	Estrutura de Vizinhaça
FoFo	Ferro Fundido
GA	<i>Genetic Algorithm</i> [= Algoritmo Genético]
HBMO	<i>Honey-Bee Mating Optimization</i> [= Otimização por Acasalamento de Abelhas]
HM	<i>Heuristic Method</i> [= Método Heurístico]
H-PSOTS	<i>Hybrid – Particle Swarm Optimization; Tabu Search</i> [= Híbrido entre os Algoritmos Otimização por Enxame de Partículas e Busca Tabu]
HSM	<i>Hybrid de Swarm Optmization</i> [= Otimização por Enxame Híbrido]
LPG	<i>Linear Programming Gradient</i> [= Gradiente de Programação Linear]
IA	Inteligência artificial
LT	Lista <i>Tabu</i>
NC	Número de Ciclos
NMC	Número Máximo de Ciclos
NMI	Número Máximo de Iterações
PO	Pesquisa operacional
PL	Programação Linear

PNL	Programação Não Linear
PSO	<i>Particle Swarm Optimization</i> [= Otimização por Enxame de Partículas]
PSO-RC	<i>Particle Swarm Optimization with Reboot Cycles</i> [= Otimização por Enxame de Partículas com ciclos de reinicialização]
PVC	Policloreto de Vinila
PBA	Ponta-Bolsa-Anel
RDA	Rede de distribuição de água
SAA	Sistema de Abastecimento de Água
SDA	Sistema de Distribuição de Água
SFLA	<i>Shuffled Frog Leaping Algorithm</i>
SINAPI	Sistema Nacional de Pesquisa de Custos e Índices da Construção Civil
SS	<i>Scatter Search</i> [= Busca Dispersa]
TC	Tolerância Convergente
TI	Tolerância de Iterações
TS	<i>Tabu Search</i> [= Busca <i>Tabu</i>]
TSHA	<i>Tabu Search Hybrid Algorithm</i> [= Algoritmo Híbrido de Busca <i>Tabu</i>]
WHSO	<i>Weighted Hybrid Swarm Optimization</i> [= Otimização por Enxame Híbrido Ponderado]

LISTA DE SÍMBOLOS

μ	Viscosidade dinâmica
C	Coeficiente de rugosidade de Hazen-Williams
c_1	Fator social
c_2	Fator cognitivo
$C_t(D, L)$	Custo do tubo de diâmetro D e comprimento L
D	Diâmetro de uma tubulação
f	Fator de atrito
$f(D)$	Função objetivo ou <i>fitness</i> , variando em função do diâmetro
G_{best}	Melhor posição alcançada pelo enxame
L	Comprimento do trecho de tubulação
m	Número total de trechos de tubulação na rede de distribuição de água
$MPart$	Partícula de memória
n	Número total de nós de uma rede
n_p	Número total de partículas do enxame
N^{rep}	Número de vezes que determinado valor ótimo se repete
N^{rest}	Número de iterações que restam ocorrer até atingir o critério NMI
N^{total}	Número máximo de iterações
P	Pressão no nó
P_{best}	Melhor posição individual alcançada pela partícula
P_{min}	Pressão mínima requerida no mesmo nó
Q	Vazão em um trecho de tubulação
Q_e	Vazão de abastecimento ou demanda do nó
Q_{ent}	Vazão que está chegando ao nó
Q_{sai}	Vazão que sai do nó
$rand$	Valor aleatório (gerador randômico) entre 0 e 1
Rh	Raio hidráulico
S_f	Gradiente hidráulico
t	Iteração corrente
v	Velocidade da água na tubulação
v_p	Velocidade da partícula
w	Fator de inércia
w_{final}	Fator de inercia final

$W_{inicial}$	Fator de inercia inicial
x	Posição da partícula
x^I	Limites inferior da posição da partícula
x^S	Limites superior da posição da partícula
α	Constante numérica de conversão na fórmula da velocidade de escoamento
Δh	Perda de carga ao longo de uma tubulação
ω	Constante numérica de conversão na fórmula de perda de carga
ε	Coefficiente de rugosidade de Darcy-Weisbach

SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	HIPÓTESE.....	18
1.2	OBJETIVOS	19
1.2.1	Objetivo geral.....	19
1.2.2	Objetivos específicos	19
1.3	ESTRUTURA GERAL DA TESE	20
2	PROJETO DE REDES DE DISTRIBUIÇÃO DE ÁGUA.....	21
2.1	REDES DE DISTRIBUIÇÃO DE ÁGUA	21
2.2	OTIMIZAÇÃO DE PROJETOS DE REDES DE DISTRIBUIÇÃO DE ÁGUA.....	23
3	TÉCNICAS DE OTIMIZAÇÃO	28
3.1	ALGORITMOS EVOLUTIVOS.....	33
3.1.1	<i>Particle Swarm Optimization (PSO)</i>	36
3.1.2	<i>Tabu Search (TS)</i>	40
3.1.3	Algoritmos híbridos	43
3.1.4	Algoritmos evolutivos aplicados a projeto de redes de distribuição de água	46
4	METODOLOGIA.....	51
4.1	FORMULAÇÃO NUMÉRICA	53
4.2	ALGORITMO HÍBRIDO (H-PSOTS).....	55
4.2.1	Estrutura híbrida.....	55
4.3	ALGORITMO COM CICLOS DE REINICIALIZAÇÃO (PSO-RC).....	57
5	RESULTADOS E DISCUSSÃO.....	61
5.1	<i>BALERMA NETWORK</i>	61
5.2	<i>HANOI NETWORK</i>	80
5.3	<i>RURAL NETWORK</i>	87
5.4	REDE PANELAS	93
6	CONCLUSÃO.....	101
	REFERÊNCIAS.....	104
	APÊNDICE A – HYBRID PARTICLE SWARM OPTIMIZATION AND TABU SEARCH FOR THE DESIGN OF LARGE-SCALE WATER DISTRIBUTION NETWORKS.....	114

1 INTRODUÇÃO

As redes de distribuição de água (RDA) são essenciais para os sistemas de abastecimento de água (SAA), pois são responsáveis por levar a água potável aos usuários com pressão e fluxo adequados para atender às suas necessidades hídricas. Por isso, é imprescindível que sejam considerados fatores de estado, como pressão e velocidade da água, para garantir a qualidade do serviço, escolhendo com cautela o diâmetro dos dutos. De acordo com Farias et al. (2021), as RDA representam mais da metade do custo total de implantação de um SAA, motivo pelo qual investir em projetos de qualidade é fundamental para garantir um abastecimento seguro e eficaz de água, aproveitando ao máximo os recursos disponíveis. Ademais, o crescimento populacional elevado exige que novos projetos sejam desenvolvidos diariamente (SARDINHA; JUNIOR, 2020. LEMOS; BARBOSA; LOPES, 2020).

Os métodos tradicionais de projeto de RDA baseiam-se geralmente em métodos de tentativa e erro guiados pela experiência do projetista (GOMES et al., 2009; BEZERRA; MACEDO, 2018; WANG et al., 2021; MACEDO; AZEVEDO; BEZERRA, 2021). Estes processos são altamente complexos e exaustivos, pois envolvem variáveis de estado do problema relacionadas às leis de conservação de massa e energia da física.

A falta de recursos financeiros é um grande desafio para a implantação de redes de distribuição de água em muitas partes do mundo. Para contornar essa limitação, rotinas de otimização juntamente a modelos de simulação hidráulica foram implementados para ajudar a escolha de diâmetros das tubulações, visando selecionar a solução econômica mais adequada para garantir a qualidade do serviço (MAZUMDER et al., 2019; FARIAS et al., 2021).

A otimização de uma RDA é um processo difícil, pois a variação em um diâmetro de um trecho afeta todas as variáveis de estado da rede, como pressão e vazão, de forma não linear. Inicialmente, técnicas de programação linear, não linear e dinâmica foram utilizadas para a minimização do custo, embora apresentem desvantagens como ineficiência, encontro da solução ótima local na busca do ótimo global, falta de flexibilidade no trato de variáveis discretas, complexidade na implementação e elevado tempo de processamento. Para superar essas limitações, algoritmos evolucionários, que possuem a característica de busca global, são considerados uma alternativa viável para o tratamento de problemas complexos (NASCIMENTO; COSTA, 2018).

Os algoritmos evolucionários, que se enquadram como um subconjunto dos algoritmos de inteligência artificial (IA), são técnicas de busca estocástica fundamentados de forma racional na inteligência coletiva proveniente da auto-organização e do comportamento

adaptativo da sociedade de certos animais (peixes, pássaros, abelhas, formigas, etc.), conhecidos categoricamente como Metaheurísticos (OSABA et al., 2021). Esses algoritmos vêm apresentando bons resultados no dimensionamento de sistemas de distribuição de água. Entre eles, se destacam em aplicações voltadas a recursos hídricos, o *Particle Swarm Optimization* (PSO) (KENNEDY; EBERHART, 1995; BEZERRA; MACÊDO, 2018; MONSEF et al., 2019; MACÊDO; AZEVEDO; BEZERRA, 2021), *Tabu Search* (TS) (GLOVER, 1989, 1990; GLOVER; LAGUNA, 1998; SUNG et al., 2007; UTAMIMA et al., 2015; WEI; HAO, 2021; MACÊDO; AZEVEDO; BEZERRA, 2021), *Genetic Algorithm* (GA) (HOLLAND, 1975; BI; DANDY; MAIER, 2015; SILVA; FERREIRA; STEINER, 2019; TANYIMBOH; SEYOUM, 2020), *Ant Colony Optimization* (ACO) (DORIGO; MANIEZZO; COLORNI, 1996; MAIER et al., 2003; OLIVAS et al., 2017; SARBU; POPA-ALBU, 2023), e *Differential Evolution* (DE) (SURIBABU, 2010; ZHENG; SIMPSON; ZECCHIN, 2011; MONSEF et al., 2019; CHEN et al., 2020), entre outros.

Cada algoritmo evolucionário tem vantagens e desvantagens, afinando-se melhor para alguns problemas do que outros. Um deles é o *Particle Swarm Optimization* (PSO), algoritmo desenvolvido pelo psicólogo social James Kennedy e o engenheiro elétrico Russel Eberhart em 1995 (KENNEDY; EBERHART, 1995). Inspirado pelo comportamento social observado em diversas espécies de animais, inclusive o humano, o PSO ganhou reconhecimento como um método de programação evolutiva, que ao longo das últimas décadas, vem sendo amplamente utilizado em problemas de otimização na engenharia, particularmente no dimensionamento de redes de distribuição de água, devido à sua facilidade de implementação e aos bons resultados apresentados na literatura (BEZERRA; MACÊDO, 2018; MOKARRAM; BANAN, 2018; MONSEF et al., 2019; ESHAGHZADEH; HAJIAN, 2021; MACÊDO; AZEVEDO; BEZERRA, 2021).

No PSO, o conjunto solução do problema a ser otimizado é representado pela posição de cada partícula no espaço de busca. A cada iteração, as partículas se movimentam para explorar esse espaço com a finalidade de encontrar o melhor resultado possível para a função objetivo, conhecido como ótimo global. No entanto, este processo de movimentação pode levar as partículas a retomarem posições já visitadas o que aumenta o custo computacional e diminui o poder exploratório do algoritmo. Assim, a inserção do algoritmo de otimização *Tabu Search* (TS) no processo exploratório do PSO surge como uma promissora solução para este problema, já que o TS restringe os movimentos repetitivos das partículas, aumentando a diversificação das soluções e norteando a exploração até o ótimo global.

O *Tabu Search* é um algoritmo metaheurístico de otimização, que tem sido destacado na comunidade científica como método auxiliar a outras técnicas de otimização para várias pesquisas (UTAMIMA et al., 2015; MARZOUKI; DRISS; GHÉDIRA, 2018; PRAJAPATI; JAIN; CHOUHAN, 2020; WEI; HAO, 2021; MACÊDO; AZEVEDO; BEZERRA, 2021). Esse algoritmo se destaca na exploração local, mudando de uma solução para outra em cada iteração, sem repetir movimentos já realizados, o que permite uma maior diversificação das soluções para encontrar o valor próximo ao ótimo global (GLOVER; LAGUNA, 1998).

Entretanto, vale salientar que, muitas vezes, por trás de simulações bem-sucedidas, há diversas tentativas frustradas, devido à grande aleatoriedade na geração de soluções iniciais, característica inerente aos algoritmos metaheurísticos. Dependendo da complexidade do espaço de busca e da posição inicial gerada, a nova simulação poderá resultar em uma nova convergência prematura em um mínimo local, ou até mesmo em um valor ótimo inferior ao último encontrado.

Ante ao exposto, esta tese apresenta duas propostas de solução promissoras para a problemática da otimização no contexto do complexo de dimensionamento de redes de distribuição de água: um modelo de otimização híbrida fundamentado nos algoritmos evolutivos e metaheurísticos PSO e TS, e um outro com a otimização baseada em ciclos de reinicialização do próprio PSO. Estes dois novos modelos somam-se a outras propostas de melhorias de processo de busca já amplamente aplicadas na área de Recursos Hídricos como em outras áreas de estudo (WANG; ZHANG; YANG, 2016; BEZERRA; MACÊDO, 2018; SURCO; VECCHI; RAVAGNANI, 2018; ARAUJO, 2019; ALIZADEH ET AL., 2019; MAZUMDER et al., 2019; ALIZADEH et al., 2019; KHAN, 2020; FARIAS et al., 2021; MACÊDO; AZEVEDO; BEZERRA, 2021; TORKOMANY et al., 2021).

Ambas propostas, foram aplicadas em três problemas de destaque na literatura e em um caso real de rede de distribuição de uma cidade localizada no interior do estado de Pernambuco, Brasil. Estes novos modelos buscam bons resultados aliados a uma boa eficiência computacional, para demonstrar que são apropriadas para aplicações em sistemas reais com grandes espaços de busca e complexidade.

1.1 HIPÓTESE

A aplicação de novas metodologias de otimização - como o algoritmo híbrido *Particle Swarm Optimization* (PSO) e o *Tabu Search* (TS) (H-PSOTS), e o algoritmo com ciclos de reinicialização baseado no PSO (PSO-RC) - podem ser uma opção na busca de soluções

eficazes para otimizar o projeto de redes de distribuição de água, reduzindo custos computacionais e tornando o processo mais rápido e efetivo para projetistas e pesquisadores. Essas ferramentas podem proporcionar resultados satisfatórios que garantam o transporte contínuo e ininterrupto de água potável aos consumidores finais, com qualidade, quantidade e pressão adequada.

1.2 OBJETIVOS

Para direcionar o desenvolvimento desta pesquisa e alcançar as respostas necessárias à problemática levantada, esta tese apresenta um objetivo geral e objetivos específicos nesta subseção. Desta forma, busca-se estabelecer uma estrutura clara para o estudo e orientar os leitores sobre os principais pontos abordados na pesquisa.

1.2.1 Objetivo geral

Esta tese busca desenvolver dois novos modelos de otimização para o projeto de rede de distribuição de água. O primeiro, denominado H-PSOTS, é um algoritmo híbrido que tem como objetivo aumentar a exploração local do PSO. O segundo modelo, PSO-RC, procura melhorar a exploração global do processo de otimização através de ciclos de reinicialização do próprio algoritmo PSO.

1.2.2 Objetivos específicos

De acordo com as necessidades já enfatizadas, definem-se como objetivos específicos da pesquisa proposta:

- a) Desenvolver um novo algoritmo híbrido baseado na combinação das técnicas *Particle Swarm Optimization* e *Tabu Search* que permita maior exploração local e refinamento da solução ótima encontrada;
- b) Propor um novo modelo de busca baseado na técnica *Particle Swarm Optimization* que proporcione maior exploração global do algoritmo e menor variabilidade de resposta, através ciclos de reinicialização, visando evitar a convergência prematura para soluções subótimas;
- c) Validar os modelos propostos através da aplicação em redes exemplificadas na literatura e em uma rede de distribuição real de uma cidade do Agreste de

Pernambuco, Brasil, comparando os resultados obtidos com os modelos existentes na literatura e avaliando a eficácia e a viabilidade dos modelos propostos em termos de desempenho, precisão e custo computacional.

1.3 ESTRUTURA GERAL DA TESE

Esta tese está organizada em seis seções. A primeira seção consiste em uma introdução geral, que descreve a contextualização do tema, sua importância e justificativas para o estudo, além da hipótese, objetivos geral e específicos.

A segunda e terceira seções tratam da fundamentação teórica da tese, abordando o estudo hidráulico de redes de distribuição de água, expondo os modelos e contribuições sobre o tema. Nestas seções, são apresentados, também, os modelos de otimização e os Algoritmos Evolutivos, abordando os de aplicação na tese, com foco em projetos de dimensionamento otimizado de redes de distribuição de água, bem como o estado da arte dos trabalhos já publicados.

Na quarta seção, é descrita a metodologia adotada, incluindo os materiais e procedimentos metodológicos, a natureza da pesquisa, a abrangência do estudo, os instrumentos e dados utilizados, a caracterização da função objetivo, os critérios e parâmetros adotados, a estrutura dos modelos desenvolvidos, a descrição rápida das redes estudadas e a situação envolvente.

Na quinta seção, são descritas detalhadamente as redes estudadas, além da discussão aprofundada dos resultados obtidos com as análises realizadas. É realizada também uma avaliação comparativa dos algoritmos propostos, fundamentada na hipótese inicial e confirmada pelo artigo publicado e presente no apêndice A desta tese.

Na sexta e última seção, são descritas as conclusões da tese e suas proposições, que visam contribuir para o seu andamento. Posteriormente, são listadas as referências utilizadas para a elaboração da tese, seguido pelo apêndice.

2 PROJETO DE REDES DE DISTRIBUIÇÃO DE ÁGUA

O projeto de redes de distribuição de água consiste em determinar se a rede de distribuição está dimensionada de forma a suportar o fluxo de água necessário, capaz de atender as necessidades operacionais e de qualidade da água. Normalmente, o dimensionamento de uma rede de distribuição de água inclui a análise de todo o conjunto de tubulações do sistema de abastecimento de água com vistas a parâmetros de operação, vazão e perda de carga para cada segmento da rede, bem como a seleção de materiais e equipamentos adequados para garantir uma ótima qualidade da água e um bom desempenho do sistema.

Além disso, o projeto de redes de distribuição de água requer uma análise e avaliação detalhada de todos os custos associados à sua construção, operação e manutenção, incluindo materiais, mão de obra, equipamentos, contratos de serviços e demais custos envolvidos. Portanto, é necessário avaliar todos esses custos de maneira minuciosa para garantir a eficiência das redes de distribuição de água (KHAN; IQBAL, 2020).

2.1 REDES DE DISTRIBUIÇÃO DE ÁGUA

O sistema de distribuição de água é todo o conjunto de processos de obtenção de água até sua utilização por parte dos consumidores. Compreende desde a captação de água no manancial ou através de águas em profundidade, passando pela Estação Elevatória, Adutora, Estação de Tratamento de Água (ETA), Reservatório Elevado, Rede de Distribuição até as ligações domiciliares. Esta última é formada por tubulações e órgãos acessórios, tais como conexões, bombas válvulas e reservatórios, todos interconectados, destinados a disponibilizar água potável aos consumidores, de forma contínua, em quantidade, qualidade e pressão adequadas (GIACOMINI; DIAS; CARVALHO, 2020).


O dimensionamento de redes de distribuição de água consiste em determinar os diâmetros adequados dos dutos para que possam atender às necessidades de pressão, vazão e qualidade da água para o abastecimento de determinada área. O dimensionamento deve ser realizado de acordo com as características do terreno, como inclinação, distância, topografia, entre outras. A análise desses fatores permitirá que o projetista escolha o diâmetro e a configuração da rede que mais se adapte às necessidades da área. Além disso, é importante levar em consideração as normas de projeto de redes de distribuição, que abrangem diversos pontos específicos, além daqueles determinados pela concessionária de cada local (PEREIRA; ALMEIDA, 2020).

De acordo com Farias et al. (2021), a rede de distribuição de água pode representar mais da metade do custo total de investimento de um sistema de distribuição, e esse custo é diretamente influenciado pela escolha e dimensionamento adequados das tubulações. Estes, por sua vez, interferem diretamente na qualidade do serviço, nas perdas reais de água, no custo de implantação e operação do sistema. Assim, o dimensionamento correto das redes de distribuição é essencial para o bom desempenho do sistema.

O traçado da rede de distribuição deve ser considerado no dimensionamento, e se remete à configuração adotada desta rede, a partir da definição topográfica de todos os seus componentes. Uma rede de distribuição de água pode ser classificada, segundo seu traçado, em rede ramificada ou rede malhada ou rede mista (PEREIRA; ALMEIDA, 2020).

Em redes ramificadas (Figura 1), os ramos principais e secundários são os condutos que formam a rede. Os ramos principais são os condutos mais próximos à saída da rede e são responsáveis por transportar a maior parte da vazão total. Já os ramos secundários estão localizados mais afastados da saída da rede e transportam uma quantidade menor dessa vazão. Nesse tipo de traçado, o escoamento tem uma única direção e as vazões são conhecidas, facilitando o dimensionamento, que é realizado determinando-se a posição e diâmetro dos ramos principais e secundários de modo que a perda de carga entre a saída da rede e cada ramo seja mínima. Além disso, as condições de operação devem atender às especificações de projeto, como por exemplo, a pressão disponível na saída da rede que deve ser suficiente para fornecer a pressão necessária a cada ramo, segundo valores determinados por normativas específicas. Com isso, tem-se que o dimensionamento da rede depende do diâmetro dos ramos principais e secundários, bem como da perda de carga associada a cada um deles (JAMIL, 2020).


Figura 1 – Representação de uma rede ramificada aleatória



Fonte: O Autor (2023).

O dimensionamento de redes malhadas é mais complexo do que o de redes ramificadas, pois os trechos estão interligados em forma de anéis ou malhas. Isso faz com que o sentido do fluxo dependa da carga hidráulica nos nós da rede, pois o fluxo vai sempre do nó com maior carga hidráulica para o nó com menor carga. Ao dimensionar uma rede malhada (Figura 2), qualquer alteração nos dados dos nós e/ou trechos de tubulação pode alterar as variáveis de estado da rede e, conseqüentemente, o sentido do fluxo de certos trechos. Redes mistas são formadas pela combinação destes dois tipos de redes, sendo, portanto, ainda mais complexas (BEZERRA; MACÊDO, 2018; JAMIL, 2020).

Figura 2 – Representação de uma rede malhada simplificada com cinco anéis



Fonte: O Autor (2023).

2.2 OTIMIZAÇÃO DE PROJETOS DE REDES DE DISTRIBUIÇÃO DE ÁGUA

Nas últimas décadas, a otimização tem sido um dos principais campos de estudo e aplicação em projetos de engenharia. O objetivo do processo de otimização é encontrar a “melhor” solução possível para um determinado problema, considerando diversos critérios como qualidade, custo, confiabilidade ou outras medidas de utilidade. Para isso, é necessário identificar o extremo, máximo ou mínimo, de uma determinada função de n variáveis de decisão, também conhecida como função objetivo. Ao aplicar a otimização em projetos de redes de distribuição de água, as empresas conseguem obter significativos ganhos de custos na implantação, manutenção e operação, fazendo uso das mais modernas tecnologias para

essa finalidade (EL-GHANDOUR; ELBELTAGI, 2018; FALLAH et al. 2019; WANG et al., 2021).

Na maioria dos sistemas físicos sujeitos a otimização, as variáveis de decisão que caracterizam seu estado estão geralmente ligadas entre si por uma série de leis de comportamento, sendo assim, o processo de otimização é restrito a conjuntos de variáveis que satisfazem essas leis. Além disso, problemas de otimização em engenharia exigem o estabelecimento de condições adicionais que descrevam os limites do bom funcionamento do sistema. Essas condições podem ser expressas funcionalmente por meio de um conjunto de equações chamadas restrições (Equações 1), do seguinte tipo (HERNÁNDEZ-DÍAZ, 2017).

$$\begin{aligned}
 a. \quad & f_j(x_1, x_2, \dots, x_n) = y_j & j &= 1 \dots n_1 \\
 b. \quad & f_k(x_1, x_2, \dots, x_n) \geq y_k & k &= 1 \dots n_2 \\
 c. \quad & f_l(x_1, x_2, \dots, x_n) \leq y_l & l &= 1 \dots n_3
 \end{aligned} \tag{1}$$

O conjunto formado pela função objetivo e as restrições é conhecido como modelo matemático. Normalmente, um modelo é composto por sua representação matemática ou algorítmica, e pelo conjunto de dados necessários para sua solução. É importante equilibrar o nível de detalhe exigido pelo modelo, as técnicas numéricas disponíveis para sua resolução, a disponibilidade e a facilidade de manipulação dos dados e as conclusões desejadas após a análise dos resultados (HERNÁNDEZ-DÍAZ, 2017).

A função objetivo a ser otimizada em um projeto de redes de distribuição de água é do custo de aquisição e assentamento das tubulações. Essa otimização busca minimizar esse custo de investimento da rede, mantendo as restrições hidráulicas, atendendo às demandas requeridas nos nós de cada rede com pressões acima das mínimas preestabelecidas. Para tal, o modelo matemático de otimização deve garantir que as vazões nos trechos da rede de distribuição e as pressões nos nós estejam de acordo com as leis de conservação de energia e massa (LIMA; SILVA; SOUZA, 2016; HERNÁNDEZ-DÍAZ, 2017).

Além disso, os parâmetros de ajuste que permitem obter a solução ótima para o modelo de otimização de rede de distribuição de água incluem a dimensão das tubulações, a disposição das tubulações, a localização dos nós de pressão, a pressão de alimentação e a vazão de cada nó. Esses parâmetros são ajustados para que o custo total seja o mínimo possível e as pressões e vazões requeridas sejam atendidas (LIMA; SILVA; SOUZA, 2016).

O projeto ótimo de redes de distribuição de água foi proposto inicialmente por Alperovits e Shamir (1977) e ainda é replicada até hoje. Essa proposta tinha por objetivo

encontrar a solução ótima para o problema da rede de distribuição de água, através da minimização dos custos de implantação da rede, que por sua vez estão relacionados aos diâmetros dos tubos e de seus respectivos comprimentos. Para tal, a Equação 2, conhecida como função objetivo, pode ser usada para encontrar a solução mais eficiente para o problema.

$$f(D_1, D_2, \dots, D_m) = \sum_{i=1}^m C_t(D_i, L_i) \quad (2)$$

onde m é o número total de trechos de tubulação na rede de distribuição de água; $C_t(D_i, L_i)$ é o custo do tubo i de diâmetro interno D e comprimento L .

No projeto de uma rede de distribuição de água, é necessário satisfazer algumas restrições para que a função objetivo seja minimizada. Estas restrições devem ser descritas a seguir.

Para cada nó, exceto a fonte, a Equação 3 da continuidade deve ser satisfeita.

$$\sum Q_{ent} - \sum Q_{sai} = Q_e \quad (3)$$

onde Q_{ent} é vazão que está chegando ao nó; Q_{sai} é a vazão que está saindo do nó e Q_e é a vazão de abastecimento ou demanda do nó. De acordo com esta convenção, quando a vazão Q_e é positiva, há um consumo no nó, e quando a vazão Q_e é negativa, há um abastecimento no nó.

A análise da energia como parte da dinâmica de redes malhadas é extremamente importante. Para cada um dos anéis da rede, a equação da conservação da energia pode ser expressa pela Equação 4.

$$\sum \Delta h_i = 0 \quad (4)$$

onde Δh_i é a perda de carga ao longo de uma tubulação i pertencente a malha ou anel, determinada pelas fórmulas de Hazen-Williams ou Darcy-Weisbach.

A análise da rede hidráulica é um dos principais pontos para a manutenção de um sistema hidráulico. Para garantir o bom funcionamento do sistema, é necessário verificar se a pressão de serviço dos nós estão de acordo com o projeto. Assim, na Equação 5 está estabelecida a restrição de pressão mínima para cada nó da rede.

$$P_j \geq P_{j \min}; \quad j=1, \dots, n \quad (5)$$

onde P_j é a pressão no nó j ; $P_{j \min}$ é a pressão mínima requerida no mesmo nó e n é o número total de nós no sistema.

Os projetistas têm como preocupação primordial prever a capacidade de condução do sistema de dutos, para o qual é necessário calcular a perda de carga ao longo dos tubos por meio de equações que consideram a pressão, vazão, comprimento e diâmetro nos cálculos. Várias fórmulas foram desenvolvidas para determinar a perda de carga devido ao atrito, sendo as mais conhecidas e usadas as de Darcy-Weisbach e de Hazen-Williams. A equação empírica de Hazen-Williams é a mais utilizada em aplicações reais, sendo representada pela Equação 6.

$$v = C \cdot Rh^{0,63} \cdot S_f^{0,54} \quad (6)$$

onde v é a velocidade do escoamento; Rh é o raio hidráulico; S_f é o gradiente hidráulico e C é o coeficiente de rugosidade dimensional cujo valor numérico pode mudar de acordo com o sistema de unidades de medida utilizado. Para um conduto circular, Rh é igual a $D/4$.

A fim de simplificar a Equação 6, o valor de C é considerado como sendo constante, e, assim, a fórmula pode ser escrita conforme a Equação 7.

$$v = \alpha \cdot C \cdot D^{0,63} \cdot S_f^{0,54} \quad (7)$$

onde D é o diâmetro interno do tubo; e α é uma constante que assume o valor de 0,55 no Sistema Britânico e 0,355 no Sistema Internacional. A seguir, apresenta-se a Equação 8, que permite determinar a perda de carga Δh desejada, tendo a vazão Q conhecida.

$$\Delta h = \omega \frac{L}{C^a \cdot D^b} Q^a \quad (8)$$

onde ω é a constante numérica de conversão, que depende do sistema de unidades utilizado; a é um coeficiente que vale $1/0,54 = 1,85$; b é um coeficiente que vale $2,63/0,54 = 4,87$; e L é o comprimento do trecho de tubulação.

As Equações 7 e 8 são fundamentais para a simulação de sistemas hidráulicos, pois descrevem a pressão e o fluxo de água em um determinado ponto do sistema, sendo assim, a constante de conversão α e ω deve ser considerada com o devido cuidado. Diferentes pesquisadores têm utilizado valores diferentes para essas constantes. Por exemplo, Savic e Walters (1997) utilizaram o coeficiente $\omega = 10,5088$, enquanto Alperotivs e Shamir (1977) e

os principais simuladores hidráulicos (ROSSMAN, 1994, 2000, 2020) consideram $\omega = 10,6792$. A definição desses parâmetros é fundamental para obter resultados precisos, o que garante o bom funcionamento dos sistemas hidráulicos. As equações mais utilizadas para o cálculo das perdas de carga em escoamentos forçados são a de Hazen-Williams, Equação (9), proposta em 1906, e a de Darcy-Weisbach, Equação (10), inicialmente proposta em 1845. A equação de Chezy-Manning, inicialmente proposta pelo engenheiro francês Antoine de Chézy, em 1769, é usualmente utilizada em escoamentos livres (Equação 11).

$$\Delta h = 10,67 \frac{L}{C^{1,852} \cdot D^{4,871}} Q^{1,825} \quad (9)$$

$$\Delta h = 0,0827 \frac{f \cdot Q^2 \cdot L}{D^5} \quad (10)$$

$$\Delta h = 10,29 \frac{n_m^2 \cdot L \cdot Q^2}{D^{5,33}} \quad (11)$$

onde D é o diâmetro interno do tubo; Q a vazão no trecho; L o comprimento do trecho; C o coeficiente de rugosidade de Hazen-Williams; f é o fator de atrito de Darcy-Weisbach; e n_m é o coeficiente de rugosidade de Manning.

A equação de Darcy-Weisbach é consistente em termos dimensionais. O valor f (fator de Darcy-Weisbach) depende de 4 variáveis: diâmetro interno da tubulação (D), vazão do trecho (Q), coeficiente de rugosidade de Darcy-Weisbach (ε) e a viscosidade dinâmica (μ). O cálculo do fator de Darcy-Weisbach não é explícito e não existe uma única equação para calculá-lo em todos os tipos de regimes hidráulicos.

Diante disso, é notório que a análise minuciosa da formação matemática para otimizar projetos de rede de distribuição de água assume grande importância, pois é responsável por garantir a eficiência, controle e segurança na distribuição deste recurso vital para os consumidores. Além disso, técnicas de otimização desenvolvidas ao longo das últimas décadas permitem essa otimização de forma eficiente, tornando essencial para a obtenção de bons resultados atrelados a qualidade do projeto desenvolvido.

3 TÉCNICAS DE OTIMIZAÇÃO

Anteriormente, a definição de projetos de sistemas era realizada pelo método de tentativa e erro, que funciona bem para sistemas simples, pois um projetista experiente pode prever ou adivinhar a influência das variáveis de projeto sobre o funcionamento do mesmo. No entanto, é difícil encontrar soluções ótimas para sistemas complexos, devido ao número de variáveis envolvidas e à interdependência muito extensa e complexa entre elas (INCE, 2010; MORA-MELIA et al., 2015; JAFARI, 2018).

Desde então, a Pesquisa Operacional (PO) visa à identificação de soluções ótimas para o projeto de sistemas complexos, considerando como base os requisitos para sua operação. Para isso, usa-se a otimização sistemática para avaliar a influência dos parâmetros de projeto na melhor solução possível, aplicando técnicas de otimização. Desde a Segunda Guerra Mundial e a invenção e desenvolvimento dos computadores, os avanços na área de otimização de sistemas têm sido significativos, possibilitaram a melhoria na qualidade da solução, assim como o aumento da eficiência em seu processo de implementação (MORA-MELIA et al., 2015).

Dessa forma, segundo Gonzalez, Cruz e Gómez (2020), os problemas de otimização podem ser classificados como:

- a. **Problemas de minimização:** São problemas que requerem que a solução ótima seja encontrada pelo mínimo de recursos. Exemplos incluem métodos gradientes, algoritmos genéticos e programação linear.
- b. **Problemas de maximização:** São problemas que requerem que a solução ótima seja encontrada pelo máximo de recursos. Exemplos incluem algoritmos de programação dinâmica, algoritmos de busca local e algoritmos híbridos.
- c. **Problemas multicritério:** São problemas que requerem que a solução ótima seja encontrada a partir de vários critérios. Exemplos incluem métodos evolutivos, análise multicritério e algoritmos genéticos.
- d. **Problemas de tomada de decisão:** São problemas que requerem que a solução ótima seja encontrada com base em determinadas decisões. Exemplos incluem análise de sensibilidade, análise de risco e inteligência artificial.

A otimização é uma área fundamental da engenharia, pois permite otimizar uma grande variedade de problemas de complexa resolução. Existem várias técnicas de otimização

disponíveis, cada uma com seus próprios benefícios e desvantagens. No entanto, é interessante fazer uma análise classificatória do problema de otimização para ter critérios suficientes para selecionar as técnicas e algoritmos mais adequados e eficazes para sua resolução. Diversas técnicas foram desenvolvidas e implementadas ao longo das últimas décadas. Elas podem ser classificadas em seis categorias (TONG; LI, 2015):

1. **Técnicas de Otimização Linear ou Programação Linear:** estas técnicas incluem o uso de programação linear para encontrar a solução ótima do problema. Em geral, são utilizados algoritmos de otimização, como o SIMPLEX, para resolverem problemas de otimização com várias variáveis.
2. **Técnicas de Otimização Não Linear Convexa:** esse tipo de técnica é um ramo da otimização matemática que envolve encontrar o melhor resultado possível para um problema de otimização com restrições não lineares. Os problemas de otimização não linear convexa são geralmente mais difíceis de resolver do que os problemas lineares, pois envolvem funções de custo não lineares e restrições complexas, e devido às propriedades da convexidade, se tiver algum ótimo, será um mínimo global. A otimização não linear convexa é aplicada em muitas áreas, como engenharia, economia, ciência da computação, finanças e estatística.

Dependendo do tipo de problema, diferentes soluções de otimização podem ser propostas. A linearização é usada para transformar problemas não lineares em lineares, o que fornece uma aproximação adequada do problema real. A programação quadrática trata de funções objetivo quadráticas e restrições lineares e pode ser resolvida por meio de transformação em um problema linear equivalente. O Método do Gradiente é um algoritmo iterativo que melhora a solução na direção do gradiente da função objetivo e encontra o ótimo (HOFFMAN; CAVES, 2017).

Para problemas de otimização não lineares mais complexos, técnicas de otimização não linear convexa são usadas. Estas técnicas incluem Gradiente Descendente, Algoritmo de Quasi-Newton, Método de Coordenada Descendente, Método de Barreira de Lagrange e Método de Subgradiente (HOFFMAN; CAVES, 2017; NESTEROV, 2019).

3. **Técnicas de Otimização Não Convexa:** se o problema de otimização não for convexo, ele pode conter um ótimo local, de modo que as primeiras técnicas

desenvolvidas, como o Método Gradiente, podem convergir em um ótimo local sem ter explorado todo o espaço de busca atrás de “melhores” soluções. Para casos não convexos, diversos procedimentos podem ser aplicados, como: Enumeração Explícita ou Exaustiva, Enumeração Implícita ou Parcial e Métodos Metaheurísticos.

- a. **Enumeração Explícita ou Exaustiva:** é um método de resolução de problemas em que se lista todas as possíveis soluções ou combinações. É usado quando há um pequeno número de possíveis soluções e, portanto, é considerado útil apenas para problemas de pequena escala. O método de enumeração explícita ou exaustiva pode ser útil para descobrir todas as possíveis maneiras de satisfazer um certo requisito.
- b. **Enumeração Implícita ou Parcial:** é um método na qual os elementos de um conjunto são numerados com um número de um ao número de elementos do conjunto. Essa técnica é usada quando os elementos do conjunto não podem ser identificados diretamente. Por exemplo, ao contar o número de pessoas em uma sala, seria impossível enumerar todas as pessoas individualmente. Nesse caso, a enumeração parcial é usada para contar o número de pessoas na sala.
- c. **Métodos Metaheurísticos:** são métodos de busca que procuram encontrar soluções ótimas para problemas complexos. São úteis para a solução de problemas que possuem um grande número de variáveis e, portanto, são difíceis de modelar usando técnicas clássicas. Os métodos metaheurísticos usam técnicas como simulação, otimização e busca local para explorar o espaço de soluções e encontrar soluções ótimas. Estes métodos são úteis quando nenhuma solução exata está disponível, e são usados em diversas áreas, como otimização de processos, reconhecimento de padrões, planejamento de atividades, programação de tarefas e processamento de imagens.

Esses métodos buscam melhorar uma solução inicial por meio de uma aproximação racional têm ganhado destaque nos últimos anos. Estes métodos oferecem uma grande flexibilidade para adaptar-se a diversos problemas específicos, mas não são capazes de garantir a obtenção do ótimo global. Apesar disso, estes métodos têm contribuído de forma significativa para aprofundar o conhecimento sobre o processo de resolução de problemas complexos. Alguns dos métodos de Metaheurísticas mais conhecidos são: *Ant Colony Optimization* (ACO), *Genetic Algorithm* (GA), *Shuffled Frog Leaping Algorithm* (SFLA), *Honey-Bee Mating Optimization* (HBMO), *Tabu Search* (TS) e *Particle Swarm Optimization*

(PSO). Estes métodos permitem, geralmente, a obtenção de melhores soluções para problemas com otimização de custos, desempenho e tempo de execução (LIU; LI, 2016).

4. **Técnicas de Programação Dinâmica:** estas técnicas utilizam a programação dinâmica para encontrar a solução ótima para o problema. A programação dinâmica é um método de solução de problemas que divide um problema em subproblemas menores, que são resolvidos e armazenados para evitar a necessidade de resolver os mesmos subproblemas repetidamente.
5. **Técnicas de Otimização Multiobjetivo:** Estes algoritmos consideram múltiplos objetivos na busca do valor ótimo. Estes algoritmos são especialmente úteis quando se trata de problemas de otimização multiobjetivo, pois permitem a obtenção de múltiplas soluções ótimas que maximizam o desempenho, o custo e outros objetivos relevantes.
6. **Técnicas de Otimização Evolutivas:** são utilizadas para otimizar o desempenho de algoritmos, como a otimização de parâmetros, seleção de variáveis, criação de modelos e outros. Elas são baseadas na evolução natural, onde os resultados são obtidos a partir de processos iterativos, como a seleção natural, a mutação e a recombinação. Exemplos de técnicas evolutivas são *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO) e *Ant Colony Optimization* (ACO). Algumas técnicas evolutivas podem apresentar métodos metaheurísticos de resolução, como também ser composta de outras técnicas de otimização.

Uma das primeiras contribuições significativas para o avanço do dimensionamento ótimo de redes foi o uso da técnica *Linear Programming Gradient* (LPG), do inglês, Gradiente de Programação Linear (GPL), que tem como algoritmo a programação linear, o método do gradiente (BHAVE; SONAK, 1992).

Uma das primeiras aplicações desse método em RDA foi apresentada por Alperovits e Shamir (1977). Esta pesquisa estabeleceu os primeiros conceitos relacionados à otimização de redes hidráulicas, e além disso, os autores consideraram diferentes estados de carga hidráulica nos seus projetos, enfatizando que as decisões de dimensionamento dos elementos não podem ser separadas das decisões operacionais. A aplicação foi composta por duas etapas:

Primeiramente, vazões que obedecem às equações de continuidade nos nós foram assumidas e os diâmetros ótimos foram calculados usando programação linear. Em seguida, a vazão foi modificada usando o método do gradiente e a solução dos diâmetros foi novamente calculada após cada alteração.

Após Alperovits e Shamir (1977), diversos pesquisadores empregaram Programação Linear (PL) com objetivo de avançar na busca de melhores soluções buscando redes mais econômicas (GESSLER, 1982; TUNG, 1985; MORGAN; GOULTER, 1985, LANSEY; MAYS, 1989). Gessler (1982) tentou resolver o problema do alto número de combinações de diâmetros encontrado no GLP, definindo grupos de tubos que teriam o mesmo dimensionamento. Reconheceu-se que a maneira de agrupar tubos pode ser um fator decisivo nos resultados obtidos. Assim, uma boa escolha no conjunto de diâmetros que integrariam um determinado trecho seria o fator chave para obter bons resultados. Esse autor ainda fez referência à solução do conhecido problema da *New York Tunnels* (SCHAAKE; LAI, 1969) e comparou os resultados com outras soluções obtidas usando o método do gradiente.

Em 1997, Silva (1997) utilizou a Programação Não Linear (PNL) como alternativa de algoritmo aplicada no dimensionamento de redes ramificadas, com o intuito de aumentar a confiabilidade do sistema e melhorar a performance computacional. Neste algoritmo, a função objetivo utiliza uma ou mais funções de restrição, que podem ser lineares e/ou não lineares.

No início do século, Gomes e Formiga (2001) apresentaram o PNL2000, formulado e programado com a ferramenta Solver da planilha eletrônica Excel[®] da Microsoft. A metodologia de dimensionamento, que usa o modelo matemático da Programação Não Linear, é dividida em duas etapas. Na primeira, é feito um pré-dimensionamento do sistema, considerando as variáveis a serem determinadas: altura manométrica de cabeceira, diâmetros e vazões dos trechos. Em seguida, com os resultados obtidos, realiza-se uma segunda etapa para corrigir os valores dos diâmetros encontrados, fazendo coincidir as bitolas com as nominais disponíveis no mercado. Esse método aplica-se a redes ramificadas ou malhadas com cota piezométrica de cabeceira fixa ou variável.

Gomes e Bezerra (2005) propuseram uma metodologia baseada no Método Granados (GRANADOS, 1990). Esta metodologia estabelece uma solução inicial composta pelos diâmetros mínimos que são modificados de acordo com a redução da cota piezométrica de cabeceira. Ao final deste processo iterativo, é possível obter um novo custo para o projeto da rede de distribuição. O processo iterativo é concluído quando o custo de intervenção nos trechos ultrapassar o custo energético. No seu processo iterativo, o método se utiliza do conceito Gradiente de Câmbio (GRANADOS, 1990).

Costa, Castro e Araújo (2006) desenvolveram um modelo que associou a programação linear (método SIMPLEX) ao simulador hidráulico Epanet, para minimizar os custos de uma rede de distribuição de água. O algoritmo aumenta o diâmetro dos trechos conectados em nós com déficit de pressão e diminui o diâmetro dos trechos conectados em nós com excesso de pressão. Todos os cálculos hidráulicos são executados no simulador e o algoritmo só finaliza quando não são solicitadas mudanças nos trechos. Posteriormente, Gomes et al. (2009) desenvolveram um algoritmo iterativo para otimização, baseado nos conceitos de gradiente energético e gradiente de pressão. Tal metodologia apresentou bons resultados de dimensionamento; no entanto, não considerava as variáveis de estado (pressão e velocidade da água) durante o processo iterativo.

Embora o uso de computadores modernos possa aumentar a capacidade de processamento para encontrar soluções para problemas de grande porte, ainda assim é necessário usar métodos que selecionem um subconjunto das possibilidades para encontrar a solução ótima. Para alcançar esse objetivo, algoritmos evolutivos têm sido usados com sucesso na otimização de sistemas de distribuição de água. Estes algoritmos são capazes de selecionar e encontrar a melhor solução entre um conjunto de alternativas, sendo mais eficientes do que os métodos de modelagem tradicionais.

Em seguida, será caracterizada a técnica evolutiva, que se destaca em diversas pesquisas relacionadas aos objetos desta tese, bem como certos aspectos relevantes das particularidades que aparecem nesse tipo de abordagem. Além disso, será realizado um estudo aprofundado da arte para um problema específico de otimização de projetos de redes de distribuição de água.

3.1 ALGORITMOS EVOLUTIVOS

Técnicas de otimização evolutivas são um conjunto de algoritmos evolutivos que exploram e melhoram soluções para problemas complexos, usando princípios inspirados na seleção natural. Estes algoritmos são amplamente utilizados para encontrar soluções otimizadas para problemas de programação de transporte, alocação de recursos, otimização de custos, otimização de tempo e outros. Também são usados para encontrar soluções robustas para problemas de tomada de decisão, como seleção de ativos, descobrimento de regras de associação e classificação de padrões (LIU; LI, 2016; GUTIERREZ; VANELLI; BRAVO, 2019; COELLO; ZITZLER, 2021)

Em resumo, os Algoritmos Evolutivos (AEs), subconjunto da classe de algoritmos de Inteligência Artificial (IA), são técnicas evolutivas baseadas na inteligência coletiva proveniente da auto-organização e do comportamento adaptativo da sociedade humana e de certos animais, além de padrões baseados e inspirados em fenômenos naturais e biológicos (ISHIBUCHI; NOJIMA; TANAKA, 2013).

Segundo Yazdi, Yoo e Kim, (2017), os algoritmos evolutivos são considerados algoritmos populacionais por trabalharem com um conjunto de soluções simultaneamente, que evoluem baseados na seleção e variação. A seleção se dá pela escolha das melhores soluções dentro desse conjunto, que competem entre si através de um processo de adaptação estocástico, e baseado no princípio da seleção natural de Darwin. Esse processo de seleção classifica qualitativamente as soluções, permitindo que as melhores possam se multiplicarem na tentativa de melhoria da sua performance. Essa classificação é dada por um valor de aptidão ou *fitness* (nome dado na literatura especializada) e representa a resposta que a solução individual traz ao problema de otimização diante do objetivo almejado. O outro ponto de evolução, a variação, é baseada na capacidade natural das espécies de se modificarem criando novos indivíduos, ou seja, novas soluções independentes das outras já existentes.

Além disso, os AEs, que vêm se destacando no meio profissional e acadêmico por apresentarem bons resultados em diversos problemas de investigação e otimização, são considerados métodos de busca estocástica e podem ser classificados segundo sua técnica de otimização, em algoritmos bioinspirados, metaheurísticos e de programação evolucionária (TONG; LI, 2015).

Em geral, os algoritmos metaheurísticos procuram soluções ótimas para problemas de otimização usando heurísticas. Esses têm a vantagem de serem robustos e flexíveis, pois podem ser adaptados para problemas específicos e também são conhecidos por serem eficientes e terem uma boa taxa de convergência (MARZOUKI; DRISS; GHÉDIRA, 2018).

Alguns algoritmos evolutivos e metaheurísticos combinam as abordagens de evolução e heurística para encontrar soluções ótimas para problemas de otimização. Eles usam técnicas de evolução para gerar soluções iniciais e a heurística para melhorar a qualidade das soluções. Estes algoritmos são conhecidos por serem robustos, flexíveis e terem uma boa taxa de convergência (TONG; LI, 2015; MARZOUKI; DRISS; GHÉDIRA, 2018).

Cada algoritmo evolutivo tem suas próprias vantagens e desvantagens, adaptando-se melhor a certos problemas do que outros (YEN; HE, 2013). Entre os AEs aplicados na otimização de sistemas de distribuição de águas, os mais utilizados e que veem se destacando são: *Genetic Algorithm* (GA), *Shuffled Frog Leaping Algorithm* (SFLA), *Ant Colony*

Optimization (ACO), *Honey-Bee Mating Optimization* (HBMO), *Scatter Search* (SS), *Differential Evolution* (DE) e *Particle Swarm Optimization* (PSO). Esses algoritmos vêm sendo adaptados por diversos pesquisadores que buscam melhorias na exploração e performance computacional (LUO; YI, 2008; JUANG; TUNG; CHIU, 2011; MORA-MELIA et al., 2015; YAZDI; YOO; KIM, 2017; DELICE et al., 2017; ALINAGHIAN et al., 2017; BEZERRA; MACÊDO, 2018; TANYIMBOH; SEYOUM, 2020; ZANGENEHMADAR; MOSELHI; GOLNARAGHI, 2020). Entre essas adaptações, está a hibridização (XU; HE, 2005; LUO; CHEN; LI, 2006; YAP et al., 2011; SEDKI; OUAZAR, 2012; MAHAPATRA; GANGULI; KUMAR, 2015; DU; LIU; ZHANG, 2016; LI; GAO, 2016; SHAH; KHAN, 2016; ALI; KHAN, 2018; BILAL; PANT, 2020; JIANG; LIANG; WANG, 2020; MACÊDO; AZEVEDO; BEZERRA, 2021).

Uma das vantagens desses algoritmos frente aos algoritmos determinísticos é não necessidade de explicitar a função objetivo e as restrições, podendo não haver nenhuma restrição quanto ao ponto de partida dentro do espaço de busca da solução. Além disso, esses algoritmos trabalham adequadamente com variáveis contínuas e discretas ou com uma combinação delas. Entretanto, o principal desafio é o alto custo computacional (MAIER et al., 2014). Para contornar esse problema, propõe-se novas abordagem adaptativas aos algoritmos já existentes, como também, a hibridização, que por sua vez, atua-se em conjunto com dois ou mais algoritmos evolutivos para otimizar e melhorar a performance de um algoritmo. Geralmente, a hibridização se concentra na parte da simulação que exige um grande número de cálculos e procedimentos e que apresenta baixa eficiência ao entregar resultados.

Esse trabalho, busca a melhoria no processo de otimização aplicado ao projeto de redes de distribuição de água, com em ganhos na exploração ou custos computacionais, utilizando um adaptação ao *Particle Swarm Optimization* (PSO) (YAP et al., 2011; SEDKI; OUAZAR, 2012; MAHAPATRA; GANGULI; KUMAR, 2015; DU; LIU; ZHANG, 2016; SHAN; KHAN, 2016; ALI; KHAN, 2018; JIANG, LIANG; WANG, 2020), como um modelo híbrido entre o PSO e *Tabu Search* (TS) (XU; HE, 2005; UTAMIMA et al., 2015; LI; GAO, 2016; PRAJAPATI; JAIN, CHOUHAN, 2020; WEI; HAO, 2021; MARZOUKI; DRISS; GHÉDIRA, 2018; MACÊDO; AZEVEDO; BEZERRA, 2021).

A presente fundamentação discorrerá sobre os Algoritmos Evolutivos (AE), metaheurísticos, utilizados nesta tese, PSO e TS, voltada para a aplicação em projetos de redes de distribuição de água.

3.1.1 *Particle Swarm Optimization (PSO)*

O *Particle Swarm Optimization* (PSO), do inglês, Otimização por Enxame de Partículas, é um algoritmo evolutivo metaheurístico, inspirado, originalmente, na teoria da biologia, que descreve a dinâmica e comportamento “social” de enxames de insetos, como abelhas e formigas, na busca de alimento (KENNEDY; EBERHART, 1995). Essa teoria é aplicada para a solução de problemas de otimização, onde cada inseto é representado por uma partícula, que pode ser considerada como um candidato a solução do problema. Durante a otimização, a partícula é direcionada para as melhores regiões do espaço de busca por meio de uma aproximação racional a “procura” da melhor solução para o problema de otimização, fazendo uso de informações dos demais indivíduos da população inicial, ou seja, o enxame. Assim, o PSO se destaca por ser um método de otimização de certa simplicidade computacional quando comparado com outros métodos, e possui a capacidade de encontrar soluções ótimas para problemas de otimização não lineares (JHA; PRAKASH, 2020).

O PSO vem sendo aplicado com sucesso para problemas de otimização em diversas áreas, como a área de recursos hídricos (WANG; ZHANG; YANG, 2016; SURCO; VECCHI; RAVAGNANI, 2018; ARAUJO, et al., 2019; BEZERRA; MACÊDO, 2018; ALIZADEH et al., 2019; MAZUMDER et al., 2019; KHAN; IQBAL, 2019; FARIAS et al., 2021; MACÊDO; AZEVEDO; BEZERRA, 2021; TORKOMANY et al., 2021). Isso se dá devido à flexibilidade de incorporar problemas discretos, a abstenção do uso de derivadas, a eficiência na exploração do espaço de busca e as facilidades na implementação. Ademais, o PSO tem sido aplicado com sucesso em problemas de otimização em outras áreas (YAP et al., 2011; ALINAGHIAN et al., 2017; CHEN et al., 2020; DAS; JENA, 2020; WANG et al., 2021). Como essa abordagem tem revelado grandes contribuições, alguns autores têm proposto modificações na forma da função de atualização e no movimento das partículas, com o objetivo de aumentar a performance do algoritmo (SEDKI; OUAZAR, 2012; MAHAPATRA; GANGULI; KUMAR, 2015; DU; LIU; ZHANG, 2016; SHAH; KHAN, 2016; ALI; KHAN, 2018; BEZERRA; MACÊDO, 2018; JIANG; LIANG; WANG, 2020; MACÊDO; AZEVEDO; BEZERRA, 2021).

A otimização de redes é um problema de otimização com variáveis discretas, cujo espaço de busca é ditado pela função objetivo e as restrições impostas, e sua complexidade está relacionada ao número de incógnitas e ao número de opções de valores que as incógnitas podem assumir. O sistema cognitivo de movimentação das partículas permite a busca de soluções ótimas de forma mais rápida, contudo, a complexidade desse problema pode exigir

grandes enxames, o que resulta em elevados esforços computacionais, pois um aumento do tamanho do enxame amplifica o esforço necessário para a realização da exploração (ALIZADEH et al., 2019).

Uma partícula se moverá de uma posição anterior para uma nova, sob a influência de um vetor velocidade (v_p), cuja direção e magnitude são determinadas pelos três componentes de movimento: inércia, cognitivo e social. O princípio de inércia é responsável por diversificar soluções, pois está relacionado ao movimento independente dos demais fatores, chamados de fatores sócio-métricos. O componente cognitivo, ou *Personal best position* (*Pbest*), se refere à experiência individual da partícula, armazenando a melhor posição já alcançada por ela. Já o componente social, ou *Global Best Position* (*Gbest*), representa a experiência de todo o enxame de partículas, armazenando a melhor posição alcançada por todas elas. Assim, as partículas são movimentadas de acordo com o vetor velocidade (v_p) (Equação 12), estabelecendo uma conexão conceitual entre os membros da população e permitindo a diversificação das soluções encontradas.

O gerenciamento da magnitude do vetor velocidade (v) poderá variar de acordo com duas constantes positivas chamadas coeficientes de aceleração c_1 e c_2 , como também, duas constantes randômicas variantes entre 0 e 1, r_1 e r_2 . Esses coeficientes foram propostos por Kennedy e Eberhart (1995) com o intuito de gerenciar a influência do *Gbest* ou o *Pbest* no movimento de cada partícula, pois estando o coeficiente c_1 ligado diretamente ao componente “social” (*Gbest*) e c_2 ao componente “cognitivo” ou de memória (*Pbest*). Assim, para se ter um equilíbrio entre esses parâmetros sócio-métricos, adota-se um valor entre 1 e 2 para ambos coeficientes de aceleração c_1 e c_2 , de acordo com a sensibilidade a variação do problema, conforme proposto por Kennedy e Eberhart (1995). Neste trabalho, já que a variação de velocidade é discreta (solução composta pelo conjunto de em diâmetros comerciais), foi adotado o valor de 2 para c_1 e c_2 . A Equação 10 mostra o vetor velocidade e suas componentes.

$$v_{pi}^{t+1} = w.v_{pi}^t + c_1.rand^t(Pbest_i^t - x_i^t) + c_2.rand^t(Gbest_i^t - x_i^t) \quad (12)$$

onde v_{pi}^{t+1} é o vetor de velocidade da partícula i na iteração $t+1$; w é o fator de inercia; v_{pi}^t é o vetor de velocidade da partícula i na iteração anterior t ; c_1 e c_2 são constantes de controle da parcela do vetor acerca do *Pbest* e *Gbest*, respectivamente; $rand$ é um valor aleatório (randômico) entre 0 e 1 gerado na iteração t ; x_i^t é a localização da partícula i na iteração

anterior t . O vetor velocidade atual é somado a posição anterior da partícula (x_i^t), dando origem a nova posição atual da partícula (x_i^{t+1}). Esta operação é expressa na Equação 13.

$$x_i^{t+1} = x_i^t + v_{pi}^{t+1} \quad (13)$$

O fator de inércia (w), proposto por Shi e Eberhart (1998a, 1998b), está relacionado ao componente de inércia presente no vetor velocidade. A escolha do valor aplicado a esse fator influencia diretamente a performance do algoritmo. Segundo Eberhart e Shi (2000), valores elevados de w aumentam a exploração global do algoritmo, com grandes variações de velocidade das partículas, mas com chances de convergência prematura em ótimos locais. Valores baixos, por outro lado, melhoram a exploração local, mas aumentam o custo computacional e não garantem o melhor resultado. Por isso, os autores propuseram que w varie progressivamente ao longo das iterações, reduzindo conforme a Equação 14. Nesse trabalho, será adotado para o fator de inércia os valores inicial e final de 0,9 e 0,4, respectivamente, com base na análise de sensibilidade realizada por Macêdo, Azevedo e Bezerra (2021) em estudo semelhante de dimensionamento ótimo. Estes autores retratam que o limite máximo de 0,9 aumenta a velocidade das partículas para pontos mais favoráveis, aumentando a exploração global e convergência até certo ponto. Então, a redução para o limite de 0,4 favorece a exploração local, com trocas discretas (diâmetros) que auxiliam na busca da solução final.

$$w^t = (w_{inicial} - w_{final}) \left(\frac{N^{total} - t}{N^{total}} \right) + w_{final} \quad (14)$$

onde w^t é o valor do fator de inércia (w) na iteração t ; $w_{inicial}$ e w_{final} são os valores inicial e final adotados para w , respectivamente; t é a iteração corrente; e N^{total} é o número máximo de iterações (NMI).

Os critérios de parada são essenciais para que os algoritmos executem de modo eficaz e eficiente. Estes critérios podem ser definidos de diversas maneiras, dependendo do tipo específico do algoritmo e da finalidade do mesmo e podem ser definidos pelo usuário ou pelo programador, a fim de garantir um número limitado de iterações para evitar um *loop* infinito. (GUTIERREZ; VANELLI; BRAVO, 2019).

Um dos critérios de parada mais utilizados em algoritmos de otimização é o NMI (Número Máximo de Iterações). Esta estratégia consiste em limitar o tempo de execução de um algoritmo, estabelecendo o número máximo de vezes que ele pode iterar antes de parar, pois não consegue mais obter resultados mais satisfatórios. Assim, é possível garantir que os resultados desejados sejam alcançados dentro de um determinado período de tempo (GUTIERREZ; VANELLI; BRAVO, 2019).

Macêdo, Azevedo e Bezerra (2021) sugeriram a Tolerância de Iterações (TI, Equação 15) como critério de parada do algoritmo PSO. Esse critério, dado em porcentagem, evita a estagnação da busca em um resultado específico, sem necessidade de executar todas as simulações até que o NMI atue. De acordo com esses autores, após as partículas convergirem a um ótimo local ou global, torna-se mais difícil realizar atualizações promissoras de busca, aumentando assim o custo computacional sem efetividade de exploração. Desta forma, esse fator fará com que a simulação seja encerrada após a relação entre o número de iterações com repetição do resultado e o número de iterações que ainda ocorrerão segundo o valor de NMI, exceder especifica porcentagem definida ao iniciar o algoritmo. Este trabalho, poderá adotar uma TI de 30%, como também foi sugerido pelos autores.

$$\left(\frac{N^{rep}}{N^{rest}} \right) * 100 \leq TI(\%) \quad (15)$$

onde N^{rep} é o número de vezes que a solução ótima se repete; N^{rest} é o número de iterações que restam ocorrer até atingir o critério NMI.

No algoritmo PSO, como um algoritmo metaheurístico, um conjunto inicial de partículas é gerado de maneira aleatória e espalhado pelo espaço de busca segundo a Equação 16.

$$x_i^I \leq x_i \leq x_i^S \quad i=1, \dots, n_p \quad (16)$$

onde x_i^I e x_i^S contém os limites inferior e superior das posições das partículas, respectivamente e n é o número total de partículas do enxame.

Com isso, vale destacar que o PSO, como outros algoritmos metaheurísticos, não garante que uma solução ótima global seja encontrada, e essa variação pode ser resultado da própria inicialização aleatória das partículas no espaço de busca (SILVA; FERREIRA; STEINER, 2019).

O pseudocódigo básico do algoritmo PSO pode ser descrito brevemente utilizando os passos observados no Pseudocódigo abaixo.

Pseudocódigo do algoritmo PSO

```

1 Inicializar o enxame ();
2 Para cada iteração faça
3   | Para cada partícula faça
4   |   | Para cada dimensão faça
5   |   |   | Atualizar velocidade e posição ();
6   |   | Fim
7   |   | Calcular fitness;
8   | Fim
9   | Atualizar o líder;
10  | Se o fitness atual for menor que o melhor fitness individual então
11  |   | Atualizar melhor fitness individual para o fitness atual;
12  | Fim
13  | Se o fitness atual for menor que o melhor fitness da vizinhança então
14  |   | Atualizar melhor fitness da vizinhança para o fitness atual;
15  | Fim
16  | Iteração ++;
18  | Se o número de iterações exceder o limite então
19  |   Parar o algoritmo;
20 Fim

```

3.1.2 *Tabu Search* (TS)

O *Tabu Search* (TS), cuja tradução do inglês é *Busca Tabu*, é um algoritmo de otimização que vem ganhando espaço na comunidade científica por ser um método adaptativo que melhora a exploração local do espaço de busca, sobretudo em problemas sensíveis às pequenas variações. Durante o processo de exploração, o algoritmo vai "movendo-se" de uma solução para outra a cada iteração, evitando movimentos já executados e garantindo assim uma maior diversificação das soluções em busca de um ótimo próximo ao ótimo global. Além disso, esse processo contribui para a redução do esforço computacional necessário (GLOVER, 1989, 1990).

A palavra *Tabu*, originária do idioma Tongan, se refere a objetos sagrados que não podiam ser manipulados pelos nativos das ilhas Tonga, localizadas na Polinésia (GLOVER 1989, 1990). No dicionário de Língua Portuguesa, ela significa ações ou objetos proibidos. Desse modo, o algoritmo proposto por Glover (1989, 1990) em 1989 tem sido amplamente adotado entre os algoritmos de otimização, por impedir a realização de movimentos de busca repetidos através da criação de uma lista de restrições, a Lista *Tabu*, com a finalidade de melhorar a busca local diminuindo o tempo de processamento.

- **Lista *Tabu* (LT)**

A Lista *Tabu* é uma estrutura de memória que armazena todos os movimentos realizados durante a busca do ótimo global. O objetivo desta lista é apresentar ao algoritmo uma série de movimentos já realizados, guiando-o para novas vizinhanças no espaço de busca e evitando que ela fique estagnada em pontos de ótimos locais. Dessa forma, a Lista *Tabu* reduz a tendência do algoritmo de otimização de voltar a pontos anteriores, que é resultado do processo de busca que possui certa aleatoriedade. Porém, quanto maior for a Lista *Tabu*, maior será a quantidade de memória necessária para armazenar os movimentos (GLOVER 1989, 1990).

Para contornar esse problema, a Lista *Tabu* também tem uma estratégia de "esquecimento" que consiste em remover os movimentos mais antigos da lista, de modo que o armazenamento de memória necessário seja reduzido. Assim, o algoritmo é capaz de se mover para novas vizinhanças, sem perder a capacidade de evitar soluções ótimas locais (GLOVER, 1989, 1990).

- **Critério de Aspiração (CA)**

O Critério de Aspiração (CA) é uma técnica usada no TS, que permite que as soluções tenham mais liberdade em relação à Lista *Tabu*, muitas vezes bastante restritiva. Para isso, o Critério de Aspiração anula o status da Lista *Tabu*, permitindo que a solução possa explorar pontos já visitados, promovendo sua diversificação. Assim, ele permite que o algoritmo aceite soluções de baixa qualidade em situações que podem ocorrer um "falso mínimo" (ou falso ótimo), o que significa que o algoritmo estava seguindo o caminho errado e não chegaria ao verdadeiro ótimo (SÖRENSEN et al., 2009).

O critério de aspiração geralmente é aplicado quando uma solução atinge o limite de passos do algoritmo TS. Ao invés de descartar uma solução que está próxima da ótima, o critério de aspiração permite que o algoritmo continue a busca e aceite a solução como ótima. Esse tipo de direcionamento da busca pode conduzir a locais ainda não explorados, onde pequenas alterações podem ser fundamentais para a obtenção do ótimo Global. A aplicação desse critério dependerá do tipo de problema a ser otimizado e sua aplicação é mais efetiva quando se tem uma grande Lista *Tabu* (SÖRENSEN et al., 2009).

- **Estrutura de Vizinhança (EV)**

A movimentação no espaço de busca realizado pelo algoritmo pode ser restritiva, devido a alguma regra ou informação que a solução deverá conter, assim haverá uma diminuição das chances de sua convergência prematura em ótimo local. Essas restrições de movimento constituem o espaço de solução possível que pode ser alcançado em cada iteração, e este conjunto de soluções possíveis é denominado de Estrutura de Vizinhança. Portanto, além da solução presente na Lista *Tabu*, o próximo movimento estará contido na Estrutura de Vizinhança, que estará sujeita a novas restrições impostas pelo problema (SÖRENSEN et al., 2009).

Em projeto de dimensionamento de Redes de Distribuição de Água, a estrutura de vizinhança pode ser o conjunto solução factível, ou seja, somente as soluções que respeitem as restrições do problema, como o nível de pressão mínima nos nós de demanda da rede.

- **Crítérios de Parada**

Para que o algoritmo não entre em *Loop* Infinito, alguns critérios de parada podem ser utilizados, tais como: o Número Máximo de Iterações (NMI); Tempo Limite de Execução (TLE); ou o próprio Tolerância de Interações (TI) proposto por Macêdo, Azevedo e Bezerra (2021). Quando a solução da função objetivo é conhecida, sua obtenção pode ser utilizada como critério de parada,

O pseudocódigo básico do algoritmo TS pode ser descrito brevemente utilizando os passos observados abaixo.

Pseudocódigo do algoritmo *Tabu Search*

```

1 Inicializar o enxame ();
2 Para cada iteração faça
3 | Para cada solução candidata do espaço de busca faça
4 | | Calcular o fitness;
5 | | Se o fitness for menor que o melhor fitness então
6 | | | Se a solução não estiver na lista de tabu então
7 | | | Atualizar o melhor fitness;
8 | | Fim
9 | Fim
10 | Atualizar a lista de tabu;
11 | Iteração ++;
12 | Se o número de iterações exceder o limite então
13 | Parar o algoritmo;
14 Fim

```

3.1.3 Algoritmos híbridos

Apesar de muitos algoritmos serem eficazes na busca por soluções, cada um com sua metodologia e particularidades, as novas abordagens híbridas estão sendo cada vez mais aplicadas com ênfase em melhorias nos procedimentos numéricos e na redução dos custos computacionais. Os algoritmos híbridos são formados a partir de dois ou mais algoritmos que, mutuamente, ofereçam benefícios em todas ou alguma parte do processo de otimização, e que possam ser implementados como um só algoritmo (BILAL; PANT, 2020).

Geralmente, existe um algoritmo base, no qual o processo geral de otimização é realizado em sua metodologia, mas algumas partes desse processo são substituídas ou incrementadas com partes de outro algoritmo que possa trazer maiores benefícios à otimização em seus diversos aspectos (MACÊDO; AZEVEDO; BEZERRA, 2021).

Vale ressaltar, que atualmente há inúmeros algoritmos híbridos na literatura (XU; HE, 2005; LUO; CHEN; LI, 2006; YAP et al., 2011; SEDKI; OUAZAR, 2012; MAHAPATRA; GANGULI; KUMAR, 2015; ZOU; LIU; ZHANG, 2016; LI; GAO, 2016; SHAH; KHAN, 2016; ALI; KHAN, 2018; BILAL; PANT, 2020; JIANG, LIANG; WANG, 2020; MACÊDO; AZEVEDO; BEZERRA, 2021). Como exemplo de melhoria adquirida com aplicação híbrida

de único objetivo, tem-se o algoritmo genético híbrido (HGA), proposto por Rajeev et al. (1998). Este algoritmo foi um dos primeiros híbridos feitos, e combina um algoritmo genético com um algoritmo local, buscando melhorar o desempenho global do algoritmo genético. Por meio da aplicação deste algoritmo híbrido, foi possível diminuir o tempo de execução do algoritmo original e, conseqüentemente, melhorar os resultados obtidos.

Em 2005, Xu e He (2005), propuseram o Algoritmo Híbrido de Busca *Tabu*, ou *Tabu Search Hybrid Algorithm* (TSHA). Este combina o conceito de Busca *Tabu* com o Algoritmo Genético, permitindo uma melhor exploração do espaço de soluções, resultando em soluções mais eficientes e ótimas. Uma vez que o TSHA explora o espaço de soluções de forma mais eficaz, ele pode encontrar melhores soluções para problemas de otimização de forma mais rápida do que os algoritmos genéticos convencionais. Além disso, o uso desse algoritmo pode resultar em soluções mais robustas e confiáveis, uma vez que ele promove a exploração eficiente do espaço de soluções.

Luo, Chen e Li (2006) propuseram um Algoritmo Híbrido com combinação do *Genetic Algorithm* (GA) com o *Ant Colony Optimization* (ACO), permitindo uma melhor exploração do espaço de soluções. Ao usar o ACO, o tempo total de execução do algoritmo genético é reduzido, resultando em soluções mais eficientes e ótimas. Além de melhorar o desempenho do AG, o algoritmo híbrido também é capaz de gerar soluções mais diversificadas. Isto significa que é possível encontrar soluções ótimas usando menos recursos computacionais, pois o algoritmo é capaz de explorar o espaço de soluções de forma mais eficiente. Além disso, o ACO é capaz de gerar soluções mais robustas, pois ele é capaz de explorar uma ampla variedade de soluções.

Devido a facilidade de implementação e resultados apresentado, muitos algoritmos utilizam o PSO em propostas híbridas. Um deles é o Algoritmo Híbrido de *Swarm Optimization* (HSO), proposto por Castro e Silva (2008). Este algoritmo combina *Particle Swarm Optimization* com o *Genetic Algorithm*, permitindo um melhor aproveitamento de recursos computacionais. Além de gerar soluções ótimas mais rapidamente, o Algoritmo Híbrido (HSO) também é capaz de gerar soluções um maior número de soluções. Este aumento dá ao algoritmo um maior leque de soluções encontradas, pois é possível explorar um maior número de soluções ótimas. Além disso, usar o HSO é mais eficiente do que usar os algoritmos genéticos convencionais, pois ele usa menos recursos computacionais para encontrar soluções ótimas.

Outro exemplo de algoritmo híbrido que faz uso do PSO em sua estrutura, entre muitos é o *Weighted Hybrid Swarm Optimization*, do inglês Otimização por enxame híbrido

ponderado (WHSO), proposto por Shah e Khan (2016). Este algoritmo combina *Particle Swarm Optimization* com o *Genetic Algorithm* de forma ponderada, buscando uma exploração eficiente do espaço de soluções. O WHSO é capaz de gerar soluções de alta qualidade, pois ele é capaz de explorar uma ampla variedade de soluções. Além disso, o WHSO é capaz de gerar soluções mais rapidamente do que os algoritmos genéticos adaptados como o HSO (CASTRO; SILVA, 2008), permitindo assim uma melhor utilização de recursos computacionais.

Em 2017, Mohamad e Nezamabadi-Pour (2017) propuseram o Algoritmo Híbrido de *Dynamic Swarm Optimization* (DHSO). Este algoritmo mantém a combinação proposta por Castro e Silva (2008), porém com modificações em sua pesquisa, que passa a ser dinâmica, permitindo uma melhor exploração global do espaço de soluções, através da inserção de parâmetros como a mutação e recombinação. Ou seja, o DHSO é capaz de lidar com ambientes dinâmicos que necessitam de grandes modificações, pois ele é capaz de se adaptar às mudanças de forma mais rápida.

O Algoritmo Híbrido de *Cauchy Swarm Optimization* (CSO), foi proposto Ali e Khan (2018). *Cauchy* é a palavra francesa para referir-se à Teoria da Otimização Estocástica de *Cauchy*, com isso, esse algoritmo híbrido combina o *Particle Swarm Optimization* com o algoritmo de busca local baseado na teoria da otimização estocástica de *Cauchy*. Nesse algoritmo, os valores de *fitness* são atualizados de acordo com as regras de movimentação, que por sua vez são determinadas por uma função de atualização baseada no algoritmo de otimização estocástica de *Cauchy*. Esta função é responsável por atualizar os valores *fitness* para cada partícula de acordo com a atração gravitacional de todas as outras partículas na população. Segundo os autores, o CSO ser capaz de explorar uma ampla variedade de soluções. Isto significa que é possível encontrar soluções ótimas usando menos recursos computacionais, pois o algoritmo é capaz de explorar o espaço de soluções de forma mais eficiente.

Um dos mais recentes é o Algoritmo Híbrido de Otimização por Enxame de Amortecimento (DSO), este algoritmo foi proposto por Jiang, Liang e Zhang (2020) e combina o *Particle Swarm Optimization* com o *Damping Optimizer*, do inglês Otimizador amortecido. No DSO as partículas são inicializadas usando uma distribuição uniforme, no cálculo das velocidades das partículas é usando o PSO e aplicado o amortecimento usando o *Damping*.

O DSO vem como alternativa redução de tempo de execução do algoritmo PSO com a obtenção de resultados mais eficientes.

3.1.4 Algoritmos evolutivos aplicados a projeto de redes de distribuição de água

Diversos são os métodos de dimensionamento das tubulações em redes de distribuição de água. Os tradicionais são baseados no balanceamento hidráulico da rede, visando atender às condições impostas pelas equações da conservação de massa nos nós e conservação de energia nos anéis. No entanto, estes métodos não abordam a minimização dos custos envolvidos na implantação e operação destas redes. Dentre os métodos tradicionais, o método de Hardy-Cross ainda é amplamente difundido para o dimensionamento de redes hidráulicas.

Porém, com o desenvolvimento das cidades e o crescente crescimento populacional, houve uma grande concentração de edificações nos centros urbanos e a necessidade de verticalização urbana. Como resultado, as redes de distribuição de água têm se tornado mais complexas e sofisticadas, exigindo diversos aspectos a serem considerados na sua concepção, além das exigências impostas por sua operação (LEMOS; BARBOSA; LOPES, 2020).

A relevância deste problema torna-se ainda maior, pois passa a se desejar projetos que apresentem o menor custo econômico possível e que atendam aos requisitos necessários para uma operação adequada. Posto isso, um evento realizado em Nova York, em 1969, contribuiu significativamente para o desenvolvimento de técnicas de otimização voltadas a projeto de redes de distribuição de água. Chamado de “*The Battle of the Networks Models*”, este consistia na apresentação de soluções para uma rede hipotética que deveria ser ampliada e economicamente dimensionada (SCHAAKE; LAI, 1969; WALSKI, 1987). Este problema, conhecido como *New York Tunnels Problem*, ainda é usado como referência para avaliar a eficácia e eficiência de diferentes métodos de otimização de sistemas de distribuição de água. No entanto, com a problemática já bastante difundida no meio acadêmico e aumento da capacidade de processamento atual dos computadores, diversas outras redes já foram propostas, como a *Balerna network* (RECA; MARTÍNEZ, 2006, 2008; BI; DANDY; MAIER, 2015), com vistas na complexidade resolutive para esse tipo de aplicação.

Com o passar dos anos, novas técnicas de evolutivas têm sido desenvolvidas para substituir as técnicas convencionais de projeto de redes de distribuição de água, como a enumeração exaustiva. Esta técnica, consiste na simulação de todas as combinações possíveis para os diâmetros comerciais de tubos, com o objetivo de se identificar a solução ideal. No entanto, ela apresenta como desvantagem a grande quantidade de cálculos necessários, pois mesmo em problemas com poucos elementos, há um número considerável de soluções. Com isso, a busca por algoritmos evolutivos que apresentem resultados mais satisfatórios se tornou cada vez maior. Alguns exemplos de algoritmos evolutivos que são amplamente utilizados

para projeto de redes de distribuição de água incluem *Genetic Algorithm* (HOLLAND, 1975), *Particle Swarm Optimization* (KENNEDY; EBERHART, 1995), *Simulated Annealing* (SOUSA; CUNHA, 1998), *Shuffled Frog Leaping* (EUSUFF; LANSEY, 2003), *Ant Colony Optimization* (MONTALVO et al., 2008), entre outros. Esses algoritmos usam técnicas heurísticas para encontrar soluções satisfatórias, mesmo em problemas complexos. Além disso, permitem que os usuários explorem várias soluções ao mesmo tempo, o que permite identificar rapidamente qual o valor ótimo.

O *Genetic Algorithm* (GA), em português Algoritmo Genético, é um algoritmo evolutivo amplamente utilizado para resolver problemas de redes de abastecimento de água. Desde que, Simpson, Dandy e Murphy (1994) aplicaram esta técnica ao projeto de redes hidráulicas e obtiveram resultados satisfatórios, várias pesquisas foram realizadas para aperfeiçoar essa técnica, como a aplicação de outras técnicas evolutivas, fim de aumentar a precisão e desempenho computacional na busca do dimensionamento ótimo (FREY, DANDY, MURPHY, 1995; DANDY; SIMPSON; MURPHY, 1996; KADU; GUPTA; BHAVE, 2008; MOHAMAD; NEZAMABADI-POUR, 2017; TANYIMBOH; SEYOUM, 2020; ZANGENEHMADAR; MOSELHI; GOLNARAGHI, 2020).

Sousa e Cunha (1998) aplicou a técnica evolutiva, *Simulated Annealing* (SA), também conhecido como Recozimento Simulado, na otimização das redes *Hanoi Network* (FUJIWARA; KHANG, 1990) e *The New York Tunnels Problem* (SCHAAKE; LAI, 1969). Essas redes foram usadas como casos de estudo pelos autores, de modo que os resultados puderam ser comparados a outros métodos para solucionar o mesmo problema. Estas duas redes são problemas clássicos usados no projeto ideal e aplicados em diversos trabalhos, porém com a tecnologia novas redes estão sendo apresentadas. Em Cunha e Sousa (1999), o método foi aplicado à rede tradicional *Two loop* de Alperovits e Shamir (1977).

Eusuff e Lansey (2003) otimizam o projeto de redes de distribuição de água a partir do uso de um algoritmo evolutivo denominado *Shuffled Frog Leaping*. Este método foi desenhado para trabalhar com variáveis discretas e possui algumas semelhanças com o *Particle Swarm Optimization* (KENNEDY; EBERHART, 1995) e a *Shuffled Complex Evolution*, em português, Evolução Complexa Embaralhada (DUAN; SOROOSHIAN; GUPTA, 1992). Para a busca de soluções, o simulador hidráulico Epanet foi empregado para realizar a análise de soluções potenciais. O problema de otimização foi desenvolvido sem considerar elementos relacionados à confiabilidade das redes. Apenas o dimensionamento dos tubos foi considerado e o projeto de outros elementos do sistema de distribuição não foi abordado. Várias comparações foram realizadas com os resultados obtidos em outras

pesquisas, permitindo inferir que o algoritmo apresentou bons resultados na busca de soluções.

Kadu, Gupta e Bhave (2008) usaram um *Genetic Algorithm* modificado e apresentaram uma maneira de o fator de penalidade evoluir dentro do esquema do algoritmo. Os pesquisadores mostraram as vantagens de usar um fator de penalidade adaptativo em vez de um fixo. Os valores muito baixos do fator de penalidade levaram a pesquisa ainda mais às regiões inviáveis do espaço da solução, enquanto o uso de altos valores do fator de penalidade restringiu a busca demais ao espaço viável, limitando a possibilidade de encontrar soluções próximas da fronteira com a região não viável.

Montalvo et al. (2008) propuseram aplicar o algoritmo *Ant Colony Optimization* (ACO), do inglês, Otimização por Colônia de Formigas, para otimizar o desempenho da distribuição de água. O algoritmo é baseado em um modelo de colônia de formigas, onde as formigas são usadas para descobrir o melhor caminho possível para distribuir a água. O algoritmo usa métodos heurísticos para achar caminhos ótimos para a distribuição de água. O algoritmo ACO também leva em consideração as restrições técnicas e ambientais que podem exigir a otimização da distribuição de água. Além disso, o algoritmo também leva em conta o custo para manter a distribuição da água, permitindo que os usuários e os gestores obtenham o máximo de benefícios possível.

Reca et al. (2008) apresentaram uma comparação entre quatro algoritmos evolutivos na otimização de redes de distribuição de água: *Genetic Algorithm*, *Simulated Annealing*, híbrido do *Iterated Local Search* com *Simulated Annealing* e, finalmente, um híbrido de *Simulated Annealing* e *Tabu Search*. Somente o custo do investimento inicial em tubos e o cumprimento das restrições de projeto foram considerados na pesquisa, sem empregar nenhuma medida de confiabilidade das soluções. Dois exemplos de redes foram usados a *Hanoi Network* (FUJIWARA; KHANG, 1990) e uma recente rede *Balerma Network*, ambas executadas dez vezes. Para cada algoritmo, foi estabelecido um número fixo de iterações. Os resultados mostraram que, para a *Hanoi Network*, o *Genetic Algorithm* obteve a melhor solução, mas a média das soluções foi pior. Para a *Balerma Network*, a melhor solução foi obtida pela combinação de *Simulated Annealing* e *Tabu Search*.

Bragalli et al. (2015) apresentaram uma nova abordagem para aumentar a eficiência dos métodos heurísticos aplicados ao projeto ótimo de sistemas de distribuição de água. Esta abordagem se baseia na redução do espaço de pesquisa, limitando os diâmetros que podem ser usados para cada canal de rede. Assim, dois cenários distintos de distribuição de vazão são analisados com restrições de velocidade nos tubos: o primeiro é a distribuição da vazão mais

uniforme e o segundo é a rede com a máxima vazão. Estas distribuições são calculadas através de um problema de programação quadrática, muito robusto e eficiente. A metodologia foi acoplada a um *Genetic Algorithm*, com um esquema de codificação de números inteiros e um número variável de alelos. A abordagem foi aplicada a várias redes de referência e seu desempenho foi comparado ao de uma formulação clássica do mesmo algoritmo. Os resultados obtidos demonstraram que a nova abordagem é capaz de melhorar significativamente a eficiência dos métodos heurísticos aplicados ao projeto ótimo de sistemas de distribuição de água. Além disso, a redução significativa do número de iterações do algoritmo torna este método inovador uma ferramenta poderosa, que pode oferecer soluções de qualidade de modo rápido e preciso.

Choi et al. (2017) propuseram três métodos para melhorar a qualidade das soluções em problemas de otimização de rede de distribuição de água: *Warm Initial Solution Methods*, *Postoptimization Method*, e *Guided-Search Method*, em português, Métodos Iniciais de Solução Quente, Método de Pós-otimização, e Métodos de Solução Inicial Guiada, respectivamente. Estes métodos foram validados através de um estudo da *Hanoi Network*, *Two-Loop Network*, *Balerma Network* e *P-city Network*. Assim, com essas redes, foi considerando uma quantidade razoável de variáveis de decisão, onde foi identificado o melhor método em termos diversidade das soluções, quando comparado com algoritmos de otimização amplamente usados na área.

Uma análise comparativa entre algoritmos evolutivos foi realizada por Zou et al. (2019). O estudo comparou quatro algoritmos evolutivos na otimização de redes de distribuição de água, incluindo um o *Genetic Algorithm*, um algoritmo híbrido, um algoritmo de busca local e um algoritmo *Ant Colony Optimization*. Os resultados mostraram que o algoritmo híbrido foi o mais eficaz, seguido pelo *Genetic Algorithm*, algoritmo *Ant Colony Optimization* e algoritmo de busca local. Os algoritmos foram testados em duas redes de distribuição de água diferentes, e o custo do investimento inicial em tubos e o comprimento das restrições foram considerados. Nenhuma medida da confiabilidade das soluções foi empregada.

Zheng et al. (2020), compararam seis algoritmos evolutivos na otimização de projetos de redes de distribuição de água. Os algoritmos incluíam dois algoritmos genéticos, dois algoritmos híbridos, um algoritmo de busca local e uma heurística nebulosa. Os resultados mostraram que os algoritmos híbridos foram os mais eficazes, seguidos pelos *Genetic Algorithm*, algoritmo de busca local e *Fuzzy heuristic*. Os algoritmos foram testados em duas

redes de distribuição de água diferentes, e o custo do investimento inicial em tubos e o cumprimento das restrições de projeto foram considerados.

As soluções propostas para a otimização de sistemas de distribuição de água ainda estão sendo desenvolvidas, pois não existe uma metodologia completamente aceita pela comunidade científica e técnicos do setor. Embora existam diferentes abordagens, elas costumam compartilhar alguns pontos em comum, como o uso computacional para a obtenção de soluções por meio de métodos iterativos, que se subdividem em diversos estágios. O trabalho desenvolvido nesta área baseou-se nos algoritmos conhecidos como *Particle Swarm Optimization* (PSO), desenvolvido por Kennedy e Eberhart (1995), e *Tabu Search*, desenvolvido por Glover (1988). Com ênfase no PSO, que é o algoritmo evolutivo de destaque neste trabalho, ele utiliza a inteligência enxame para a otimização de uma função objetivo específica. Esta abordagem oferece grande flexibilidade para avaliar e quantificar economicamente os modelos de sistemas de distribuição de água.

4 METODOLOGIA


O algoritmo *Particle Swarm Optimization* (PSO) utilizado neste trabalho para a adaptação proposta pelos modelos desenvolvidos, bem como para a análise avaliativa e comparativa, foi apresentado inicialmente por Kennedy e Eberhart (1995). Nesta tese, esse algoritmo foi denominado como PSO convencional e foi ajustado de acordo com a questão abordada, que trata de variáveis discretas (opções de diâmetros de tubulações a serem otimizadas), ao invés da análise contínua presente na proposta original. Para a utilização da técnica de otimização *Tabu Search* (TS), foi adotado o modelo sugerido por Glover (1989, 1990).

Os modelos *Particle Swarm Optimization* com ciclos de reinicialização e o algoritmo híbrido foram implementados no software de cálculo científico e programação, Matlab (*MATrix LABoratory*). Ambos visaram a minimização dos custos do projeto e o aperfeiçoamento da performance computacional, por meio do aumento exploratório das partículas iniciadas aleatoriamente no espaço de busca. O Matlab se comunica com o simulador hidráulico Epanet¹ (versão 2.00.12) para determinar os parâmetros hidráulicos necessários no processo de otimização das redes.

O Matlab é um *software* versátil que conta com uma linguagem de programação própria e possui a capacidade de vincular bibliotecas externas. A associação desse *software* com o simulador hidráulico Epanet é realizada por meio do compartilhamento de um arquivo de biblioteca de vínculo dinâmico (.dll), contendo uma coleção de funções. O Matlab recebe como entrada um arquivo do Epanet do tipo “inp”, que descreve a rede, e através dessa biblioteca é executado, obtendo-se os dados necessários para a análise e o cálculo da função objetivo. Em virtude da versatilidade do Matlab, pode-se realizar operações matemáticas envolvendo matrizes e computar os dados necessários para o cálculo das variáveis hidráulicas das redes de distribuição de água. Esse processo é repetido todas as vezes que um conjunto de diâmetros é avaliado, ou seja, a cada avaliação de um conjunto solução, representada por uma partícula, em uma iteração durante o processo de otimização. Por isso, quanto maior for o número de partículas adotado no processo de otimização, maior será o custo computacional envolvido nesse processo. A Figura 3 mostra o processo de iteração entre os *softwares*.

¹ O Epanet é um simulador hidráulico de código livre desenvolvido pela Agência de Proteção Ambiental dos Estados Unidos (EPA). Esse software permite executar simulações estáticas e dinâmicas do comportamento hidráulico e de qualidade em sistemas de distribuição de água (ROSSMAN, 1994, 2000, 2020).

Figura 3 – Processo iterativo entre o simulador hidráulico Epanet e o Matlab



Fonte: O Autor (2023).

Os modelos propostos e o PSO convencional foram aplicados em três redes de distribuição de água referenciadas na literatura, com o objetivo de analisar e comparar os resultados obtidos, bem como em um caso real complexo adaptado à problemática de uma cidade do interior de Pernambuco, Brasil.

A primeira rede estudada é o sistema complexo de irrigação de Balerma (*Balerma Irrigation Network* ou *Balerma Network*), localizado na província de Almería, na Andalucia, Espanha (RECA; MARTÍNEZ, 2006, 2008). A complexidade da *Balerma Network* vai além do número de trechos de tubulação e do número de opções de diâmetros comerciais para o dimensionamento, mas sim, do seu traçado, exigências de demandas e outras particularidades, o que a torna um problema desafiador para a análise de algoritmos de dimensionamento ótimo (MACÊDO; AZEVEDO; BEZERRA, 2021). Esta rede foi selecionada como base inicial para o estudo e análise da sensibilidade dos parâmetros de entrada dos modelos propostos e do algoritmo PSO (PSO convencional) para obter uma configuração padrão (*default*) para todas as redes estudadas.

A segunda rede, a *Hanoi Network*, proposta por Fujiwara e Khang (1990), é amplamente conhecida na comunidade acadêmica como uma opção viável para resolver problemas de otimização de forma eficaz e rápida. Ela possui uma complexidade inferior a *Balerma Network*, porém tem sido usada como referência para métodos de análise de redes menores, bem como para estudar problemas de otimização em outras áreas da computação evolutiva. Nesta tese, essa rede serviu para analisar o comportamento dos modelos frente a problemas de baixa complexidade, além de servir como exemplo avaliativo da eficácia dos modelos, uma vez que, seu valor ótimo global é conhecido.

A *Rural Network* é terceira rede proposta, uma rede de irrigação complexa, projetada para facilitar o aproveitamento de água em diferentes regiões. Ela foi inicialmente estudada

por Marchi et al. (2014) e se destaca pelo seu traçado complexo, com inúmeras malhas e conexões, além de um elevado número de opções de diâmetros para seu dimensionamento. Tornando-a um exemplo de aplicação desafiador para os algoritmos de otimização.

Os resultados das análises (dimensionamentos ótimos) das redes literárias foram comparados com os obtidos por outros métodos descritos, também, na literatura. Além do custo mínimo, avaliaram-se outros fatores, como a busca por soluções satisfatórias com menor custo computacional. No Epanet, a equação de perda de carga pode ser dada pela equação de Darcy-Weisbach ou Hazen-Williams ou Chezy-Manning. A escolha de qual equação será utilizada dependerá das informações disponíveis em cada problema avaliado, para possibilitar a comparação dos resultados a partir dos dados de entrada das redes.

A última rede estudada é a rede de distribuição de água da cidade de Panelas (Rede Panelas), situada no interior do estado de Pernambuco, Brasil. Esta rede possui um grande número de trechos de tubulação, um traçado complexo e diversas demandas acentuadas em específicos nós. Além disso, conta com uma grande variedade de diâmetros diferentes para serem usados no dimensionamento da rede. Estas características tornam a Rede Panelas um exemplo avaliativo de otimização e uma excelente oportunidade de estudo para a comunidade científica.

Todas as simulações foram executadas em um notebook com processador Intel i7 8550U @ 1,80GHz, 1,99GHz e 8 GB de memória RAM.

4.1 FORMULAÇÃO NUMÉRICA

Ainda hoje, quando se trata de um projeto de dimensionamento de redes de distribuição de água, o custo de implantação da rede tem sido adotado como função objetivo a ser minimizada, principalmente devido às limitações financeiras existentes. Para isso, os algoritmos de otimização têm buscado encontrar uma combinação de variáveis (tamanhos de diâmetros) que possibilitem o menor custo possível para essa função (ALPEROVITS; SHAMIR, 1977; CHU et al., 2008; EL-GHANDOUR; ELBELTAGI, 2018; FALLAH et al., 2019).

Segue a quantificação desse custo expresso na Equação 17 (Equação 2).

$$f(D_1, D_2, \dots, D_m) = \sum_{i=1}^m C_t (D_i, L_i) \quad (17)$$

onde $f(D)$ é a função objetivo ou fitness que varia em função dos diâmetros dos trechos de tubulação da rede; m é o número total de trechos de tubulação na rede; $C_i(D_i, L_i)$ é o custo do tubo i de diâmetro interno D e comprimento L .

O grande desafio dessa problemática é encontrar uma solução que represente o menor custo possível, atendendo às restrições hidráulicas da rede e suprindo as demandas requeridas nos nós, ao mesmo tempo em que satisfaz a pressão mínima admissível da rede. A variável de decisão (vazões nos trechos e pressões nos nós) muda a cada alteração feita nos diâmetros dos tubos da rede.

A função objetivo, em um projeto de rede de distribuição de água, foi representada matematicamente como o custo total de implantação, que é uma função dos diâmetros e comprimentos dos tubos. Para que as restrições sejam atendidas, foram inseridas na forma de penalidade nessa função. Por exemplo, caso haja violação do requisito de pressão mínima nos nós, um aumento a esse custo será somado. A função objetivo de otimização a ser minimizada é descrita na Equação 18.

$$f(D_1, D_2, \dots, D_m) + Penalidades = \sum_{i=1}^m C(D_i, L_i) + (P_{min j} - P_j) \quad (18)$$

onde $P_{min j}$ é a pressão mínima no nó j ; e P_j é a pressão no nó j . As penalidades só são contabilizadas quando algum nó apresenta pressão inferior a mínima requerida e podem, quando necessário, serem multiplicadas por algum fator majorador (Fator de penalização).

A fim de considerar factível uma solução, foi necessário que o fator de penalidade seja igual a zero, indicando que ela satisfaz o requisito de pressão mínima em todos os nós da rede. Caso contrário, essa solução não será considerada válida (infactível). É destacável que o custo computacional investido na otimização depende da troca de dados entre o simulador hidráulico Epanet e o *software* Matlab, que se intensifica com o tamanho da rede estudada e o número de partículas avaliadas em cada iteração. Assim, reduzindo esse intercâmbio, o custo computacional pode ser diminuído, o que aumenta o desempenho da otimização.

Para comparar os resultados, todas as informações originais dos estudos de caso foram preservadas e disponibilizadas no simulador hidráulico.

4.2 ALGORITMO HÍBRIDO (H-PSOTS)

A cada iteração no processo de otimização do *Particle Swarm Optimization* (PSO), inúmeras partículas se movimentam no espaço de busca direcionadas pelo seu vetor de velocidade. Esse vetor leva em consideração fatores como a inércia, o melhor resultado individual e o melhor resultado coletivo. Durante esse movimento, as partículas podem retomar posições já visitadas anteriormente, assim como também podem passar por posições já alcançadas por outras partículas durante o processo de busca pelo ótimo global.

Todas as partículas do enxame, mesmo aquelas em posições já visitadas, são submetidas ao mesmo processo de cálculo, seja no simulador hidráulico ou avaliadas segundo a função objetivo (*fitness*). Logo, quanto maior o número de partículas no processo de otimização, maior o tempo de processamento e, conseqüentemente, o custo computacional.

Com isso, a inserção do algoritmo de otimização *Tabu Search* (TS) no processo de busca do PSO surge como uma solução eficaz para o problema de repetição de movimentos entre as partículas. O TS possibilita uma maior exploração local, reduzindo a convergência prematura do algoritmo e diminuindo o esforço computacional necessário.


4.2.1 Estrutura híbrida

A posição inicial das partículas no processo do PSO comporá a primeira Lista *Tabu* de restrição de movimentos. À medida que a posição das partículas é atualizada, antes de se efetuar o cálculo no simulador hidráulico e da função objetivo, verifica-se se essa posição já foi alcançada por esta ou por outra partícula do enxame. Se for uma posição nova, a partícula mantém-se nela, prosseguindo o processo de atualização do enxame, e a Lista *Tabu* acolhe essa nova posição como incremento. Porém, caso a partícula se dirija a uma posição já constante na Lista *Tabu*, ela volta ao procedimento de atualização de sua posição. Este processo se repete até que todo o enxame esteja atualizado com suas partículas a visitarem posições novas.

Ao término da atualização do enxame, a Lista *Tabu* pode ser atualizada com as novas posições, mantendo ou não as anteriores. No entanto, a fim de garantir a convergência do modelo a posição *Gbest* do algoritmo não fez parte da Lista *Tabu*. A quantidade de vezes e/ou posições a serem armazenadas na Lista *Tabu* foi determinada por meio de uma análise de sensibilidade realizada em uma das redes em estudo, cujo o intuito foi de obter resultados satisfatórios em um menor tempo de processamento. Os demais parâmetros de entrada inicial

do PSO adotados para este trabalho foram baseados na literatura, configurando-se como uma versão padrão (*default*) para o modelo em todos os demais exemplos. Segue na Figura 4 o processo de simulação do H-PSOTS.

Figura 4 – Fluxograma de processo do Algoritmo Híbrido (H-PSOTS)



Fonte: O Autor (2023).

Os critérios de parada aplicados ao H-PSOTS foram a Tolerância de Iterações (TI) e o Número Máximo de Iterações (NMI) (MACÊDO; AZEVEDO; BEZERRA, 2021). Estas medidas são relevantes no desempenho do algoritmo, pois, quando alcançado um destes critérios, o algoritmo é interrompido. A TI adotada foi de 30%, como sugerido por Macêdo, Azevedo e Bezerra (2021). Para o NMI, os valores propostos variam entre 1000 e 1500 iterações, de acordo com a análise a ser feita.

4.3 ALGORITMO COM CICLOS DE REINICIALIZAÇÃO (PSO-RC)

A utilização do algoritmo PSO tem se mostrado eficaz na exploração do espaço de busca de diversos problemas de otimização. No entanto, a inicialização aleatória do conjunto solução inicial, característica inerente à metaheurística, pode levar à uma convergência prematura do algoritmo para um mínimo local, o que pode prejudicar o processo de otimização.

É fato que ao aumentar do número de partículas do enxame melhora a exploração do PSO, porém, devido à natureza aleatória presente na formação inicial dessas partículas, o algoritmo pode em inúmeras tentativas de simulação convergir prematuramente para um mesmo ou um outro mínimo local. Em consequência disso, há um aumento no custo computacional, que se eleva a cada incremento no enxame, além do aumento do número de tentativas de simulação que são necessárias para se obter um resultado mais confiável.

Além disso, Pereira et al. (2020) reforçam a ideia de que o processo exploratório do PSO se inicia de forma global, onde as partículas abrangem todo o espaço de busca com grandes alterações nas suas variáveis permitindo inúmeras possibilidades de solução. Em seguida, é iniciado o processo de busca local, onde as soluções encontradas são aperfeiçoadas, ou seja, há um progresso contínuo de melhoria, mas somente dentro de uma parte específica desse espaço. Os autores ainda afirmam que o resultado da solução final depende da exploração global inicial da simulação, regida pela posição inicial aleatória das partículas.


Assim, como solução para o problema em questão, que buscou um aumento da exploração global do algoritmo PSO e menor variabilidade de resposta, foi proposto o modelo PSO-RC ou PSO-*Reboot Cycles (Particle Swarm Optimization with Reboot Cycles)*. Essa proposta consiste em executar ciclos reinicialização do algoritmo PSO com baixo número de partículas, além de incrementar uma partícula de memória (*Memory Particle*) ao enxame. Dessa forma, a intenção foi a de aumentar a exploração do algoritmo, diminuindo o número de tentativas frustradas de simulação e elevado custo computacional, ao mesmo tempo em que garante maior rapidez e eficácia ao processo exploratório.

A *Memory Particle* é uma partícula adicional ao enxame, responsável por armazenar a posição da melhor solução encontrada em cada ciclo de busca (*Gbest*). Esta partícula atua dinamicamente se alterado, ao término de cada simulação, quando se tem uma nova *Gbest* encontrada, por isso, ela, apesar de compor o enxame, não é avaliada e atualizada juntamente as demais partículas. Ao iniciar um novo ciclo de simulação, todas as partículas são reinicializadas aleatoriamente, exceto a *Memory Particle*, que mantém a posição da melhor

solução encontrada no ciclo anterior. Assim, esta partícula se torna a nova *Gbest* do enxame atual até que outra seja encontrada. Esta abordagem permitiu uma melhor exploração global, com a reinicialização aleatória do enxame em todo o espaço de busca, e uma melhor exploração, próxima à posição da *Memory Particle*. O vetor velocidade da Equação 12 foi responsável por direcionar este processo, levando à melhoria progressiva do resultado a cada ciclo. Dessa forma, é apresentado na Equação 19, a inserção da *Memory Particle*, que substitui a *Gbest* até que uma nova *Gbest* seja encontrada.

$$v_{pi}^{t+1} = w.v_{pi}^t + c_1.rand^t(Pbest_i^t - x_i^t) + c_2.rand^t(MPart_i^t - x_i^t) \quad (19)$$

onde $MPart_i^t$ é a *Memory Particle*, do inglês, Partícula de Memória, com o melhor *fitness* encontrado por todas as partículas da população na última simulação. É possível ver na Figura 5 o processo adaptativo da *Memory Particle* do algoritmo PSO-RC em três ciclos consecutivos. É válido destacar que a *Memory Particle* pode ser adicionada ao enxame (n) após o término da simulação inicial e início do primeiro ciclo, ou, no início da simulação inicial, porém, com atualização somente ao término desta, com a posição da *Gbest* encontrada.



Fonte: O Autor (2023).


Critérios de parada podem ser aplicados ao algoritmo PSO-RC. Alguns são responsáveis pela reinicialização do algoritmo, como a Tolerância Convergente (TC), a Tolerância de Iterações (TI) e o Número de Ciclos (NC). Outros, como o Número Máximo de Ciclos (NMC) e Número Máximo de Iterações (NMI), como limitadores a entrada do algoritmo em um “loop” infinito de ciclos e iterações, respectivamente. Estas medidas foram úteis para o desempenho do algoritmo, pois, para cada critério, há uma medida estabelecida, que, se atingida, o algoritmo será reiniciado ou interrompido, diminuindo ainda mais o custo computacional da simulação completa.

A TC finalizou a iteração do ciclo corrente após um determinado número de partículas do enxame convergirem para um ótimo local. Esse critério foi determinado em análise de sensibilidade realizada na *Balerma Network*. O valor adotado para TI foi de 30% (Equação 12), conforme sugerido por Macêdo, Azevedo e Bezerra (2021) para esse tipo de aplicação. O NC atuou de forma mais generalista, limitando o número de ciclos que ocorreram após a *Memory Particle* permanecer inalterada entre ciclos consecutivos. O valor deste critério também foi determinado por meio de uma análise de sensibilidade.

Os critérios NMC e NMI poderiam atuar em conjunto em uma mesma simulação ou ser aplicados de forma individual, conforme a necessidade do projetista. Nesse trabalho, entre os dois critérios citados anteriormente, o único adotado foi o NMI cujo valor corresponderá entre 1000 e 1500 iterações, a depender do exemplo estudado. Essa restrição foi escolhida para se manter um padrão entre as simulações e análise comparativa entre os algoritmos, e foi aplicado a cada ciclo individualmente. Os demais parâmetros de entrada do PSO foram adotados com base na literatura.

Na Figura 6 é apresentado o fluxograma do processo de simulação do algoritmo PSO-RC.

Figura 6 – Fluxograma de simulação do Algoritmo PSO-RC



Fonte: O Autor (2023).

Nota-se que o algoritmo inicializa o processo de otimização adicionando uma partícula excedente ao enxame ($n+1$). Essa partícula, apesar de compor o enxame, não será avaliada e atualizada juntamente as demais partículas, e se tornará posteriormente a *Memory Particle*, que a partir do primeiro ciclo de simulação, armazenará a melhor solução encontrada na simulação anterior, retornando, posteriormente, ao novo enxame.

5 RESULTADOS E DISCUSSÃO

Com o objetivo de fornecer uma análise aprofundada dos resultados alcançados nesta pesquisa, esta seção apresenta os resultados e discussão, destacando os principais achados. A partir da apresentação cuidadosa dos dados e das reflexões a eles associadas.

5.1 *BALERMA NETWORK*

A *Balerma Irrigation Network* ou *Balerma Network*, é uma adaptação da rede de distribuição de água de um sistema de irrigação do distrito Sol-Poniente, em Balerma, na província de Almería, na Espanha (RECA et al. 2008; BI; DANDY; MAIER, 2015). De acordo com Macêdo, Azevedo e Bezerra (2021), esta rede é um ótimo exemplo de aplicação de projeto de dimensionamento ideal, devido às suas particularidades, como demandas acentuadas em determinados pontos da rede, diversos trechos ramificados unidos a grandes anéis (malhas) em seu traçado, entre outras. O *layout* desta rede é mostrado na Figura 3, onde é possível observar 3 reservatórios, 443 nós, 454 trechos e 8 anéis (malhas), o que caracteriza seu porte e alta complexidade.

Figura 7 – Layout da *Balerma Network*



Fonte: Reça et al. (2008).

Para essa rede, a pressão mínima requerida em seus nós é de 20 mca e o cálculo da perda de carga é realizado pela equação de Darcy-Weisbach mantendo o coeficiente de rugosidade de 0,0025 mm para todos os tubos. Para o processo de dimensionamento ótimo estão disponíveis 10 tubos comerciais com diâmetros nominais variando de 125 a 600 mm.

O número de diâmetros disponíveis para o dimensionamento, juntamente com o número de trechos a serem dimensionados, determinará o total de soluções potenciais de projeto da rede. Neste caso, com 10 possíveis diâmetros a serem aplicados em 454 trechos de tubulação, o problema terá 10^{454} soluções (factíveis e infactíveis) a serem investigadas. Para esse número de soluções, torna-se inviável a aplicação de técnicas de otimização convencionais ou tradicionais, baseadas na programação matemática. Dessa forma, torna-se vantajoso explorar esse grande espaço de soluções através do uso de algoritmos evolutivos. Na Tabela 1, são apresentados os diâmetros e seus respectivos custos de implantação das tubulações.

Tabela 1 – Custo de aplicação das tubulações por metro para a *Balerma Network*

Diâmetro (mm)	Custo (€/m)
113,0	7,22
126,6	9,10
144,6	11,92
162,8	14,84
180,8	18,38
226,2	28,60
285,0	45,39
361,8	76,32
452,2	124,64
581,8	215,85

Fonte: Reca et al. (2008).


Com relação à determinação dos parâmetros específicos de entrada dos modelos propostos. Para o modelo híbrido (H-PSOTS), será definido o tamanho da Lista *Tabu* (LT) com o número de posições restritivas que as partículas terão a cada iteração. Para o PSO-RC, serão definidos os critérios de Tolerância Convergente (TC) e Número de Ciclos (NC).

Ainda nesta análise de sensibilidade, para cada um dos modelos (H-PSOTS e PSO-RC), serão estabelecidos tamanhos de enxames que produzam a mesma efetividade de

resposta do modelo PSO convencional, a fim de obter um estudo comparativa de desempenho mais adequado. Para isso, inicialmente, foram realizadas 20 simulações com o PSO convencional em quantidades discretas de enxames, cujo o número de partículas variou entre os limites de 20 e 200. Vale destacar que, se algum modelo obtiver a mesma média de resposta que o PSO convencional com um número menor de partículas, esse já demonstrará efetividade em seu desempenho e o valor do enxame será adotado nas demais simulações.

Na Figura 8, é mostrada a relação entre o tamanho do enxame e tempo médio de execução das simulações até a convergência para cada quantidade ao longo das 20 simulações realizadas. Esta análise de sensibilidade fez uso apenas dos critérios NMI de 1500 iterações e TI de 30%. Além disso, foi preferível identificar o menor custo encontrado para cada enxame individual, uma vez que esse é o valor almejado em problemas desse tipo. No entanto, é importante mencionar que a maior variação do tempo de execução da simulação se deu entre enxames, permanecendo praticamente estável quando analisado as simulações em um único enxame específico, com isso, segue justificado a preferência em apresentar o tempo médio de execução das simulações neste e demais estudos realizados.

Figura 8 – Relação entre número de partículas do enxame, tempo médio de execução e o menor custo ótimo encontrado com o PSO convencional



Fonte: O Autor (2023).


Observa-se na Figura 8, que há um padrão de estabilidade no custo iniciado no enxame de 160 partículas, cujo valor representa a solução mais baixa encontrada pelo PSO

convencional, que foi de aproximadamente € 2,10 milhões. Esse resultado foi encontrado pelos demais enxames superiores. Por conseguinte, foi adotado esse enxame (160 partículas) para definir o tamanho da Lista *Tabu* do modelo híbrido (H-PSOTS), a fim de manter um valor fixo e assim realizar uma melhor análise sob menor custo computacional possível, pois esse foi o menor enxame que obteve o melhor resultado encontrado. Após a definição do tamanho da Lista, uma nova análise será realizada com o modelo híbrido, de modo a redefinir ou confirmar o tamanho do enxame a ser utilizados nas demais simulações com esse modelo.

Aumentar o número de partículas poderia aumentar o custo computacional e, consequentemente, o tempo de execução do algoritmo, conforme demonstrado na Figuras 8. Observa-se ainda que o tamanho do enxame escolhido corresponde a 35% do número total de variáveis (trechos de tubulação) do problema.

Assim, a análise do tamanho da Lista *Tabu* foi dada por meio de 20 simulações do modelo híbrido com as seguintes variações de tamanho da Lista: (1) memorizando apenas as posições anteriores de cada partícula até a atualização do enxame completo; (2) memorizando até duas posições anteriores; (3) memorizando até três; (4) memorizando até quatro; e (5) memorizando até cinco. É apresentado na Figura 9 o resultado dessa análise juntamente com o menor custo encontrado e tempo médio de execução obtidos nas simulações de mesmo enxame, mantendo os mesmos critérios de parada, NMI de 1500 iterações e TI de 30%.

Figura 9 – Relação entre tamanho da Lista *Tabu*, tempo médio de execução e custo ótimo do H-PSOTS



Fonte: O Autor (2023).

Verifica-se na Figura 9, que o aumento do tamanho da Lista *Tabu* trará um acréscimo, tanto ao tempo médio de execução do algoritmo, quanto aos resultados da otimização. Esse acréscimo de tempo, se deve ao aumento do número de verificações que foram feitas a Lista *Tabu* durante a atualização de cada partícula. A respeito do custo ótimo, grandes listas limitam muito a exploração do enxame por locais já percorridos pelas partículas, que podem redirecionar o enxame em etapas avançadas do processo. Essa reexploração em etapas avançadas de simulação poderá ajudar a diminuir as chances de uma convergência prematura em ótimos locais, permitindo alcançar melhores resultados.

Assim, será adotada uma Lista *Tabu* mais simples, memorizando apenas as posições anteriores de cada partícula, até que a atualização do enxame seja completada. Além disso, esse tamanho de lista evita a ação de outros critérios de aspiração do algoritmo *Tabu Search*, pois as partículas poderão retornar a duas posições anteriores a atual. Nesse processo, caso o tamanho da Lista *Tabu* adotada fosse mais extensa, e buscando diminuir o consumo de memória, as novas posições substituiriam as posições mais antigas de cada partícula.


Vale destacar, que o tempo médio de execução do H-PSOTS cai em relação ao PSO convencional, devido a ação do critério TI adotado nesta análise. Como o H-PSOTS busca dar maior direcionamento as partículas, com maior varredura do espaço de busca local, o enxame converge mais rapidamente para um valor ótimo, igual ou mais próximo ao ótimo global. Enquanto que o PSO convencional avança na otimização com grandes variações iniciais e sutis variações finais (menor busca local). E como as partículas desse algoritmo (PSO convencional) podem passar por posições já visitadas, dificulta a atuação do critério de TI de parada, mantendo-se por mais tempo em execução.

Após a definição do tamanho da Lista *Tabu* e objetivando nova definição do número de partículas do enxame para ambos os modelos desenvolvidos, análises semelhantes à presente na Figura 8 foram realizadas com o H-PSOTS e o PSO-RC, como pode ser visto nas respectivas Figuras 10 e 11. Nessas análises foram mantidas as mesmas informações, critérios de parada e número de simulações para ambos modelos. Porém, para o PSO-RC o critério NMI atuará no acumulado de todas as iterações entre ciclos, enquanto o TI e o Tolerância Convergente (TC) será avaliado de forma independente para cada ciclo. O critério Número de Ciclos (NC) não será inserido nesta primeira análise, pois ainda será estudado e definido.

Para a determinação do critério TC, foi observado em todas as simulações realizadas pelo PSO convencional, que após, aproximadamente, 75% (terceiro quartil) do enxame convergir para um valor ótimo, dificilmente havia alteração significativa do valor encontrado. Dessa forma, esse valor passa a ser adotado para este critério e aplicado nas demais


simulações a serem realizadas nesse estudo, buscando melhorar a performance do algoritmo, objetivando a diminuição do tempo de execução de cada ciclo. Apesar desse critério poder ser adotado pelos demais algoritmos, foi referível somente no PSO-RC, para que um número maior de ciclos seja realizado, e com isso, haja uma maior exploração global do algoritmo. Assim, esse critério atuará de forma independente a cada ciclo nas simulações realizadas pelo PSO-RC.

Figura 10 – Relação entre número de partículas do enxame, tempo médio de execução e o menor custo ótimo encontrado utilizando o H-PSOTS



Fonte: O Autor (2023).

Figura 11 – Relação entre número de partículas do enxame, tempo médio de execução e o menor custo ótimo encontrado utilizando o PSO-RC



Fonte: O Autor (2023).

Segundo as informações presentes na Figura 10, nota-se que o melhor resultado alcançado pelo H-PSOTS (€ 1,998 milhões) iniciou em 160 partículas e continuou sendo alcançado nos demais enxames sucessivos. Esse tamanho corresponde a mesma quantidade determinada na primeira análise feita com o PSO convencional (Figura 8), cuja relação representa cerca de 35% do número de trechos de tubulação da rede (454 trechos). Assim, e diante dessa nova análise, essa relação será mantida por esse modelo para esta e demais redes estudadas. Já o PSO-RC (Figura 11) obteve o melhor resultado (€ 2,096 milhões) a partir de 100 partículas, que se manteve por enxames superiores. Esta quantidade corresponde cerca de 23% do número de trechos de tubulação, uma redução de 38% em relação ao enxame definido para o modelo híbrido. Essa relação será mantida para o PSO-RC e aplicada as análises subsequentes de estudo desse modelo, para esta e demais redes estudadas, incluindo a própria conclusão da análise de sensibilidade.


Segundo Macêdo, Azevedo e Bezerra (2021), relacionar o número de partículas do enxame com o número de trechos a serem dimensionados em problemas de otimização de Redes de Distribuição de Água, segue como uma boa aproximação de análise da aplicação de técnicas evolutivas. No entanto, esse número deverá representar certa tendência a um mesmo resultado ótimo encontrado pelo algoritmo em um estudo de análise de sensibilidade. Além disso, os autores afirmam que a complexidade resolutiva desse tipo de problema pode ir além

do número de trechos da rede, mas sim, da sua estrutura, componentes e exigências, estando a cargo do engenheiro projetista determinar ajustes a escolha desse valor.

No que se refere ao tempo médio de execução (Figuras 8, 10 e 11), é possível verificar certa linearização em resposta ao crescimento, também, linear de partículas dos enxames, independente do algoritmo aplicado. Além disso, é possível destacar, que esse aumento do enxame melhora a exploração dos algoritmos, e consequentemente, o resultado final da simulação. Porém, cada algoritmo possui sua estratégia de busca, e por isso, há diferença em seus tempos de execução.

Ainda, ao analisar dos resultados das Figuras 8, 10 e 11, é possível notar que, para um mesmo enxame, os maiores valores de tempo médio de execução estão com o PSO convencional, seguido pelo PSO-RC, e por último o H-PSOTS. O PSO convencional segue com os maiores tempos, pois, como já mencionado, as partículas desse algoritmo podem retornar a posições já frequentadas, o que acaba gerando sutis avanços do valor ótimo ao longo das iterações, dificultando a ação do critério TI de parada. Por outro lado, o H-PSOTS direciona mais rapidamente as partículas para novos caminhos de busca, afunilando a busca em torno de valores ótimos melhores, garantindo um resultado mais rápido. Já o PSO-RC se posiciona em um nível intermediário de tempo, pois as reinicializações do algoritmo geram um número maior de simulações, onde o único critério finalizador da simulação atuante é o NMI. Porém, como esse modelo cíclico possui um enxame menor e mantém a cada reinicialização o último valor ótimo encontrado (*Memory Particle*), sua convergência se torna mais rápida a cada novo ciclo, tornando o seu tempo de execução menor que o do PSO convencional. Na Figura 12 é apresentado um resumo dos dados obtidos pelo PSO convencional, H-PSOTS e PSO-RC.


Figura 12 – Comparação entre a relação enxame, custo ótimo e tempos médio de execução dos algoritmos PSO convencional, H-PSOTS e PSO-RC.



Fonte: O Autor (2023).

Observando a Figura 12, é possível notar que o PSO-RC apresentou os melhores resultados nos enxames iniciais, como resposta a maior à exploração global do algoritmo, seguindo uma maior estabilidade em torno do menor valor encontrado por esse algoritmo. Esse aumento na exploração global, resultante dos ciclos de reinicialização, aumentou sutilmente o tempo de execução do modelo em relação ao H-PSOTS, que obteve o melhor resultado entre todos os algoritmos, devido ao aumento da exploração local proporcionada pela hibridização. É mostrado na Figura 13, a relação entre os custos ótimos obtidos pelo PSO-RC e a média do número de ciclos executados.

Figura 13 – Custo ótimo obtido pelos algoritmo PSO-RC e o número de ciclos executados




Fonte: O Autor (2023).

É possível observar que, à medida que o tamanho do enxame aumenta (Figura 13), o número de ciclos tende a diminuir. Isso é esperado, pois um maior enxame permite que as partículas se espalhem mais no espaço de busca, o que aumenta a exploração e reduz as chances de convergência prematura do algoritmo para um ótimo local.

Outro ponto a ser considerado é a qualidade da resposta obtida pelo PSO-RC em enxames menores. Apesar do aumento do número de ciclos, melhores resultados são alcançados, como pode ser visto nas simulações com 20 partículas, onde O PSO-RC obteve um valor 32% menor que o PSO convencional e 19% menor que o H-PSOTS. No entanto, para aprimorar a exploração desse método em problemas complexos, é necessário buscar maior exploração local, como sugerido pelo H-PSOTS.


Vale destacar, que nem sempre se tem um bom resultado em uma única simulação de um algoritmo metaheurístico, necessitando reiniciar todo o processo de simulação, o que ainda poderá ocasionar em uma convergência prematura em um resultado inferior ao encontrado na simulação anterior. Para melhor análise desse ponto, as Figuras 14, 15 e 16 mostram a variação dos resultados obtidos para as 20 simulações em determinados enxames realizadas com PSO convencional, H - PSOTS e PSO-RC, respectivamente.

Figura 14 – Variação do custo final em relação ao enxame do PSO convencional




Fonte: O Autor (2023).

Figura 15 – Variação do custo final em relação ao enxame do H-PSOTS



Fonte: O Autor (2023).

Figura 16 – Variação do custo final em relação ao enxame do PSO-RC




Fonte: O Autor (2023).

Como pode ser visto, ao analisar as Figuras 14, 15 e 16, o PSO-RC apresentou as melhores médias de respostas nas simulações para os mesmos enxames analisados em todos algoritmos, com menor variabilidade entre simulações. Isso diminui a necessidade de inúmeras tentativas de simulação.


Devido ao único critério de parada da simulação completa atuante em uma simulação completa do PSO-RC ser o NMI (1500 iterações), este algoritmo limita o avanço da otimização de enxames menores, que por sua vez, necessitariam de um maior número de ciclos e consequentemente maior número de iterações, para alcançar os melhores resultados.

Com isso, a fim de testar a eficiência do algoritmo, uma análise foi realizada para um enxame menor (50 partículas), sem que houvesse limitação no número de iterações, e adotando, inicialmente o Número de Ciclos (NC) com o valor 4 como critério de parada da simulação, além dos demais critérios, TC (75%) e TI (30%). aplicados a cada ciclo individualmente. Assim, segue na Figura 17, a evolução do custo a cada ciclo de forma independente, em partes, estando o número de iterações representada no eixo das abcissas de forma acumulada. O valor do custo representado é somente o valor da *GBest* das partículas do enxame com exceção da *Memory Particle*.


Figura 17 – Evolução do custo ao longo dos processos de otimização do PSO-RC para a *Balerna Network*




(a) Inicialização do algoritmo




(b) Primeiro Ciclo



(c) Segundo ciclo



(d) Terceiro ciclo



(e) Ciclos de repetição

Fonte: O Autor (2023).

A simulação presente na Figura 17, ocorreu em 13,94 minutos e deixa claro que o custo ótimo evoluiu significativamente durante os três primeiros ciclos, demonstrando que o enxame, mesmo pequeno, é capaz de encontrar um resultado satisfatório. Após os três primeiros ciclos, o resultado se repete até que o critério NC seja atingido. Com isso, é observado que um valor de NC menor já seria suficiente para finalizar a simulação.

Para avaliar o método proposto de forma adequada, com vistas a redução do custo computacional, uma vez que esse enxame analisado é pequeno, e exames pequenos geram um maior número de ciclos, foi estabelecido como critério de parada um NC igual a 3, que abrangerá outros casos em que serão necessários enxames maiores. Além disso, para se manter um padrão, foi optado nas simulações com o PSO-RC, em permanecer com a relação de 23% entre o número de partículas do enxame e o número de trechos de tubulação da rede de distribuição, ainda que a alteração da quantidade de partículas possa resultar em melhores resultados.

Por fim, a determinação do número máximo de iterações deve ser vinculada à complexidade resolutiva de cada rede. No caso da *Balerna Network*, o valor de 1500 iterações foi suficiente para a análise de sensibilidade e para a comparação entre os modelos. Portanto, esse valor será mantido nas demais redes estudadas. Para o PSO-RC, o critério NC pode ser utilizado como único critério de parada, substituindo o NMI, ou atuando em conjunto com ele, neste trabalho, ambos atuaram simultaneamente.

Após a determinação e análise de todos os parâmetros, foi estabelecida uma configuração padrão (default) para os modelos, que pode ser visualizada na Tabela 2.

Tabela 2 – Parâmetros definidos para o PSO convencional, H-PSOTS e PSO-RC

Método de otimização	Relação partículas/trechos	Número máximo de iterações	Tolerância de iterações	Tolerância convergente	Número de ciclos
PSO conv.	35%	1500*	30%**	-	-
H-PSOTS				-	-
PSO-RC	23%			75%	3


Fonte: O Autor (2023).

*Para o PSO-RC o NMI atuará sobre o total de iterações realizadas de forma acumulada entre ciclos consecutivos.

**Para o PSO-RC o TI atuará a cada ciclo individualmente.

Após todos os parâmetros de entrada determinados, segue na Figura 18 a representação gráfica da evolução do custo ao longo do processo de otimização pelos algoritmos PSO convencional, H-PSOTS e PSO-RC. Nesta figura, para o PSO-RC, o número de iterações será representado no eixo das abcissas de forma acumulada a cada ciclo e o valor do custo representado será somente o valor da *GBest* das partículas do enxame com exceção da *Memory Particle*.

Figura 18 – Evolução do custo ao longo dos processos de otimização para a *Balerma Network*



Fonte: O Autor (2023).

É apresentado na Tabela 3, um resumo dos resultados obtidos em 20 simulações para os modelos aplicados neste trabalho, segundo os parâmetros determinados em análise de sensibilidade. O tempo de execução corresponde ao valor médio das simulações realizadas.

Tabela 3 – Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na *Balerna Network*

Método de otimização	Melhor solução (10⁶ €)	Pior solução (10⁶ €)	Média das soluções (10⁶ €)	Desvio padrão	Tempo de execução (min.) *
PSO conv.	2,099	3,795	3,261	0,278	42,34
H-PSOTS	1,998	2,893	2,433	0,251	19,47
PSO-RC	2,096	2.460	2.295	0,153	15,42

Fonte: O Autor (2023).

*Tempo de execução até a ação de algum critério de parada.

Diante do elevado número de soluções presentes na literatura para o dimensionamento ótimo da rede *Balerna Network*, muitas se destacam por apresentar soluções ótimas efetivas a aplicação real. No entanto, muitas são obtidas sob um elevado conjunto-soluções a serem avaliadas em um denso número de iterações ou evoluções, como é o caso de alguns algoritmos evolutivos, como o *Genetic Algorithm*. Assim, na Tabela 4 segue alguns resultados reportados na literatura.

Tabela 4 – Resultados descritos na literatura para o dimensionamento ótimo da *Balerma Network*

Autores	Método	Melhor solução (10⁶ €)
Reca e Martinez (2006)	<i>Genetic algorithm</i>	2,302
Zheng, Simpson e Zecchin (2011)	<i>Differential evolution</i>	1,923
Sheikholeslami et al. (2016)	<i>Cuckoo search</i>	2,036
Sheikholeslami et al. (2016)	<i>Hybrid cuckoo harmony search</i>	1,988
Lee et al. (2016)	<i>Decomposition approach</i>	2,066
Zheng et al. (2017)	<i>Ant colony optimization adapted</i>	2,020
Bi, Xu e Wang (2020)	<i>Differential evolution</i>	2,002
Bi, Xu e Wang (2020)	<i>Ant colony optimization</i>	2,332
Saldarriaga et al. (2020)	<i>Optimal power use surface</i>	2,015
PSO convencional		2,099
H-PSOTS		1,998
PSO-RC		2,096

Fonte: O Autor (2023).


Entre as soluções presentes na Tabela 4, Zheng, Simpson e Zecchin (2011), utilizando o NLP- *differential Evolution* (Programação Não Linear – Evolução Diferencial) obteve o melhor resultado, € 1,923 milhões. Esses autores, antes de aplicar o NLP- *Differential Evolution* na rede, utiliza de um procedimento chamado de árvore de menor distância em *Loop*. Esse procedimento encontra o menor caminho entre o ponto mais distante e os reservatórios, melhorando o procedimento de otimização do algoritmo proposto.

Apesar das melhorias impostas ao PSO convencional, não foi possível chegar, em ambas propostas, ao valor de € 1,923 milhões obtido por Zheng, Simpson, e Zecchin (2011). No entanto, ambos algoritmos demonstraram bom desempenho, diante de aspectos importantes como o custo computacional e o aperfeiçoamento da capacidade de exploração desse algoritmo bastante difundido na comunidade científica, sem que houve a aplicação alguma técnica de simplificação da rede a ser otimizada. Assim, é notável que o algoritmo híbrido obteve um bom desempenho com um grau de refinamento constante, mostrando que as partículas, em poucas iterações, já demonstravam melhoria do resultado, enfatizando sua performance na busca local. Essa maior exploração fez com que o tempo de execução diminuísse cerca de 54% em relação ao PSO convencional. Para que esse algoritmo obtivesse melhores resultados, seria necessário que ele explorasse mais o espaço de busca de forma global, alcançando regiões ainda não visitadas pelas partículas.

O algoritmo com ciclos de reinicialização, PSO-RC, demonstrou alcançar bons resultados de otimização com redução no número de partículas em relação ao PSO convencional, cerca de 38%, com uma redução no tempo de execução de 64% em relação a esse algoritmo. No entanto, apesar da ocorrência de vários ciclos e do entendimento que haveria melhora do resultado a cada ciclo realizado, o valor ótimo encontrado (€ 2,099 milhões) permaneceu inalterado e maior em relação ao valor obtido pelo H-PSOTS, € 1,998 milhões. Isso se deu devido à complexidade do problema. Segundo Macêdo, Azevedo e Bezerra (2021), muitas partículas, ao longo das simulações, podem retornar a “caminhos” já frequentados do espaço de busca, inúmeras vezes. Necessitando de alguma implementação que melhor diversifique as soluções, ou seja, que force as partículas a percorrerem novos caminhos em espaços de busca mais complexos. Porém, como o número de partículas do PSO-RC é reduzido, seu tempo de execução se assemelhou ao do algoritmo híbrido (H-PSOTS), mesmo com o acréscimo do número de iterações.


Segue apresentado na Figura 19 o esquema de diâmetros da rede otimizada para o melhor custo encontrado (H-PSOTS), seguido das pressões nodais desta rede, na Figura 20.

Figura 19 – Diâmetros otimizados da *Balerma Network* determinados pelo H-PSOTS



Fonte: O Autor (2023).

Figura 20 – Pressões nodais da *Balerna Network* determinados pelo H-PSOTS




Fonte: O Autor (2023).

Por fim, as metodologias propostas proporcionaram uma maior exploração do espaço de busca em um menor tempo de execução, além de uma menor variabilidade na solução apresentada. Esses ganhos, oferecem ao projetista uma maior flexibilidade de aplicação em sistemas reais de dimensionamento, além de um conjunto de soluções viáveis, com similaridade de preço.

5.2 HANOI NETWORK

A *Hanoi Network* (Figura 21) foi originalmente proposta por Fujiwara e Khang (1990) e, posteriormente, adotada por inúmeros pesquisadores na área de otimização (ZECCHIN et al., 2006; BRAGALLI et al., 2015; SURIBABU, 2017; CHOI et al., 2017; BEZERRA; MACÊDO, 2018; MANOLIS; SIDIROPOULOS; EVANGELIDES, 2021).

Figura 21 – Layout da *Hanoi Network*

Fonte: Fujiwara e Khang (1990).

Essa rede possui 3 anéis, 34 trechos, 32 nós e 1 reservatório de nível fixo com cota piezométrica de 100 mca e a pressão mínima exigida é de 30 mca em todos os seus nós. Para a perda de carga, foi adotado a fórmula de Hazen-Williams com o valor da constante numérica de conversão ω de 10,6792, valor adotado pelo simulador hidráulico Epanet, mantendo-se o coeficiente de rugosidade de 130 para o cálculo de perda de carga em todos os trechos de tubulação.

O número de opções de diâmetros disponíveis para o dimensionamento juntamente com o número de trechos a serem dimensionados, ditará o total de soluções potenciais de projeto da rede. Por esse problema possuir 6 possíveis diâmetros disponíveis, para serem aplicados em 34 trechos de tubulação, o problema terá, neste caso, $6^{34} \approx 2,8 \times 10^{26}$ soluções a serem investigadas. Esse valor, apesar de pequeno, quando comparado com outras redes de distribuição, torna-se de inviável avaliação feita por técnicas de otimização convencionais ou tradicionais, baseadas na programação matemática, e é por isso que é vantajoso explorar este conjunto de soluções através do uso de algoritmos evolutivos. Além disso, esse exemplo foi escolhido por possuir valor ótimo global já conhecido, e assim, poder analisar o comportamento dos modelos quando aplicados em problemas de pequeno porte.

A Tabela 5 apresenta as demandas requeridas nos nós da rede, enquanto a Tabela 6 os diâmetros disponíveis e seus respectivos custos por metro de tubulação (\$/m) conforme determinado por Fujiwara e Khang (1990).

Tabela 5 – Dados referentes a *Hanoi Network*

Nó	Demanda (L/s)	Cota (m)	Trecho	Comprimento (m)
1	–	100	t1	100
2	247,22	0	t2	1350
3	236,11	0	t3	900
4	36,11	0	t4	1150
5	201,39	0	t5	1450
6	279,17	0	t6	450
7	375,00	0	t7	850
8	152,78	0	t8	850
9	145,83	0	t9	800
10	145,83	0	t10	950
11	138,89	0	t11	1200
12	155,56	0	t12	3500
13	261,11	0	t13	800
14	170,83	0	t14	500
15	77,78	0	t15	550
16	86,11	0	t16	2730
17	240,28	0	t17	1750
18	373,61	0	t18	800
19	16,67	0	t19	400
20	354,17	0	t20	2200
21	258,33	0	t21	1500
22	134,72	0	t22	500
23	290,28	0	t23	2650
24	227,78	0	t24	1230
25	47,22	0	t25	1300
26	250,00	0	t26	850
27	102,78	0	t27	300
28	80,56	0	t28	750
29	100,00	0	t29	1500
30	100,00	0	t30	2000
31	29,17	0	t31	1600
32	223,61	0	t32	150
			t33	860
			t34	950

Fonte: Fujiwara e Khang (1990).


Tabela 6 – Custo das tubulações para a *Hanoi Network*

Diâmetro (pol.)	Custo (\$/m)
12	45,73
16	70,40
20	98,38
24	129,30
30	180,80
40	278,30

Fonte: Fujiwara e Khang (1990).

O número de partículas adotado para a otimização com o H-PSOTS e PSO convencional será 19, que corresponde a aproximados 35% do número de trechos de tubulação existentes. Para O PSO-RC será de 13 partículas, correspondendo a 23%. Vale destacar que esses valores são mínimos e próximos.

Para apreciação dos resultados e análise comparativa, de forma semelhante à ocorrida na *Balerma Network*, foram realizadas 20 simulações com cada um dos algoritmos, seguindo os critérios de parada já especificados e determinados neste trabalho. Na Figura 22, segue a variação dos resultados (custo ótimos) obtidos para o PSO convencional, H-PSOTS e PSO-RC.


Figura 22 – Variação do custo obtidos no PSO convencional, HPSOTS e PSO-RC para a *Hanoi Network*

Fonte: O Autor (2023).

Ao analisar a variação dos resultados obtidos pelos algoritmos estudados (Figura 22), é possível observar que PSO convencional se destaca com maior variação, estando o PSO-RC com a menor. Apesar do H-PSOTS apresentar bons resultados, esse algoritmo ainda demonstra certa variação a cada simulação, em resposta a necessidade de melhoria da exploração global do algoritmo, o que é presente no PSO-RC.

Na Figura 23, segue a representação gráfica da evolução do menor custo encontrado nas simulações realizadas ao longo dos processos de otimização para os algoritmos em função do número de iterações. Nesta Figura 23, para o PSO-RC, encontra-se o número de iterações representada no eixo das abcissas de forma acumulada a cada ciclo e o valor do custo representado é somente o valor da *GBest* das partículas do enxame com exceção da *Memory Particle*.

Figura 23 – Evolução do custo ao longo dos processos de otimização para a *Hanoi Network*



Fonte: O Autor (2023).

É apresentado na Tabela 7, um resumo dos resultados obtidos nas simulações realizadas para os modelos aplicados nesta rede, segundo os parâmetros determinados em análise de sensibilidade. O tempo de execução corresponde ao valor médio das simulações realizadas.

Tabela 7 – Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na *Hanoi Network*

Método de otimização	Melhor solução (10⁶ \$)	Pior solução (10⁶ \$)	Média das soluções (10⁶ \$)	Desvio padrão	Tempo de execução (min.) *
PSO conv.	6,151	6,341	6,240	0,047	1,48
H-PSOTS	6,081	6,254	6,125	0,046	2,15
PSO-RC	6,081	6,154	6,105	0,022	2,65

Fonte: O Autor (2023).

*Tempo de execução até a ação de algum critério de parada.

Como pode ser observado na Tabela 7, o mínimo custo encontrado pelo PSO convencional foi \$ 6,151 milhões, enquanto o H-PSOTS e o PSO-RC alcançaram o valor de \$ 6,081 milhões, semelhante ao mínimo global citado na literatura. No entanto, diferente da *Balerna Network*, o PSO convencional apresentou um menor tempo de execução devido ao tamanho reduzido do enxame e consequente convergência prematura do algoritmo. Além disso, essa redução faz com que a diferença entre enxames adotados entre os modelos, sejam irrisórios, deixando a definição do tempo de execução direcionada as particularidades que cada método possui.

No entanto, como o H-PSOTS avalia a Lista *Tabu* a cada atualização da partícula, o seu tempo de execução aumenta, além disso, a exploração desse algoritmo se torna mais restritiva e direcionada, provocando uma maior exploração local, resultando em um aumento do número de iterações executadas pelo algoritmo. Já para o PSO-RC, é intrínseco o aumento do número de iterações da simulação, devido a própria reinicialização do algoritmo, assim, segue justificado o aumento do tempo de execução deste algoritmo.

Segundo Bezerra e Macêdo (2018), para que o PSO convencional obtivesse bons resultados, próximo ao melhor valor ótimo já descrito na literatura, números elevados de partículas devem ser inseridos no enxame, resultando no aumento do custo computacional de simulação e ainda não haveria garantia de resultado.

A Tabela 8 traz o resultado do dimensionamento ótimo da *Hanoi Network*, para o valor ótimo de \$ 6,081 milhões. Enquanto a Tabela 9 apresenta alguns custos ótimos descritos na literatura para o dimensionamento ótimo da *Hanoi network*.

Tabela 8 – Resultados do dimensionamento ótimo da *Hanoi Network* – Diâmetros

ID Trecho	Diâmetros (pol.)	ID Trecho	Diâmetros (pol.)
1	40	18	24
2	40	19	20
3	40	20	40
4	40	21	20
5	40	22	12
6	40	23	40
7	40	24	30
8	40	25	30
9	40	26	20
10	30	27	12
11	24	28	12
12	24	29	16
13	20	30	12
14	16	31	12
15	12	32	16
16	12	33	16
17	16	34	24

Fonte: O Autor (2023).

Tabela 9 – Resultados descritos na literatura para o dimensionamento ótimo da *Hanoi Network*

Autores	Método	Melhor Custo (10 ⁶ \$)
Liong e Atiquzzaman (2004)	<i>Shuffled Complex Evolution</i>	6,220
Zecchin et al. (2006)	<i>Ant Colony Optimization</i>	6,134
Gomes et al. (2009)	<i>Lenhsnet</i>	6,962
Bragalli et al. (2015)	<i>Genetic Algorithm Modificado</i>	6,081
Choi et al. (2017)	<i>Guided-Search</i>	6,081
Bezerra e Macêdo (2018)	<i>Particle Swarm Optimization Modificado</i>	6,081
Manolis, Sidiropoulos e Evangelides (2021)	<i>Targeted path search algorithm</i>	6,081
PSO convencional		6,151
H-PSOTS		6,081
PSO-RC		6,081

Fonte: O Autor (2023).


Os modelos propostos se destacaram nesta rede menor por apresentarem qualidade nos resultados chegando ao valor ótimo global, com um baixo número de partículas no enxame. O PSO-RC obteve menor variabilidade da resposta, tornando-se mais efetivo em aplicações em redes de menor complexidade, pois esse modelo apresenta uma maior diversidade de soluções próximas ou iguais ao ótimo global.

Em resumo, a análise realizada nesta rede trouxe pontos de entendimento fundamentais para se compreender melhor o funcionamento e características particulares dos modelos propostos.

5.3 RURAL NETWORK

A *Rural network* é o modelo hidráulico de uma rede real de um sistema de irrigação totalmente canalizado. Esta rede possui 2 reservatórios interligados por 476 tubos e 379 nós de junção. Com inúmeras malhas (Figura 24), este problema torna-se um bom exemplo representativo de redes de distribuição de alta complexidade.

Figura 24 – Layout da *Rural Network*



Fonte: Marchi et al. (2014).

A *Rural Network* foi inicialmente otimizada por Marchi et al. (2014), aplicando os algoritmos: *Genetic Algorithm*; *Particle Swarm Optimization*; e *Differential Evolution*. E

posteriormente otimizada por Bi, Dandy e Maier (2015) aplicando um *Genetic Algorithm* com adaptações.

É apresentado na Tabela 10, um conjunto de 15 diâmetros disponíveis de tubulação e seus respectivos custos de implantação a serem utilizados durante o projeto da rede. O grande número de possibilidades de diâmetros eleva o espaço de busca, que fica em torno de 15^{476} soluções possíveis, destacando o grau de dificuldade que essa rede traz para o estudo de otimização. Tornando-se um bom desafio aos modelos propostos neste trabalho.


Tabela 10 – Custo das tubulações para a *Rural Network*

Diâmetro (mm)	Custo (\$/m)
44,0	12,0
64,0	17,0
80,8	21,0
104,0	34,0
117,0	42,0
141,0	55,0
159,0	61,0
207,0	98,0
225,0	116,0
262,0	126,0
307,0	146,0
384,0	199,0
480,0	285,0
518,0	334,0
622,0	411,0

Fonte: Marchi et al. (2014).

O sistema requer uma pressão mínima de 0 m, e para a perda de carga, a equação de Darcy-Weisbach foi aplicada com um coeficiente de rugosidade de 0,012 mm para todos os tubos. O enxame será composto por 167 partículas nas simulações com o H-PSOTS e o PSO convencional (35% do número de trechos). Para o PSO-RC, será 110 partículas (23% do número de trechos). Na Figura 25, segue a variação dos resultados obtidos pelos modelos após 20 simulações com cada um deles, seguindo os critérios de parada já especificados e determinados neste trabalho.


Figura 25 – Variação do custo obtidos no PSO convencional, HPSOTS e PSO-RC para a *Rural Network*



Fonte: O Autor (2023).

Observando as informações presentes na Figura 25, é possível perceber a elevada variação dos resultados apresentados pelos algoritmos, deixando claro a complexidade resolutive desse problema. Mesmo assim, é fato que o PSO-RC possui menor variação, enfatizando a importância e dependência da formação da solução inicial do enxame no resultado final da otimização. Deixando claro, a necessidade de se explorar melhor o espaço de busca de forma global.

Na Figura 26, segue a representação gráfica da evolução do menor custo encontrado nas simulações realizadas ao longo dos processos de otimização para os algoritmos em função do número de iterações. Nesta Figura 26, para o PSO-RC, encontra-se o número de iterações representada no eixo das abcissas de forma acumulada a cada ciclo e o valor do custo representado é somente o valor da *GBest* das partículas do enxame com exceção da *Memory Particle*.

Figura 26 – Evolução do custo ao longo dos processos de otimização para a *Rural Network*

Fonte: O Autor (2023).

É apresentado na Tabela 11 um resumo dos resultados obtidos para os modelos aplicados nesta rede. O tempo de execução corresponde ao valor médio das simulações realizadas. A complexidade resolutiva deste problema fica mais evidente ao analisar o tempo de execução dessa rede, enfatizando a importância da aplicação de critérios de parada para reduzir o custo computacional. Essa complexidade é fruto do número de trechos de tubulação, mas também do seu traçado repleto de malhas e do elevado número de opções de diâmetro disponíveis para o dimensionamento. Resultados descritos na literatura para o dimensionamento ótimo da *Rural network* são apresentados na Tabela 12.

Tabela 11 – Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na *Rural Network*

Método de otimização	Melhor solução (10 ⁶ \$)	Pior solução (10 ⁶ \$)	Média das soluções (10 ⁶ \$)	Desvio padrão	Tempo de execução (min.) *
PSO conv.	46,45	78,67	64,91	9,35	35,85
H-PSOTS	35,68	64,44	50,94	8,51	32,15
PSO-RC	37,43	54,01	44,34	5,19	29,08

Fonte: O Autor (2023).

*Tempo de execução até a ação de algum critério de parada.

Tabela 12 – Resultados descritos na literatura para o dimensionamento ótimo da *Rural Network*


Autores	Método	Melhor Custo (10⁶ \$)
Marchi et al. (2014)	<i>Differential evolution</i>	31,22
Bi, Dandy e Maier (2015)	<i>Differential evolution</i>	35,17
Bi, Xu e Wang (2020)	<i>Differential evolution</i>	30,99
Bi, Xu e Wang (2020)	<i>Ant Colony Optimization</i>	36,74
PSO convencional		46,45
H-PSOTS		35,68
PSO-RC		37,43

Fonte: O Autor (2023).

Tanto o PSO-RC, como o H-PSOTS atingiram valores próximos ao melhor valor ótimo presente na literatura (\$30,99 milhões) obtido por Bi, Xu e Wang (2020) utilizando o *Differential Evolution*, em tempos de processamento menores em relação ao PSO convencional. Vale destacar que muitos autores não disponibilizam o tempo de execução para os resultados ótimos obtidos, além disso, sabe-se que as condições computacionais variam com o tempo e disponibilidade. Porém, muitos desses resultados de otimização são obtidos sob avaliação de elevados conjunto-soluções em um denso número de iterações ou evoluções, como é o caso de Bi, Xu e Wang (2020), com o algoritmo evolutivo, *Differential evolution*. Para esses autores chegassem ao valor de US\$ 30,99 milhões, avaliaram 1000 soluções (ou indivíduos) durante 10.000 iterações (ou gerações).


Segue apresentado na Figura 27 o esquema de diâmetros da rede otimizada para o melhor custo encontrado (H-PSOTS), seguido das pressões nodais desta rede, na Figura 28.

Figura 27 – Diâmetros otimizados da *Rural Network* determinados pelo H-PSOTS



Fonte: O Autor (2023).

Figura 28 – Pressões nodais da *Rural Network* determinados pelo H-PSOTS



Fonte: O Autor (2023).

Os modelos propostos neste trabalho demonstraram melhoria enfática em relação ao método convencional, tanto na redução da variação dos resultados ao longo das simulações, como na qualidade da resposta apresentada. Assim, estes métodos seguem como alternativas

eficientes, substituindo o processo convencional de programação matemática e com alta variabilidade da resposta obtida.

Fica claro, com nesse exemplo proposto, que esses modelos trazem um conjunto de soluções que satisfazem as demandas e as pressões mínimas com um custo mínimo viável e em um tempo de processamento aceitável. Tornando-as opções de escolha aos projetistas que atrelam outros critérios a tomada de decisão (por exemplo, possibilidades de ampliação, flexibilidade e facilidade de operação, e menor variabilidade).

5.4 REDE PANELAS

A adoção da Rede Pannelas como estudo de caso promove a aplicação prática dos modelos em um caso real. Esta rede está implantada e foi adaptada com a atualização das demandas com base nas exigências atuais. Tal caso real enriquece esse trabalho, mostrando a importância e a devida aplicabilidade do modelo de otimização, além de servir com mais um exemplo prático de aplicação pela comunidade científica.

A emancipação política de Pannelas ocorreu a mais de 100 anos. A cidade possui uma área aproximada de 370 km² e uma população de aproximadamente 26 mil habitantes, segundo o censo do IBGE de 2010 (IBGE, 2023). É apresentado na Figura 29 a localização da cidade em estudo em imagem de satélite.

Figura 29 – Localização da cidade de Pannelas-PE para o estudo da rede real- a ser testada



Fonte: Adaptado de Google Earth (2023).

A Rede Pannelas possui um total de 646 trechos de tubulação com 2 reservatórios para abastecimento, estando um na cota 577 m e o outro na cota 557 m. Este exemplo foi escolhido devido ao elevado número de trechos e traçado complexo, como pode ser visto em seu layout na Figura 30, tornando esse estudo desafiador para o método proposto neste trabalho. A pressão mínima dinâmica adotada no estudo da Rede Pannelas é de 6 mca. Por esse problema possuir 8 possíveis diâmetros disponíveis para o dimensionamento (Tabela 14) em 646 trechos de tubulação da rede, o problema terá, neste caso, 8^{646} soluções a serem investigadas. Os valores presentes na Tabela 14, foram obtidos pelo Sistema Nacional de Pesquisa de Custos e Índices da Construção Civil (SINAPI) além de valores estimados em análise de mercado.

Figura 30 – Rede de distribuição de água da Rede Pannelas



Fonte: O Autor (2023).

Tabela 13 – Custos dos tubos de PVC PBA e PVC DEFoFo (Rede Panelas)

Diâmetro nominal (DN)	Diâmetro interno (mm)	Custo de implantação (novo trecho) (R\$ /m)
50	53,4	35,14
75	75,6	55,44
100	108,4	69,87
150	156,4	145,20
200	204,2	225,01
250	252,0	345,21
300	299,8	409,45
350	347,6	545,10
400	394,6	670,65


Fonte: CTTIGRE (2023).

A fórmula adotada para o cálculo da perda de carga foi a de Hazen-Williams com o valor de α igual a 10,6792 (valor utilizado no Epanet versão 2.00.12) e coeficiente de rugosidade igual a 130.

Atualmente algumas melhorias encontram-se em andamento nesta rede, estando muitos trechos duplicados, devido ao aumento de demanda em decorrência ao contínuo crescimento da cidade, muitas executadas em novos ramos.

Seguindo o proposto neste trabalho, foram realizadas 20 simulações com o enxame de 226 partículas (~35% do número de trechos) nos algoritmos, PSO convencional e H-PSOTS. Para o PSO-RC, foram 149 partículas (~23% do número de trechos). Na Figura 31 é apresentado a variação dos resultados encontrados pelos algoritmos para esta rede.

Figura 31 – Variação do custo obtidos no PSO convencional, HPSOTS e PSO-RC para a Rede Painelas




Fonte: O Autor (2023).

A variação de resultados apresentado por todos os algoritmos, denotam certa complexidade resolutive dessa rede, como visto, na *Rural Network*, permanecendo a maior variação com o PSO convencional e a menor com o PSO-RC.

Na Figura 32, segue a representação gráfica da evolução do menor custo encontrado nas simulações realizadas ao longo dos processos de otimização para os algoritmos em função do número de iterações. Nesta figura, para o PSO-RC, encontra-se o número de iterações representada no eixo das abcissas de forma acumulada a cada ciclo e o valor do custo representado é somente o valor da *GBest* das partículas do enxame com exceção da *Memory Particle*.

Figura 32 – Evolução do custo ao longo dos processos de otimização para a Rede Pannelas



Fonte: O Autor (2023).

É apresentado na Tabela 15, um resumo dos resultados obtidos para os modelos aplicados nesta rede. O tempo de execução corresponde ao valor médio das simulações realizadas.

Tabela 14 – Resultados da aplicação do PSO convencional, H-PSOTS e PSO-RC na Rede Pannelas

Método de otimização	Melhor solução (10 ⁶ R\$)	Pior solução (10 ⁶ R\$)	Média das soluções (10 ⁶ R\$)	Desvio padrão	Tempo de execução (min.) *	Pressão mínima (mca)
PSO conv.	1,652	2,945	2,154	0,349	60,21	6,05
H-PSOTS	1,050	1,687	1,399	0,234	40,88	6,03
PSO-RC	1,145	1,510	1,286	0,089	32,14	6,02

Fonte: O Autor (2023).

*Tempo de execução até a ação de algum critério de parada.

A complexidade resolutive desta rede torna o seu tempo de execução superior ao da *Rural Network*, inclusive devido ao maior número de trechos de tubulação e consequente número de partículas do enxame aplicado. Essa complexidade é fruto da existência de muitos ramos na rede, elevado número de diâmetros disponíveis para o seu dimensionamento e traçado complexo, com grandes números de ramos e malhas.

Similar ao ocorrido nas demais redes de grande porte, o PSO convencional apresentou o maior tempo de execução convergindo para um ótimo local, devido ao aumento do enxame do algoritmo, em resposta ao elevado número de trechos desta rede, dificultando a ação do critério de parada TI, pois, como destacado, as partículas deste algoritmo convencional podem retornar a posições já visitadas, permanecendo-as na simulação com sutis alterações do resultado ótimo.

Já está no tempo de execução do PSO-RC, permanece o menor, mesmo com um maior número de iterações. Isso ocorre devido a redução do enxame utilizado por modelo e melhor direcionamento das partículas a cada ciclo, devido a *Memory Particle*. É importante destacar que, a inserção do critério TC reduz o tempo de execução a cada novo ciclo, dando maior celeridade ao processo de otimização deste modelo.

Ainda assim, tanto nesse exemplo como nos demais exemplos anteriores, o algoritmo híbrido apresentou a melhor solução, mesmo com certa variação entre os resultados encontrados em uma sequência de simulações. Mostrando que a inserção do TS ao PSO, força a exploração local desse algoritmo, permitindo uma maior diversificação da sua resposta, conseguindo alcançar os melhores resultados. Porém, como esse resultado ótimo não se repete com frequência, nota-se a importância da formação inicial do enxame, que por sua vez, a depender da região em que ele abranja inicialmente, direcionará melhor as partículas a ótimos globais.

Com isso, nas Figuras 31 e 32 estão apresentadas o esquema dos diâmetros da rede otimizada e as pressões para o menor custo encontrado, respectivamente.

Figura 33 – Diâmetros otimizados da Rede Panelas determinados pelo H-PSOTS



Fonte: O Autor (2023).

Figura 34 – Pressões nodais da Rede Panelas determinados pelo H-PSOTS



Fonte: O Autor (2023).

Essa rede segue como uma nova proposta singular para o estudo de otimização de projetos de dimensionamento ótimo, pois suas particularidades denotam a sua complexidade resolutiva, destacando-a nesse tipo de cenário com uma rede de desafiadora e promissora.

6 CONCLUSÃO

Com base nos resultados obtidos, é possível concluir que os objetivos propostos foram alcançados, uma vez que os dois modelos desenvolvidos demonstraram melhorias significativas na performance do processo de otimização voltado a projeto de rede de distribuição de água. Além disso, é importante destacar que o PSO vem se destacando cada vez mais na área de recursos hídricos, devido à sua capacidade de encontrar soluções efetivas para problemas complexos, como o projeto de redes de distribuição de água. Os resultados deste trabalho reforçam essa tendência e indicam que o uso de algoritmos de otimização, como o PSO-RC e o H-PSOTS, pode ser uma solução viável e eficiente para problemas de projeto em sistemas de distribuição de água e outros sistemas complexos.

O algoritmo híbrido H-PSOTS, em análise para um número de partículas do enxame semelhante ao PSO convencional, mostrou-se eficaz na redução de movimentos repetitivos das partículas durante a simulação, o que foi alcançado através da análise das posições alcançadas pelas partículas. Como resultado, foi possível reduzir significativamente o número de cálculos envolvidos durante o processo de otimização, o que consequentemente diminuiu o custo computacional e resultou em tempos de processamento inferiores ao PSO convencional, cerca de 54% para a *Balerma Network* e 32% para Rede Panelas, por exemplo. Além disso, a análise dos resultados também evidenciou que a capacidade de exploração local do algoritmo aumentou significativamente devido ao aumento da diversificação das soluções encontradas. Isso possibilitou ao modelo híbrido alcançar os melhores resultados em todas as redes de distribuição de água estudadas.

O PSO-RC mostrou-se eficaz na exploração global do algoritmo convencional, graças à sua abordagem de reinicialização e formação do enxame inicial, que direciona a otimização as proximidades do ótimo global. Segundo a análise de sensibilidade realizada, o PSO-RC demonstrou efetividade de resposta com uma redução de 38% no número de partículas do enxame em relação ao definido para o PSO convencional e o modelo híbrido. Devido a esse enxame inferior, esse modelo apresentou menor tempo de execução nas redes de maior complexidade. Como exemplo, tem-se a análise da *Belarma Network*, onde essa redução foi de 63,6% em relação ao PSO convencional. Ademais, em todas as redes estudadas, o PSO-RC apresentou melhor resultado ótimo em relação a esse algoritmo.

Ainda em análise dos resultados obtidos pelo PSO-RC, é possível concluir que a metodologia proposta, com a inserção da *Memory Particle*, proporcionou soluções satisfatórias em todas as simulações, com menor variação da resposta final e menor

necessidade de repetição de simulação, com pode ser visto em todos os desvios padrão apresentados. Essa redução, para a Rede Panela, por exemplo, correspondeu a 47% em relação ao PSO convencional e a 21% em relação ao H-PSOTS. Isso sugere uma redução no custo computacional, uma vez que é possível reduzir o número de tentativas de simulação através desse aperfeiçoamento de busca. Em resumo, o PSO-RC apresentou uma abordagem promissora para o projeto de rede de distribuição de água, com potencial de aplicação em problemas similares em outros contextos

Para situações em que os problemas possuem menor complexidade, como visto em análise feita na *Hanoi Network*, os enxames aplicados nas simulações são reduzidos e de valores próximos, com isso, ambos modelos propostos apresentaram tempo de execução superiores ao PSO convencional em resposta a maior exploração proporcionada por esses algoritmos. No entanto, alcançaram o valor de ótimo global descrito na literatura (\$6,081 milhões), diferentemente do PSO convencional que não alcançou esse resultado (\$6,151 milhões). Mesmo assim, é válido destacar que o tempo de processamento desses algoritmos, em todas as simulações realizadas nesta rede foram inferiores a 3 min.

Com isso, é possível concluir que o PSO convencional apresentou o maior tempo de processamento em resposta ao aumento do enxame de aplicação. Como esse algoritmo permite que as partículas retornem a posições já visitadas, dificulta a ação dos critérios de parada adotados (Tolerância de Iteração), devido a sutis variações no custo ótimo ao longo das iterações, quase sempre direcionando o algoritmo a mínimos locais. Em problemas menores, esse tempo de execução diminui em relação aos outros modelos testados, devido à diminuição do enxame e melhor atuação do critério de parada, uma vez que enxames menores convergem mais rapidamente em ótimos locais. Para que houvesse maior varredura do espaço de busca, o PSO convencional necessitaria de grandes enxames, o que resultariam em um aumento considerável do custo computacional e ainda haveria a possibilidade de convergência prematura do algoritmo, necessitando reiniciá-lo. Como o algoritmo convencional perde as informações da simulação anterior, a cada nova reinicialização, não é garantido a sua convergência em um resultado melhor que o já alcançado.

Apesar de ambas as metodologias propostas não alcançarem os melhores ótimos relatados na literatura para todas as redes de referência, obtiveram notória efetividade em relação ao PSO convencional com o mesmo ou menor número de partículas e menor custo computacional.

A efetividade do PSO-RC e do algoritmo híbrido H-PSOTS na otimização do projeto de rede de distribuição de água foi comprovada, mostrando potencial para aplicação em

problemas similares. Ambos melhoraram significativamente a resposta apresentada, encontrando soluções efetivas com menor variabilidade e em tempo de execução razoável. Os resultados são promissores para a aplicação na otimização de sistemas complexos, tornando-se ferramentas eficientes de auxílio aos projetistas na tomada de decisão.

Este trabalho ainda afirma que ambas as metodologias se complementam, propondo para estudo posteriores, um novo modelo baseado nas duas propostas dessa Tese. Cujas finalidades são a melhoria da exploração global e menor variabilidade de resposta com o PSO-RC e melhoria da exploração local (refinamento da resposta ótima encontrada) com o H-PSOTS. Esse novo modelo poderá ser chamado de H-PSOTS-RC.

REFERÊNCIAS

- ALI, S.; KHAN, S. A cauchy swarm optimization algorithm for global numerical optimization. **Applied Soft Computing**, 59, 806-821, 2018.
- ALINAGHIAN, M.; GHAZANFARI, M.; NOROUZI, N.; NOURALIZADEH, H. A Novel Model for the Time Dependent Competitive Vehicle Routing Problem: Modified Random Topology Particle Swarm Optimization. **Networks and Spatial Economics**, 1-27, 2017.
- ALIZADEH, Z.; YAZDI, J.; MOHAMMADIUN, S.; HEWAGE, K.; SADIQ, R. Evaluation of data driven models for pipe burst prediction in urban water distribution systems. **Urban Water Journal**, v. 16, n. 2, p. 136-145, 2019.
- ALPEROVITS, E.; SHAMIR, U. Design of optimal water distribution systems. **Water Resources Research**, 13(6), 885-900, 1977.
- ARAÚJO, A. A.; Q. LIMA, A. R. B.; OLIVEIRA, S. H.; NASCIMENTO, R. S., OLIVEIRA, R. Loss of water and restoration of water supply systems. **Brazilian Journal of Development**, v. 5, n. 12, p. 33428-33437, 2019.
- BEZERRA, S. T. M.; MACÊDO, J. E. S. Dimensionamento de redes de distribuição de água malhadas via otimização por enxame de partículas. **IRRIGA**, v. 23, n. 4, p. 798-817, 2018.
- BHAVE, P. R.; SONAK, V. V. A critical study of the linear programming gradient method for optimal design of water supply networks. **Water Resources Research**, v. 28, n. 6, p. 1577-1584. New York, NY, USA, 1992.
- BI, W.; DANDY, G. C.; MAIER, H. R. Improved genetic algorithm optimization of water distribution system design by incorporating domain knowledge. **Environmental Modelling e Software**, 69, 370-381, 2015.
- BI, W.; XU, Y.; WANG, H. Comparison of searching behavior of three evolutionary algorithms applied to water distribution system design optimization. **Water (Basel)**, 12(3), 695, 2020.
- BILAL; PANT, M. Parameter Optimization of Water Distribution Network—A Hybrid Metaheuristic Approach. **Materials and Manufacturing Processes**, v. 35, n. 6, p. 737-749, 2020.
- BRAGALLI, C.; D'AMBROSIO, C.; LEE, J.; LODI, A.; TOTH, P. Optimizing the design of water distribution networks using mathematical optimization. In: **Case studies in operations research**. Springer, New York, NY, p. 183-198, 2015.
- CASTRO, R. P. G.; SILVA, R. A. A hybrid swarm optimization algorithm. **Proceedings of the 14th International Conference on Artificial Intelligence**, vol. 1, pp. 523-530, 2008.
- CTTIGRE, Catálogo Técnico Tigre. **Tigre S/A**. Disponível em <<https://www.tigre.com.br/catalogos-tecnicos>>. Acessado em 29 de abril de 2023.

CHEN, Y.; YAN, J.; SAREH, P.; FENG, J. Feasible prestress modes for cable-strut structures with multiple self-stress states using particle swarm optimization. **Journal of Computing in Civil Engineering**, v. 34, n. 3, p. 04020003, 2020.

CHOI, J. H.; LEE, J. D.; YOO, H. M.; KIM, D. G. Improving the Quality of Pareto Optimal Solutions in Water Distribution Network Design. **Journal of Water Resources Planning and Management**, v. 143, n. 8, p. 04017036, 2017.

CHU, C.W.; LIN, M.D.; LIU, G. F.; SUNG, Y. H. Application of immune algorithms on solving minimum-cost problem of water distribution *network*. **Mathematical and Computer Modelling**, v. 48, n. 11-12, p. 1888-1900, 2008.

COELLO, C. A.; ZITZLER, E. Multi-Objective Evolutionary Algorithms. **Handbook of Nature-Inspired and Innovative Computing**, Eds., 2021, pp. 571-597, 2021.

COSTA, L.H.M.; CASTRO, M.A.H.; ARAÚJO, J.K. Dimensionamento econômico de redes de abastecimento de água utilizando o EPANET e a linguagem Delphi. In: **VI Seminário Iberoamericano sobre Sistemas de Abastecimento Urbano de Água**, João Pessoa, Brasil, Junho, 2006.

CUNHA, M. D. C.; SOUSA, J. Water distribution *network* design optimization: simulated annealing approach. **Journal of water resources planning and management**, 125(4), 215-221, 1999.

DANDY, G. C.; SIMPSON A. R.; MURPHY L. J. An improved genetic algorithm for pipe *network* optimization, **Water Resour. Res.**, 32(2), 449–457, 1996.

DAS, P. K.; JENA, P. K. Multi-robot path planning using improved particle swarm optimization algorithm through novel evolutionary operators. **Applied Soft Computing**, v. 92, p. 106312, 2020.

DELICE, Y.; AYDOĞAN, E. K.; ÖZCAN, U.; İLKAY, M. S. A modified particle swarm optimization algorithm to mixed-model two-sided assembly line balancing. **Journal of Intelligent Manufacturing**, 28(1), 23-36, 2017.

DORIGO, M.; MANIEZZO V.; COLORNI A. The ant system: optimization by a colony of cooperating agents. **IEEE Transactions on Systems, Man, and Cybernetics**. Part B, Cybernetics 26(1): 29-41, 1996.

DU, H.; LIU, D.; ZHANG, M. A hybrid algorithm based on particle swarm optimization and artificial immune for an assembly job shop scheduling problem. **Mathematical problems in engineering**, v. 2016, 2016.

EBERHART, R. C.; SHI, Y. Comparing inertia weights and constriction factors in particle swarm optimization. In: **Proceedings of the 2000 congress on evolutionary computation. CEC00 (Cat. No. 00TH8512)**. IEEE p. 84-88, 2000.

EL-GHANDOUR, H. A.; ELBELTAGI, E. Comparison of five evolutionary algorithms for optimization of water distribution networks. **Journal of Computing in Civil Engineering**, v. 32, n. 1, p. 04017066, 2018.

ESHAGHZADEH, A.; HAJIAN, A. 2-D gravity inverse modelling of anticlinal structure using improved particle swarm optimization (IPSO). **Arabian Journal of Geosciences**, v. 14, n. 14, p. 1-10, 2021.

EUSUFF, M. M.; LANSEY, K. E. Optimization of water distribution *network* design using the shuffled frog leaping algorithm. **Journal of Water Resources Planning and Management**, 129(3), 210-225, 2003.

FALLAH, H.; KISI, O.; KIM, S.; REZAIE-BALF, M. A new optimization approach for the least-cost design of water distribution networks: improved crow search algorithm. **Water Resources Management**, v. 33, n. 10, p. 3595-3613, 2019.

FARIAS, G.A.; NASCIMENTO, L.C.; de OLIVEIRA, F.G.; de SOUZA, M.A.; de SOUZA, J.F.; de ALMEIDA, A.S.; PÁDUA, D.M. Hydrological modeling of the water distribution *network* for water quality assessment. **Science of The Total Environment**, 767, 145253, 2021.

FREY, J.; DANDY, G. C.; MURPHY, L. J. A new breakthrough technology optimizes distribution system design and operation. In: **American Water Works Association Distribution System Symposium: Nashville, Tennessee, USA**. 1995.

FUJIWARA, O.; KHANG, B. A two-phase decomposition method for optimal design of looped water distribution networks. **Water resources research**, v. 26, n. 4, p. 539-549, 1990.

GESSLER, J. Optimization of pipe networks. International Symposium on Urban Hidrology, **Hydraulics and Sediment Control**, University of Kentucky, Lexington, Kentucky, 1982.

GIACOMINI, T. R.; DIAS, P. L. G.; CARVALHO, F. A. B. Sistema de abastecimento de água: principais componentes e fatores críticos. **Engenharia Sanitária e Ambiental**, 25(2), 240–249, 2020.

GLOVER, F.; LAGUNA, M. Tabu search. In: **Handbook of combinatorial optimization**. Springer, Boston, MA, p. 2093-2229, 1998.

GLOVER, Fred. Tabu search—part I. **ORSA Journal on computing**, v. 1, n. 3, p. 190-206, 1989.

GLOVER, Fred. Tabu search—part II. **ORSA Journal on computing**, v. 2, n. 1, p. 4-32, 1990.

GOMES H.; FORMIGA K. T. M. PNL2000: Método prático de dimensionamento econômico de água. **Revista Brasileira de Recursos Hídricos**. Porto Alegre: ABRH 6 (4) 91-108, 2001.

GOMES, H. P.; BEZERRA, S. T. M. Reabilitação de redes coletivas de sistemas pressurizados de irrigação. **Revista Brasileira de Engenharia Agrícola Ambiental**, v. 9, n. 4, p. 457-463, 2005.

GOMES, H. P.; BEZERRA, S. T. M.; CARVALHO, P. S. O.; SALVINO, M. M. Optimal dimensioning model of water distribution systems. **WATER SA**, v. 35, p. 421-432, 2009.

GOMES, H. P.; BEZERRA, S. T. M.; CARVALHO, P. S. O.; SALVINO, M. M. Optimal Dimensioning Model of Water Distribution Systems. **Water S. A.**, v. 35, p. 421-432, 2009.

GONZALEZ, D.; CRUZ, O. P.; GÓMEZ, J. G. Optimization Challenges and Resolution Techniques. **Computer Science Journal**, 7(2), 80-91, 2020.

GRANADOS, A. Infraestructuras de regadíos – redes colectivas de riego a presión. Servicio de Publicación de **E. T. S. I.** de Caminos de La Universidad Politécnica de Madrid, España, 1990.

GUTIERREZ, J. C. T.; VANELLI, F. M.; BRAVO, J. M. Aplicação de um novo critério de parada para algoritmos evolucionários de otimização multi objetivo na calibração automática de modelos hidrológicos. **Simpósio Brasileiro de Recursos Hídricos (23.: Foz do Iguaçu, 2019). Anais [recurso eletrônico]. Porto Alegre: ABRH, 2019, 2019.**

HERNÁNDEZ-DÍAZ, M. Physical System Optimization: Basic Concepts. **Latin American Journal of Engineering**, 2(1), 17–27, 2017.

HOFFMAN, P. D.; CAVES, K. Otimização de redes neurais: Conceitos e técnicas. **IEEE Transactions on Neural Networks and Learning Systems**, 28(12), 2980-2992, 2017.

HOLLAND, J.H. Adaptation in Natural and Artificial Systems. **University of Michigan Press**, Ann Arbor, Michigan, 1975.

IBGE, INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Censo Brasileiro de 2010. **Rio de Janeiro**. Disponível em <<http://www.ibge.com.br/hsknofnonfd lkfndnfhs>>. Acessado em 18 de fevereiro de 2023.

INCE, D. Systems Design: Building Intelligent Solutions. **Computers and Education**, 14(1), 23-32, 2010.

ISHIBUCHI, H.; NOJIMA, Y.; TANAKA, S. A Survey of Evolutionary Algorithms for Optimization, **Artificial Intelligence Review**, vol. 40, no. 1, pp. 33–79, Nov. 2013.

JAFARI, A. System Design: A Practical Approach to System Development. **International Journal of Computer Applications**, 152(1), 1-8, 2018.

JAMIL, A. Redes Ramificadas: Fundamentos, Dimensionamento e Aplicações. **Revista Iberoamericana de Ingeniería Química**, 19 (2), 218-252, 2020.

JHA, P.; PRAKASH, S. A Hybrid Intelligent System for Automatic Detection of Diabetic Retinopathy Using Image Processing. **International Journal of Engineering & Technology**, 9(3.3), 441-446, 2020.

JIANG, Y.; LIANG, T.; ZHANG, J. A damping swarm optimization algorithm for global numerical optimization. **Swarm and Evolutionary Computation**, 51, 1-17, 2020.

JUANG, Y. T.; TUNG, S. L.; CHIU, H. C. Adaptive fuzzy particle swarm optimization for global optimization of multimodal functions. **Information Sciences**, v. 181, n. 20, p. 4539-4549, 2011.

KADU, M.S.; GUPTA, R., BHAVE, P.R. **Optimal design of water networks using a modified genetic algorithm with reduction in search space**. J. Water Resour. Plan. Manag, 134 (2), 147-160, 2008.

KENNEDY, J.; EBERHART, R. C. Particle Swam Optimization. In: **IEEE International Conference on Neural Networks**, IEEE Service Center, Piscataway, NJ, N: 1942-1948, Path, Australia, 1995.

KHAN, J. M.; IQBAL, M. Design and Cost Analysis of Water Distribution Network Using Hydraulic Modeling. **Water Resources Management**, 33(13), 4387–4403, 2019.

KING, M. L. **A Martin Luther King treasury**. 1. ed. Geórgia: Educational Heritage Inc., 1968. 352p.

LANSEY, K. E.; MAYS, L. W. Optimization model for water distribution system design. **Journal of Hydraulic Engineering**, 115(10): 1401-1418, 1989.

LEE, H. M.; YOO, D. G.; SADOLLAH, A.; KIM, J. H. Optimal cost design of water distribution networks using a decomposition approach. **Engineering Optimization**, 48(12), 2141-2156, 2016.

LEMOES, E. S.; BARBOSA, J. T.; LOPES, W. A. Sistemas de abastecimento de água: Planejamento, projeto, operação e manutenção. São Paulo: **Spring**. 2a edição, 2020.

LI, X.; GAO, L. An effective hybrid genetic algorithm and tabu search for flexible job shop scheduling problem. **International Journal of Production Economics**, v. 174, p. 93-110, 2016.

LIMA, R. M.; SILVA, E. R.; SOUZA, L. M. Optimization Model for Water Distribution Network Design. Brazilian Journal of Regional Development and Management, 12(3), 582-596, 2016.

LIONG, S. Y.; ATIQUZZAMAN, M. Optimal design of water distribution *network* using shuffled complex evolution. **Journal of the Institution of Engineers**, Singapore, 44(1), 93-107, 2004.

LIU, Y.; LI, G. Metaheuristics: a survey from a multi-disciplinary perspective. **Swarm and Evolutionary Computation**, 27, 1-30, 2016.

LUO, Q.; CHEN, J.; LI, X. An ant colony optimization hybridized genetic algorithm for the traveling salesman problem. **Applied Mathematics and Computation**, 180(2), 956-970, 2006.

LUO, Q.; YI, D. A co-evolving framework for robust particle swarm optimization. **Applied Mathematics and Computation**, 199(2), 611-622, 2008.

MACÊDO, J. E. S.; AZEVEDO, J. R. G.; BEZERRA, S de Tarso Marques. Dimensionamento ótimo de redes de distribuição de água de grande porte via particle swarm optimization e tabu search. **RBRH**, v. 26, 2021.

- MAHAPATRA, P. K.; GANGULI, S.; KUMAR, A. A hybrid particle swarm optimization and artificial immune system algorithm for image enhancement. **Soft computing**, v. 19, n. 8, p. 2101-2109, 2015.
- MAIER, H. R.; KAPELAN, Z.; KASPRZYK, J.; KOLLAT, J.; MATOTT, L. S.; CUNHA, M. C.; OSTFELD, A. Evolutionary algorithms and other metaheuristics in water resources: Current status, research challenges and future directions. **Environmental Modelling e Software**, 62, 271-299, 2014.
- MAIER, H. R.; SIMPSON, A. R.; ZECCHIN, A. C.; FOONG, W. K., PHANG, K. Y., SEAH, H. Y.; TAN, C. L. Ant colony optimization for design of water distribution systems. **Journal of water resources planning and management**, ASCE, 129(3), 200-209, 2003.
- MANOLIS, A.; SIDIROPOULOS, E.; EVANGELIDES, C. Targeted path search algorithm for optimization of water distribution networks, *Urban Water Journal*, 18:3, 195-207, 2021.
- MARCHI, A.; DANDY, G.; WILKINS, A.; ROHRLACH, H. Methodology for comparing evolutionary algorithms for optimization of water distribution systems. **Journal of water resources planning and management**, v. 140, n. 1, p. 22-31, 2014.
- MARZOUKI, B.; DRISS, O. B.; GHÉDIRA, K. Multi-agent model based on combination of chemical reaction optimisation metaheuristic with Tabu search for flexible job shop scheduling problem. **International Journal of Intelligent Engineering Informatics**, v. 6, n. 3-4, p. 242-265, 2018.
- MAZUMDER, R. K.; SALMAN, A. M.; LI, Y.; YU, X. Reliability Assessment of Corroded Water Distribution Networks. In: **Pipelines 2019: Condition Assessment, Construction, and Rehabilitation**. Reston, VA: American Society of Civil Engineers, p. 343-353, 2019.
- MOHAMAD, R.; NEZAMABADI-POUR, H. Dynamic hybrid swarm optimization algorithm for global numerical optimization. **Applied Soft Computing**, 53, 688-705, 2017.
- MOKARRAM, V.; BANAN, M. R. A new PSO-based algorithm for multi-objective optimization with continuous and discrete design variables. **Structural and Multidisciplinary Optimization**, v. 57, n. 2, p. 509-533, 2018.
- MONSEF, H.; NAGHASHZADEGAN, M.; JAMALI, A.; FARMANI, R. Comparison of evolutionary multi objective optimization algorithms in optimum design of water distribution network. **Ain Shams Engineering Journal**, v. 10, n. 1, p. 103-111, 2019.
- MONTALVO, I.; IZQUIERDO, J.; PÉREZ, R.; TUNG, M.M. Particle Swarm Optimization applied to the design of water supply systems. **Computers and Mathematics with Applications**, 56(3) 777-784, 2008.
- MORA-MELIA, D.; IGLESIAS-REY, P. L.; MARTINEZ-SOLANO, F. J.; BALLESTEROS-PÉREZ, P. Efficiency of evolutionary algorithms in water network pipe sizing. **Water resources management**, 29(13), 4817-4831, 2015.
- MORGAN, D. R.; GOULTER, I. C. Optimal urban water distribution design. **Water Resources Research** 21(5): 642-652, 1985.

NASCIMENTO, D. R.; COSTA, R. N. Uma abordagem baseada em algoritmos evolucionários para otimização de redes de distribuição de água. **Sistemas & Gestão**, 13(2), 342-355, 2018.

NESTEROV, Y. *Convex Nonlinear Optimization: Modern Algorithms and Applications*. Nova Iorque: Springer, v 1, 1-280, 2019.

OLIVAS, F.; VALDEZ, F.; CASTILLO, O.; GONZALEZ, C. I.; MARTINEZ, G.; MELIN, P. Ant colony optimization with dynamic parameter adaptation based on interval type-2 fuzzy logic systems. **Applied Soft Computing**, v. 53, p. 74-87, 2017.

OSABA, E.; VILLAR-RODRIGUEZ, E.; DEL SER, J.; NEBRO, A. J.; MOLINA, D.; LATORRE, A.; HERRERA, F. A tutorial on the design, experimentation and application of metaheuristic algorithms to real-world optimization problems. **Swarm and Evolutionary Computation**, 64, 100888, 2021.

PEREIRA, L. L. M.; SANTOS, D. C., MORAES, M. H. M.; GONÇALVES FILHO, G. M.; ANCIOTO FILHO, E. M.; PEREIRA JUNIOR, W. M.; DANTAS, M. J. P. Estudo de Sensibilidade do Algoritmo de Colônia de Vagalumes para um Problema de Engenharia Envolvendo Dimensionamento de Treliças. **TEMA** (São Carlos), v. 21, p. 583-599, 2020.

PEREIRA, M. S.; ALMEIDA, M. O Dimensionamento de Redes de Distribuição de Água: Abordagem Metodológica. **Ambiente Construído**, v. 19, n. 1, p. 1-14, 2020.

PRAJAPATI, V. K.; JAIN, M.; CHOUHAN, L. Tabu search algorithm (TSA): A comprehensive survey. In: **2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning and Internet of Things (ICETCE)**. IEEE, p. 1-8, 2020.

RAJEEV, B. P.; SHARMA, M. P.; SHARMA, P. Hybrid genetic algorithm: A new approach to solve optimization problems. **Computers & Industrial Engineering**, 35(3), 539-545, 1998.

RECA, J.; MARTÍNEZ, J. Genetic algorithms for the design of looped irrigation water distribution networks. **Water Resour. Res.** 42 (5), W05416, 2006.

RECA, J.; MARTÍNEZ, J.; GIL, C.; BAÑOS, R. Application of several meta-heuristic techniques to the optimization of real looped water distribution networks. **Water Resources Management**, v. 22, n. 10, p. 1367-1379, 2008.

resolution. **Computers & Chemical Engineering**, v. 96, n. 4, p. 169-182, 2017.

ROSSMAN, L.; WOO, H.; TRYBY, M.; SHANG, F.; JUNKE, R.; HAXTON, T. **Epanet 2.2 user manual**. Cincinnati: EPA, 2020.

ROSSMAN, Lewis A. **EPANET 2. Users manual**. US Environmental Protection Agency (EPA), USA, 2000.

ROSSMAN, Lewis A. **EPANET. Users manual**. US Environmental Protection Agency (EPA), USA, 1994.

SALDARRIAGA, J.; PÁEZ, D.; SALCEDO, C.; CUERO, P.; LÓPEZ, L.L.; LEÓN, N.; CELEITA, D. A direct approach for the near-optimal design of water distribution networks based on power use. **Water**, 12(4), 1037, 2020.

SARBU, I.; POPA-ALBU, S. Optimization of urban water distribution networks using heuristic methods: an overview. **Water International**, v. 48, n. 1, p. 120-148, 2023.

SARDINHA, W. C.; JUNIOR, F. V. S. Estudo comparativo dos custos da implantação de rede de abastecimento de água no distrito de Luzimangues/TO. **Technology Sciences**, v. 2, n. 2, p. 30-37, 2020.

SAVIC, D. A.; WALTERS, G. A. – Genetic algorithm for least-cost design of water distribution networks. **Journal of Water Resources Planning and Management**, v. 123, n. 2, p. 67-77. 1997.

SCHAAKE JR, J. C.; LAI, D. Linear programming and dynamic programming application to water distribution network design. **Department of Civil and Environmental Engineering**, 1969.

SEDKI, A.; OUAZAR, D. Hybrid particle swarm optimization and differential evolution for optimal design of water distribution systems. **Advanced Engineering Informatics**, v. 26, n. 3, p. 582-591, 2012.

SHAH, F. A.; KHAN, S. Weighted hybrid swarm optimization algorithm for global numerical optimization. **Applied Soft Computing**, 44, 1-14, 2016.

SHEIKHOLESAMI, R.; ZECCHIN, A.C.; ZHENG, F.; TALATAHARI, S. A hybrid cuckoo-harmony search algorithm for optimal design of water distribution systems. **Journal of Hydroinformatics**, 18(3), 544-563, 2016.

SHI, Y.; EBERHART, R. C. A modified particle swarm optimizer. In: The 1998 IEEE International Conference on Evolutionary Computation Proceedings, 1998. **IEEE World Congress on Computational Intelligence**. IEEE. p. 69-73, 1998a.

SHI, Y.; EBERHART, R. C. Parameter selection in particle swarm optimization. In: **International Conference on Evolutionary Programming**. Springer, Berlin, Heidelberg, p. 591-600, 1998b.

SILVA, A. L.; FERREIRA, J. C.; STEINER, M. T. A. Approach to vehicle routing with exact, heuristic and environmental procedures: a case study/Abordagem de roteamento de veículos com procedimentos exatos e heurísticos sob uma ótica ambiental: um estudo de caso. **Revista Exacta**, v. 17, n. 1, p. 171-189, 2019.

SILVA, R. C. A. Otimização de redes ramificadas através do método da programação não linear. Dissertação de Mestrado. **Universidade Federal da Paraíba**. Campina Grande, PB, 1997.

SIMPSON, A. R.; DANDY, G. C.; MURPHY, L. J. Genetic algorithms compared to other techniques for pipe optimization. **Journal of Water Resources Planning and Management**, 120(4), 423-443, 1994.

SÖRENSEN, S.D.; RASMUSSEN, S.M.; ANDERSEN, F.A.; LAGESEN, V. Variable neighbourhood search. Berlin, Germany: Springer Science & Business - An experimental study. **Production Engineering**, 19 (3), pp. 393-406, 2009.

SOUSA, J.; CUNHA, M. C. Dimensionamento otimizado de redes malhadas de distribuição de água. **4º Congresso da Água**, "A Água como Recurso Estruturante do Desenvolvimento" Lisboa, 1998.

SUNG, Y. H.; LIN, M. D.; LIN, Y. H.; LIU, Y. L. Tabu search solution of water distribution *network* optimization. **Journal of Environmental Engineering and management**, v. 17, n. 3, p. 177, 2007.

SURCO, D. F.; VECCHI, T. P. B.; RAVAGNANI, M. Optimization of water distribution networks using a modified particle swarm optimization algorithm. **Water Science and Technology: Water Supply**, v. 18, n. 2, p. 660-678, 2018.

SURIBABU, C. R. Differential evolution algorithm for optimal design of water distribution networks. **Journal of Hydroinformatics**, 12(1), 66-82, 2010.

TANYIMBOH, T. T.; SEYOUM, A. G. Design optimization of water distribution networks: real-world case study with penalty-free multi-objective genetic algorithm using pressure-driven simulation. **Water SA**, v. 46, n. 3, p. 465-475, 2020.

TONG, Z.; LI, Y. Uma revisão de técnicas de redução de custo para problemas de programação linear. **Otimização e Engenharia**, 16(4), 719-737, 2015.

TORKOMANY, M. R.; HASSAN, H. S.; SHOUKRY, A.; ABDELRAZEK, A. M.; ELKHOLY, M. An Enhanced Multi- Particle Swarm Optimization in Water Distribution Systems Design. **Water**, v. Objective 13, n. 10, p. 1334, 2021.

TUNG, Y. K. Evaluation of water distribution *network* reliability. **Hydraulics and hydrology in the small computer age**, Lake Buena Vista, Florida, USA, 1985.

UTAMIMA, A.; PRADINA, K. R.; DINI, N. S.; STUDIAWAN, H. Distribution route optimization of gallon water using genetic algorithm and tabu search. **Procedia Computer Science**, v. 72, p. 503-510, 2015.

WALSKI, T. M. Battle of the *network* models: epilogue. **Jornal of Water Resources Planning and Management**, ASCE, v. 113, n.2, p. 191-203. New York, NY, USA, 1987.

WANG, H.; LIANG, M.; SUN, C.; ZHANG, G.; XIE, L. Multiple-strategy learning particle swarm optimization for large-scale optimization problems. **Complex & Intelligent Systems**, v. 7, p. 1-16, 2021.

WANG, Y.; ZHANG, X.; YANG, Y. Hybrid swarm optimization algorithm for global numerical optimization. **Swarm and Evolutionary Computation**, 29, 1-13, 2016.
WEI, Zequn; HAO, Jin-Kao. Kernel based tabu search for the Set-union Knapsack Problem. **Expert Systems with Applications**, v. 165, p. 113802, 2021.

XU, Y.; HE, X. A hybrid tabu search algorithm for the traveling salesman problem. **International Journal of Computers & Industrial Engineering**, 48(1), 174-181, 2005.

YAP, D. F. W.; KOH, S. P.; TIONG, S. K.; PRAJINDRA, S. K. Particle swarm based artificial immune system for multimodal function optimization and engineering application problem. **Trends in Applied Sciences Research**, v. 6, n. 3, p. 282, 2011.

YAZDI, J.; YOO, D. G.; KIM, J. H. Comparative study of multi-objective evolutionary algorithms for hydraulic rehabilitation of urban drainage networks. **Urban Water Journal**, v. 14, n. 5, p. 483-492, 2017.

YEN, G. G.; HE, Z. Performance metric ensemble for multiobjective evolutionary algorithms. **IEEE Transactions on Evolutionary Computation**, v. 18, n. 1, p. 131-144, 2013.

ZANGENEHMADAR, Z.; MOSELHI, O.; GOLNARAGHI, S. Optimized planning of repair works for pipelines in water distribution networks using genetic algorithm. **Engineering Reports**, v. 2, n. 6, p. e12179, 2020.

ZECCHIN, A. C.; SIMPSON, A. R.; MAIER, H. R.; LEONARD, M.; ROBERTS, A. J.; BERRISFORD, M. J. Application of two ant colony optimisation algorithms to water distribution system optimisation. **Mathematical and Computer Modelling**, 44(5), 451-468, 2006.

ZHENG, F.; SIMPSON, A. R.; ZECCHIN, A. C. A combined NLP - differential evolution algorithm approach for the optimization of looped water distribution systems. **Water Resources Research**, 47(8), 2011.

ZHENG, F.; ZECCHIN, A. C.; NEWMAN, J. P.; MAIER, H. R.; DANDY, G. C. An adaptive convergence-trajectory controlled ant colony optimization algorithm with application to water distribution system design problems. **IEEE Transactions on Evolutionary Computation**, 21(5), 773-791, 2017.

ZHENG, Y.; ZHANG, X.; WANG, H.; LI, J. Comparison of six evolutionary algorithms for water distribution *network* design optimization. **Engineering Optimization**, 52(6), 1067-1088, 2020.

ZOU, X.; LIU, H.; ZHANG, H.; CHEN, Y.; Xu, Y. Comparative analysis of evolutionary algorithms for water distribution *network* optimization. **Water Science and Technology: Water Supply**, 19(2), 587-597, 2019.

APÊNDICE A – HYBRID PARTICLE SWARM OPTIMIZATION AND TABU SEARCH FOR THE DESIGN OF LARGE-SCALE WATER DISTRIBUTION NETWORKS



Revista Brasileira de Recursos Hídricos
Brazilian Journal of Water Resources
 Versão On-line ISSN 2318-0331
 RBRH, Porto Alegre, v. 26, e11, 2021
 Scientific/Technical Article

<https://doi.org/10.1590/2318-0331.262120210006>

Hybrid particle swarm optimization and tabu search for the design of large-scale water distribution networks

Dimensionamento ótimo de redes de distribuição de água de grande porte via particle swarm optimization e tabu search

José Eloim Silva de Macêdo¹ , José Roberto Gonçalves de Azevedo¹ & Saulo de Tarso Marques Bezerra²

¹Universidade Federal de Pernambuco, Recife, PE, Brasil

²Universidade Federal de Pernambuco, Caruaru, PE, Brasil

E-mails: eloim.macedo@ufpe.br (JESM), jose.azevedo@ufpe.br (JRG), saulo.tarso@ufpe.br (STMB)

Received: January 08, 2021 - Revised: March 03, 2021 - Accepted: March 10, 2021

ABSTRACT

Water distribution network (WDN) optimization has received special attention from various technicians and researchers, mainly due to its high costs of implementation, operation and maintenance. However, the low computational efficiency of most developed algorithms makes them difficult to apply in large-scale WDN design problems. This article presents a hybrid particle swarm optimization and tabu search (H-PSOTS) algorithm for WDN design. Incorporating tabu search (TS) as a local improvement procedure enables the H-PSOTS algorithm to avoid local optima and show satisfactory performance. Pure particle swarm optimization (PSO) and H-PSOTS algorithms were applied to three benchmark networks proposed in the literature: the Balerna irrigation network, the ZJ network and the Rural network. The hybrid methodology obtained good results when seeking an optimal solution and revealed high computational performance, making it a new option for the optimal design of real water distribution networks.

Keywords: Water distribution systems; Complex networks; Optimization; Hybrid algorithm.

RESUMO

O dimensionamento ótimo de redes de distribuição de água (RDA) tem recebido atenção especial de projetistas e pesquisadores devido, principalmente, aos elevados custos de implantação, operação e manutenção. No entanto, a baixa eficiência computacional da maioria dos algoritmos dificulta a aplicação desses em RDA de grande porte. Diante disto, este artigo apresenta um algoritmo híbrido (H-PSOTS) baseado nos métodos *particle swarm optimization* (PSO) e *tabu search* (TS) para o projeto de RDA. Incorporar a TS, como um procedimento de melhoria da busca local, permite que o algoritmo H-PSOTS evite ótimos locais e apresente um desempenho satisfatório. O PSO padrão e o H-PSOTS foram aplicados a três redes de referência propostas na literatura: *Balerna irrigation network*, *ZJ network* e *Rural network*. O algoritmo híbrido obteve bons resultados na busca pela solução ótima e alto desempenho computacional, tornando-se uma nova opção para o projeto ótimo de redes de distribuição de água reais.

Palavras-chave: Sistemas de distribuição de água; Redes complexas; Otimização; Algoritmo híbrido.



This is an Open Access article distributed under the terms of the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

INTRODUCTION

Water distribution networks (WDNs) are hydraulic systems composed of reservoirs, pumps, pipes, valves, sensors and other accessories designed to transport drinking water with sufficient flow and pressure to meet consumers' water needs continuously and appropriately. WDNs are an important part of the water supply system, mainly due to their high cost of implementation, operation and maintenance.

WDN designers seek to assign pipe diameters to minimize investment costs, including those related to implementing and purchasing materials and equipment. Traditionally, engineers design pipe networks using trial and error guided by experience. However, the state variables of the problem are linked by the mass and energy conservation laws of physics, which make the design of large systems complex and exhaustive.

The term "optimization", present in several engineering studies and projects, refers to the search for the best solution to a problem. WDN design is classified as a large combinatorial discrete nonlinear nondeterministic polynomial-hard (NP-hard) optimization problem (Moosavian & Lence, 2020). Such problems are nonlinear and non-convex, and global optimization techniques cannot usually solve them. Therefore, the development of new models makes a substantial contribution to solving this type of problem (Cassiolato et al., 2020).

Technological evolution has led many researchers to develop and apply evolutionary algorithms to solve WDN design problems. These include ant colony optimization (Zheng et al., 2017; Bahoosh et al., 2019), colliding bodies optimization (Kaveh & Dadras Eslamlou, 2020), differential evolution (Monsef et al., 2019; Chen et al., 2019), genetic algorithm (Reca et al., 2017; Rathi et al., 2020), genetic heritage evolution by stochastic transmission (Bolognesi et al., 2010), harmony search (Choi et al., 2017; Jung et al., 2018), honey-bee mating optimization (Bozorg Haddad et al., 2016), particle swarm optimization (Bezerra & Macêdo, 2018; Monsef et al., 2019), scatter search (Baños et al., 2009), shuffled frog leaping (Mora-Melia et al., 2016), simulated annealing (Cunha & Marques, 2020), soccer league competition (Moosavian & Kasaei Roodsari, 2014) and whale optimization (Ezzeldin & Djebedjian, 2020). However, these mathematical models do not guarantee that the minimum cost solution found is the global optimum, and, although the methods present good solutions, their practical application remains rare.

The evaluation of complex real-world problems using large search spaces is currently the main difficulty addressed in the specialized literature. The characterization of the size of a WDN is dictated by its number of nodes and meshes, due to the growing number of independent and variable equations to be determined during its dimensioning, in addition to the iteration between them, which makes the problem more complex and difficult to solve (Chen et al., 2019). In this context, this work presents a hybrid particle swarm optimization and tabu search (H-PSOTS) algorithm used to design large-scale WDNs. In recent years, the hybridization of these techniques has been applied in several areas (Chentoufi & Ellaia, 2018; Tang & Lee, 2018; Ahmadian et al., 2019; Alharkan et al., 2020; Ebadi & Jafari Navimipour, 2019; Toshev, 2019), but a literature search revealed no such applications to the proposed problem type.

Particle swarm optimization (PSO) is used widely in WDN design problems due to its ease of implementation and the good results reported in the literature. At each iteration of the PSO process, numerous particles explore the search space to find the best results for the objective function. During this process, the particles can resume the positions visited and revisit the positions already reached by other. In large problems, this iterative process results in high computational cost and execution time. Therefore, a tabu search (TS) algorithm was inserted into the PSO process to restrict repetitive movements. The TS algorithm gained popularity in the scientific community as an auxiliary adaptive procedure, as it improves the exploration of local search spaces and facilitates greater solution diversification in the search of the global optimum.

METHOD

The H-PSOTS algorithm was implemented using Matlab software. According to Chandramouli (2019), Matlab is best suited for all mathematical operations and can link external libraries. The EPANET input (.inp) file is first read to create the network model and obtain all network parameters (e.g. layout, node demands, pipe lengths). Matlab was combined with the functions of the EPANET toolkit to simulate the various solutions indicated by the optimization algorithm. On Windows systems, the library is precompiled into a dynamic link library file called EPANET2.dll. All analyses were performed on a personal computer with an Intel Core i7 1.88-GHz processor and 8 GB of RAM.

Optimal design of WDN

In this article, WDN design was formulated as a least-cost optimization problem with a selection of pipe diameters as the decision variables. In general, WDN optimization was defined as follows:

Minimize: Total cost of the WDN

Subject to:

1. Conservation of mass: Inflows and outflows must balance at each node;
2. Conservation of energy: Head loss around a closed loop must be equal zero, and head loss along a path between two reservoirs must be equal to the reservoirs' elevation difference;
3. Minimum pressure requirements: Minimum pressure must be provided at network locations for a given set of demands;
4. Acceptable pipe sizes: Diameters must be selected from an admissible set.

The objective function (Equation 1) was assumed mathematically to be a cost function of pipe diameters and lengths plus the penalty. Whenever the pressure at a node violated the minimum pressure requirement, a penalty was added to the total cost. This penalty made solutions that did not meet the minimum pressure requirement infeasible or infactible.

$$\text{Minimize } f(D_i) = \sum_{i=1}^m f(D)_i \cdot L_i + \sum_{j=1}^n PP_j \quad (1)$$

where $f(D_i)$ is the total cost of the network, $f(D)_i$ is the cost in pipe diameter per unit length, L_i is the pipe length, m and n are the number of pipes and nodes of the network, and PP_j is a penalty function intended to ensure that pressure constraints are satisfied.

During the optimization process, EPANET received the set of new diameters as input and returned the pressures on the network nodes to the algorithm. The head loss equation depended on the problem evaluated; available choices included the Darcy-Weisbach, Hazen-Williams and Chezy-Manning equations. The original information from the case studies was maintained so the results could be compared with the works published in the literature. In addition, the optimization models included integer variables, and no approximations were used to find the diameter values in the discrete set of commercially available diameters.

Particle Swarm optimization

The PSO algorithm is widely used because of its simplicity and attractive search efficiency. Kennedy & Eberhart (1995) developed the parallel evolutionary computation technique based on the social behavior metaphor to solve unconstrained optimization problems (Yang et al., 2019). In the PSO algorithm, a set of particles, called a population or swarm, is used to “research” for the best solution to the optimization problem. The search space is dictated by the objective function and the restrictions imposed, and each particle represents a unique set of solutions to the problem. The particle movement cognitive system allows the best solutions to be identified more quickly, decreasing the computational cost of the exploration process. However, a larger swarm size, dictated by the complexity of the problem, results in increased execution time.

The particles’ movement is associated with $Gbest$, the best position reached within the search space for the swarm particles, and $Pbest$, the best individual position reached within the search space for each particle. In successive iterations, the particle’s new velocity is calculated using its previous velocity (weighted by an inertia factor) and the distance from its current position to its $Pbest$ position and the $Gbest$ position (weighted by social and cognitive factors), as shown in Equation 2. To manage $Gbest$ or $Pbest$ ’s influence on particle motion, Kennedy & Eberhart (1995) adopted two positive constants, called acceleration coefficients c_1 and c_2 , which are directly linked to “social and cognitive factors”. In this work, following the recommendation of these authors, value 2 was adopted for the coefficients. The current velocity vector is added to the previous particle position, X_i^t , giving rise to the new position, X_i^{t+1} (Equation 3).

$$V_i^{t+1} = w^t \cdot V_i^t + c_1 \cdot r_1^t (Pbest_i^t - X_i^t) + c_2 \cdot r_2^t (Gbest_i^t - X_i^t) \quad (2)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (3)$$

Where: V_i and X_i are the velocity and position of the i^{th} particle, w is inertia weight that introduces the weighting of the current

velocity on the particle in the next generation, $Pbest_i$ represents the position with the best fitness found so far by the i^{th} particle, $Gbest_i$ is the position with the best fitness found so far by all the particles in the population, c_1 and c_2 are positive constants, r_1 and r_2 are random numbers between 0 and 1, t is the number of the iteration, and w is the inertia weight that controls the impact of the velocity history on the current velocity to influence the trade-off between global and local experiences.

The inertia factor (Equation 4) is related to the portion of the velocity vector that is connected directly to the particles’ movement. The balance between the global and local exploration of the particles is related to this factor’s value. Eberhart & Shi (2000) proposed that the factor varies between an initial value of 0.9 and a final value of 0.4 in the iterations and decreases gradually. In addition, they noted that high factor values are more effective at the beginning of the search, exploration, because they accelerate convergence and spread the particles over a broader search space. Smaller values favor local exploration by improving the refinement of the search for the final solution.

$$w^t = (w_{ini} - w_{fin}) \left(\frac{N-t}{N} \right) + w_{fin} \quad (4)$$

Where: w_{ini} and w_{fin} are the initial and final inertia factors; and N is the total number of iterations. In order to determine the values of initial and final inertia factors, a sensitivity analysis was performed on the first network evaluated, Balerna irrigation network.

Iteration tolerance (IT) is one of the stopping criteria attributed to the PSO algorithm to prevent simulations from entering an infinite loop. This factor interrupts the optimization process when the number of iterations with the same result exceeds a certain proportion of the total number of iterations that have already occurred. In this work, an IT of 30% was adopted in all case studies. Additionally, it is highlighted that this work adopted a maximum number of iterations, in each simulation, equal to 1000.

H-PSOTS hybrid algorithm

Glover (1989) proposed the concept of the tabu search (TS) heuristic. The basic principle of the TS is to pursue a local search by allowing non-improving moves whenever it encounters a local optimum. Five key elements (i.e. search space, neighborhood structure, tabu list, aspiration criteria and termination criteria) must be designed when developing a TS (Yang et al., 2017). A fundamental element of TS is using flexible memory functions (tabu list) to forbid transitions, called “moves”, from the current solution to other previously visited candidate solutions. The list is updated with each move of the particles and remains in memory for a number of iterations. The longer the list, the more restrictive the search process and the longer the computer runtime. Another factor that improves the method’s quality is restricting moves that guide the particles to new search space neighborhoods, avoiding premature convergence in a local optimum.

Inserting the TS algorithm into the PSO algorithm’s search process increased particle movement efficiency because the TS improves local exploration and decreases premature algorithm convergence and computational cost. The convergence speed

of TS depends on the initial solution, and the parallelism of the PSO population helps the TS find promising search space regions very quickly. Incorporating TS into a PSO algorithm as a local improvement procedure enables the algorithm to maintain the population's diversity (Shen et al., 2008). During the present study's exploration process, the algorithm reduced the repetition of executed movements, allowing a greater diversification of solutions in the search for the global optimum.

The initial position of the particles in the PSO process comprised the tabu list's movement restrictions. As the position of the particles was updated and before the calculation process in the hydraulic simulator and the objective function, the algorithm verified whether a particle of the swarm had already reached the position. If it was a new position, the particle did not move, the swarm update process continued and the list received that position as an increment. However, if the particle's position was already on the tabu list, it was updated. This process was repeated until the whole swarm was updated when its particles visited new positions. When every particle in a swarm has been updated, the list can be updated equally with the new positions, depending on whether the particles were able to keep the previous ones. The number of times or positions stored in the list was determined based on a sensitivity analysis carried out in one of the case studies. To guarantee algorithm convergence regardless of the situation, the Gbest position was not part of the list.

In addition to the tabu list size, the aspiration criterion was defined. This criterion removed the tabu list status from particles with high values in the final optimization phase (close to the maximum number of iterations or iteration tolerance). Thus, the particles had more freedom to seek solutions, preventing the algorithm from stagnating in a local optimum. This criterion directed the particles to the best identified cost, returning solutions that could be useful in swarm diversification. Another criterion adopted for the list was related to the particles that presented the same position as Gbest, facilitating better particle positions and the convergence of the algorithm. In all case studies, the criteria for stopping the search were an iteration tolerance of 30% and a maximum of 1000 iterations. The general flowchart of the H-PSOTS algorithm is shown in Figure 1.

Because evolutionary algorithms are not deterministic, a sensitivity analysis was performed to define the number of particles in the PSO algorithm and the tabu list size. The other input parameters of the PSO algorithm were adopted based on the literature and remained as a standard configuration (default) for all case studies. The adoption of specific parameters for each case study would present better results, but a single algorithm configuration was chosen to determine a typical configuration suitable for any network.




Figure 1. General flowchart of the H-PSOTS algorithm.

RESULTS AND DISCUSSION

For comparison, the PSO and H-PSOTS algorithms were applied to three complex WDNs referenced in the literature. The first network studied was the large irrigation system located in Balerma (Reca & Martínez, 2006), in the province of Almería (Andalusia, Spain). The second, known as the ZJ network (Zheng et al., 2011), was a provincial water supply network in China. The last case study, the Rural network, was also a complex irrigation system, initially presented by Marchi et al. (2014). Network layouts are shown in Figure 2.

Balerma irrigation network

The Balerma irrigation network (Reca & Martínez, 2006) is an adaptation of the WDN for the irrigation system in the Sol-Poniente district, located in Balerma, province of Almería, Spain. This irrigation network includes 454 PVC pipes, 443 nodal demands, eight loops and four reservoirs. The diameter set consisted of 10 diameter types ranging from 113 to 581.8 mm: $D(\text{mm}) = \{113.0, 126.6, 144.6, 162.8, 180.8, 226.2, 285.0, 361.8, 452.2, 581.8\}$. Table 1 presents the costs of the specified diameters.




Figure 2. Case studies.

Sources: (a) Reca and Martínez (2006), (b) Zheng et al. (2011), (c) Marchi et al. (2014).

Table 1. Pipe diameters and costs for the Balerma irrigation network.

Pipe diameters (mm)	Cost (€/m)	Pipe diameters (mm)	Cost (€/m)
113.0	7.22	226.2	28.60
126.6	9.10	285.0	45.39
144.6	11.92	361.8	76.32
162.8	14.84	452.2	124.64
180.8	18.38	581.8	215.85

The minimum pressure required at each node was 20 meters, and pipe friction head loss was computed for all pipes using the Darcy-Weisbach equation with a roughness coefficient of 0.0025 mm.

The algorithm was applied to this network with two objectives: (a) to determine the parameters: inertia factors, number of particles, and the tabu list size, which defined the number of restrictive positions that the particles occupied in each iteration, and (b) to verify the proposed algorithm's performance. The complexity of the WDN design problem is related to the number of sections in the network and the diameters available for the design. Therefore, this network has a search space with 10^{454} possible solutions (viable and non-viable).

To determine the inertia factor (Equation 4), the PSO algorithm was applied in 50 simulations for different w_{ini} and w_{fin} values, keeping the number of particles (100 particles) and the social and cognitive factors (equal to two) constant. The w_{ini} and w_{fin} values ranged from 0.3 to 1.0. Figure 3 shows the results of the sensitivity analysis, where the center of each circle indicates the average values of runtime and cost obtained in 50 simulations, while the diameter represents the standard deviation of costs. Some simulations with values less than 0.3 and greater than 1.0 were performed; however, it was decided not to include them in the text, as they obtained premature convergence in local minimums or high simulation runtime. Thus, this work adopted 0.4 and 0.9 for the w_{ini} and w_{fin} values, respectively.

With the inertia factor defined, the next step was to determine the number of particles used during the optimization process. For this, several simulations were performed with the PSO algorithm by varying the number of particles from 10 to 200. The best values of the simulations' results are shown in Figure 4. The best solution, € 2.10 million, remained stable from 160 particles. Therefore, this value was adopted for the H-PSOTS algorithm because the increase in particles would result in a higher computational cost and a consequent increase in execution time. The relationship between the number of particles and the number of variables (pipe diameters) was 35%. This relationship was maintained in the other networks studied, even though increasing the number of particles can yield better results.

To analyze and determine the hybrid algorithm's tabu list size, simulations were performed in which the list retained up to four previous positions for each particle until the complete swarm update. The best values of the analysis for each the list size increment are shown in Figure 5. It is noteworthy that, regardless of the tabu list size, each new position was added to the list during the particle update process. In addition, at the end of the swarm update, the newly generated positions replaced were added to the old ones, depending on the choice adopted.

Increasing the tabu list worsened the algorithm's solution execution time, demonstrating that a simple list is the best option. The time increase resulted from a growth in the number of checks performed on the list during each particle's updates. In terms of cost, large lists limited the swarm's diversification, which is, in many cases, essential for the improvement of results in the process's advanced stages. During advanced stages of simulation, this diversification helped to decrease the chances of premature convergence in local minima.

After all parameters were determined, the H-PSOTS algorithm was applied, and its results compared with those of the PSO algorithm and the literature (Zheng et al., 2011; Sheikholeslami et al., 2016; Bi et al., 2020) (Table 2). The H-PSOTS algorithm obtained a minimum cost of € 1.998 million, close to the best-known minimum cost of € 1.923 million found by Zheng et al. (2011) using NLP-DE2. Although the result obtained by hybrid algorithm might not represent the best cost in the literature, it determined a good solution with a low simulation runtime in relation to the PSO algorithm.

Figure 6 shows the evolution of the costs of the best solutions found by algorithms PSO and H-PSOTS during the optimization




Figure 3. Analysis of the influence of inertia factor on the optimization process of the Balerma network.




Figure 4. Analysis of the influence of particle number on the optimization process of the Balerma irrigation network.




Figure 5. Analysis of the influence of tabu list size on the optimization process of the Balerma network.

processes, while Figure 7 shows the graphical representations of the results obtained (costs and simulation runtimes) in the 100 simulations performed (50 for each algorithm).

The H-PSOTS algorithm determined the optimum solution with a simulation runtime of 19 minutes, while the PSO algorithm required 43 minutes. The H-PSOTS algorithm resulted in greater exploration of the search space in a shorter execution time because calculation processes were avoided when moving the particles during each iteration. The algorithm's runtime offers the designer more flexibility to scale real systems, and it offers a set of viable solutions




Figure 6. Cost evolution of the best solutions – Balerna irrigation network.

with similar prices and reliability. Figure 8 shows the diameters of the optimized network and the nodal pressures obtained by the H-PSOTS algorithm.

ZJ network

The ZJ network, originally described by Zheng et al. (2011), is a real network in an eastern province of China. It comprises 50 loops, 164 pipes, 113 nodes and a single reservoir. The minimum pressure required at each node was 22 meters, which can be considered the lower pressure limit of the WDN's nodes. Pipe friction head loss was computed using the Hazen-Williams equation, whose coefficients were $\omega = 10.667$, $\alpha = 4.871$ and $\beta = 1.852$; the dimensionless roughness coefficient C was 130 for all pipes. Fourteen potential pipe diameters between 150 and 1000 mm were available for the network design (Table 3); therefore, the search space for this optimization problem consisted of $14^{164} = 9.226 \times 10^{187}$ possible solutions.

The number of particles adopted in this case study was 58, which corresponds to 35% of the number of pipes in the network. This follows the relationship determined in the analysis of the Balerna network. The results of the design using the PSO and H-PSOTS algorithms and the works in the literature are shown in Table 4.

Table 2. Results obtained for the Balerna irrigation network using various methods.

Authors	Method	Solution (10 ⁶ €)
Reca & Martinez (2006)	Genetic algorithm	2.302
Zheng et al. (2011)	Differential evolution	1.923*
Sheikholeslami et al. (2016)	Cuckoo search	2.036
Sheikholeslami et al. (2016)	Hybrid cuckoo harmony search	1.988
Lee et al. (2016)	Decomposition approach	2.066
Zheng et al. (2017)	Ant colony optimization adapted	2.020
Bi et al. (2020)	Differential evolution	2.002
Bi et al. (2020)	Ant colony optimization	2.332
Saldarriaga et al. (2020)	Optimal power use surface	2.015
	PSO	2.099
	H-PSOTS	1.998

*Current best-known solution




Figure 7. Results obtained on the optimization process of the Balerna irrigation network: (a) costs and (b) simulation runtimes.




Figure 8. Optimal pipe size solutions and nodal pressures obtained for the Balerna irrigation network using the H-PSOTS algorithm.

Table 3. Pipe diameters and costs for the ZJ network.

Pipe diameters (mm)	Cost (\$/m)	Pipe diameters (mm)	Cost (\$/m)	Pipe diameters (mm)	Cost (\$/m)
150	24.530	400	93.610	750	261.228
200	35.200	450	113.784	800	291.742
250	47.388	500	134.024	900	355.322
300	61.160	600	180.158	1000	426.690
350	76.450	700	234.74		

Table 4. Results obtained for the ZJ network using various methods.

Authors	Method	Solution (10 ⁶ \$)
Zheng et al. (2011)	NLP – differential evolution	7.082*
Bi et al. (2020)	Differential evolution	7.125
Bi et al. (2020)	Ant colony optimization	7.579
	PSO	8.330
	H-PSOTS	7.704

*Current best-known solution.

The value obtained using the H-PSOTS algorithm was \$ 7.70 million, which corresponds to a reduction of approximately 7.5% compared to the PSO algorithm. The current best-known solution for the ZJ network reported in the literature is \$ 7.082 million, as reported by Zheng et al. (2011), which was preceded by Bi et al. (2020), with a solution of \$ 7.431 million.

Figure 9 shows the evolution of the costs of the best solutions found by algorithms PSO and H-PSOTS during the optimization processes, while Figure 10 shows graphical

representations of the results obtained (costs and runtimes) in the 100 simulations performed. For the best results obtained, the simulation runtimes were 20 and 24 minutes for the H-PSOTS and PSO algorithms, respectively. As expected, the H-PSOTS algorithm presented a more efficient search, which resulted in a reduction in execution time of about 20% compared to the PSO algorithm. This decrease occurred because of the reduced number of mathematical operations and iterative processing between Matlab and EPANET.

Optimal WDN design presents a good configuration of diameters and nodal pressures, with gradual variations in diameters. In other words, it always presents the flow direction from the largest diameter to the smallest. Figure 11 shows the network diameters and nodal pressures obtained using the H-PSOTS algorithm.

Rural network

The Rural network is a real WDN based on an irrigation system and consists of 379 junction nodes, 98 loops, and two reservoirs linked by 476 PVC pipes. Because it contains numerous loops, the Rural network is a good representative example of a highly complex WDN. The network was initially optimized by Marchi et al. (2014) using the genetic algorithm, PSO and differential

evolution algorithms. The minimum pressure required at each node is zero, and the Darcy-Weisbach equation was adopted to calculate head loss using a roughness of 0.012 mm for all pipes.

The available set of diameters used to design the network comprised 15 possible pipe diameters (Table 5). The large number of possible diameters increased the search spaces, which presented 15^{476} (6.61×10^{559}) possible solutions, making it a good challenge for the algorithm proposed in this research.

The swarm consisted of 167 particles in the simulations with the PSO and H-PSOTS algorithms, and the results are shown in Table 6. Although the PSO algorithm had several iterations with values close to those of the H-PSOTS algorithm, its solution and execution time were worse. Figure 12 shows graphical representations of the results obtained (costs and simulation runtimes) in the 100 simulations performed, while Figure 13 shows the evolution of the costs of the best solutions found by algorithms PSO and H-PSOTS during the optimization processes.

The H-PSOTS algorithm reached values close to the current best-known solution (\$30.99 million) in 29 minutes, with an execution time that was 19% shorter than that of the PSO algorithm (36 minutes). The algorithms' evolutionary behavior profile is similar, with small evolutions at each iteration. Figure 14 shows the pipe diameters and nodal pressures of the network optimized using the H-PSOTS algorithm.

The methodology proposed in this study is aimed at improving the design of WDNs based on the execution time and the quality of the results. This technique, which involves two high performance algorithms in applications of this type, creates a set of solutions that meet the water demands and minimum pressures at a minimum cost and in an acceptable execution time.




Figure 9. Cost evolution of the best solutions – ZJ network.

Table 5. Pipe diameters and costs for the Rural network.

Pipe diameters (mm)	Cost (\$/m)	Pipe diameters (mm)	Cost (\$/m)	Pipe diameters (mm)	Cost (\$/m)
44.0	12.0	141.0	55.0	307.0	146.0
64.0	17.0	159.0	61.0	384.0	199.0
80.8	21.0	207.0	98.0	480.0	285.0
104.0	34.0	225.0	116.0	518.0	334.0
117.0	42.0	262.0	126.0	622.0	411.0






Figure 10. Results obtained on the optimization process of the ZJ network: (a) costs and (b) simulation runtimes.

Table 6. Results obtained for the Rural network using various methods.

Authors	Method	Solution (10^6 \$)
Bi et al. (2015)	Differential evolution	35.17
Marchi et al. (2014)	Differential evolution	31.22
Bi et al. (2020)	Differential evolution	30.99*
Bi et al. (2020)	Ant colony optimization	36.74
	PSO	46.45
	H-PSOTS	35.68

*Current best-known solution.

**Figure 11.** Optimal pipe size solutions and nodal pressures obtained for the ZJ network.**Figure 12.** Results obtained on the optimization process of the Rural network: (a) costs and (b) simulation runtimes.




Figure 13. Cost evolution of the best solutions – Rural network.




Figure 14. Optimal pipe size solutions and nodal pressures obtained for the Rural network using the H-PSOTS algorithm.

CONCLUSION

The H-PSOTS algorithm proved to be a good option for the optimal design of large WDNs. The H-PSOTS and PSO algorithms were applied using the same conditions for three benchmark networks proposed in the literature (i.e. the Balerma irrigation network, the ZJ network and the Rural network). In all cases, the H-PSOTS algorithm achieved lower costs compared to the PSO algorithm with shorter execution times. The results were also compared with those of other studies.

The Balerma irrigation network was used to determine the specific input parameters for the algorithms to establish a standard configuration for the design of any WDN. It is noteworthy that, if the algorithms' parameters were adjusted for each case study, they could obtain better results. In all cases, the criteria for interrupting the algorithms were an iteration tolerance of 30% and a maximum number of 1000 iterations.

The H-PSOTS algorithm found good solutions within a reasonable runtime. It explored the search space more efficiently

than did the PSO algorithm, minimizing the calculations and the exchange of information between the optimization algorithm and the hydraulic simulator. The results also demonstrated that the H-PSOTS algorithm can be applied in real systems and projects and can serve as an efficient tool to assist designers.

DATA AVAILABILITY STATEMENT

Some or all data, models, or code that support the findings of this study are available from the corresponding author upon reasonable request.

ACKNOWLEDGEMENTS

This article was completed during the COVID-19 pandemic. The authors dedicate this article to health professionals worldwide due to their great efforts against the disease.

REFERENCES

- Ahmadian, A., Elkamel, A., & Mazouz, A. (2019). An improved hybrid particle swarm optimization and tabu search algorithm for expansion planning of large dimension electric distribution network. *Energies*, 12(16), 3052. <http://dx.doi.org/10.3390/en12163052>.
- Alharkan, I., Saleh, M., Ghaleb, M. A., Kaid, H., Farhan, A., & Almarfadi, A. (2020). Tabu search and particle swarm optimization algorithms for two identical parallel machines scheduling problem with a single server. *Journal of King Saud University-Engineering Sciences*, 32(5), 330-338. <http://dx.doi.org/10.1016/j.jksues.2019.03.006>.
- Bahoosh, S., Bahoosh, R., & Haghighi, A. (2019). Development of a self-adaptive ant colony optimization for designing pipe networks. *Water Resources Management*, 33(14), 4715-4729. <http://dx.doi.org/10.1007/s11269-019-02379-5>.
- Baños, R., Gil, C., Reca, J., & Martínez, J. (2009). Implementation of scatter search for multi-objective optimization, a comparative study. *Computational Optimization and Applications*, 42(3), 421-441. <http://dx.doi.org/10.1007/s10589-007-9121-1>.
- Bezerra, S. T. M., & Macêdo, J. E. S. (2018). Looped water distribution networks design via particle swarm optimization. *Irriga*, 23(4), 798-817. <http://dx.doi.org/10.15809/irriga.2018v23n4p798-817>.
- Bi, W., Dandy, G. C., & Maier, H. R. (2015). Improved genetic algorithm optimization of water distribution system design by incorporating domain knowledge. *Environmental Modelling & Software*, 69(1), 370-381. <http://dx.doi.org/10.1016/j.envsoft.2014.09.010>.
- Bi, W., Xu, Y., & Wang, H. (2020). Comparison of searching behavior of three evolutionary algorithms applied to water distribution system design optimization. *Water (Basel)*, 12(3), 695. <http://dx.doi.org/10.3390/w12030695>.
- Bolognesi, A., Bragalli, C., Marchi, A., & Artina, S. (2010). Genetic heritage evolution by stochastic transmission in the optimal design of water distribution networks. *Advances in Engineering Software*, 41(5), 792-801. <http://dx.doi.org/10.1016/j.advengsoft.2009.12.020>.
- Bozorg Haddad, O., Ghajarnia, N., Solgi, M., Loáiciga, H. A., & Mariño, M. (2016). A DSS-based honeybee mating optimization (HBMO) algorithm for single-and multi-objective design of water distribution networks. In X.-S. Yang, G. Bekdaş, S. M. Nigdeli (Eds.), *Metaheuristics and optimization in civil engineering* (pp. 199-233). Cham, Switzerland: Springer. http://dx.doi.org/10.1007/978-3-319-26245-1_10.
- Cassiolato, G., Carvalho, E. P., Caballero, J. A., & Ravagnani, M. A. (2020). Optimization of water distribution networks using a deterministic approach. *Engineering Optimization*, 53(2), 1-18. <http://dx.doi.org/10.1080/0305215X.2019.1702980>.
- Chandramouli, S. (2019). MATLAB code for linking genetic algorithm and EPANET for reliability based optimal design of a water distribution network. In M. Rathinasamy, S. Chandramouli, K. Phanindra & U. Mahesh (Eds.), *Water resources and environmental engineering I* (pp. 183-194). Singapore: Springer. http://dx.doi.org/10.1007/978-981-13-2044-6_16.
- Chen, W. N., Jia, Y. H., Zhao, F., Luo, X. N., Jia, X. D., & Zhang, J. (2019). A cooperative co-evolutionary approach to large-scale multisource water distribution network optimization. *IEEE Transactions on Evolutionary Computation*, 23(5), 842-857. <http://dx.doi.org/10.1109/TEVC.2019.2893447>.
- Chentoufi, M. A., & Ellaia, R. (2018, 21-23 November). A hybrid particle swarm optimization and tabu search algorithm for adaptive traffic signal timing optimization. In *Proceedings of the 2018 IEEE International Conference on Technology Management, Operations and Decisions (ICTMOD)*. USA: IEEE. <http://dx.doi.org/10.1109/ITMC.2018.8691188>.
- Choi, Y. H., Lee, H. M., Yoo, D. G., & Kim, J. H. (2017). Self-adaptive multi-objective harmony search for optimal design of water distribution networks. *Engineering Optimization*, 49(11), 1957-1977. <http://dx.doi.org/10.1080/0305215X.2016.1273910>.
- Cunha, M., & Marques, J. (2020). A new multiobjective simulated annealing algorithm – mosa-gr: application to the optimal design of water distribution networks. *Water Resources Research*, 56(3), e2019WR025852. <https://doi.org/10.1029/2019WR025852>.
- Ebadi, Y., & Jafari Navimipour, N. (2019). An energy-aware method for data replication in the cloud environments using a tabu search and particle swarm optimization algorithm. *Concurrency and Computation*, 31(1), e4757. <http://dx.doi.org/10.1002/cpe.4757>.
- Eberhart, R. C., & Shi, Y. (2000, 16-19 July). Comparing inertia weights and constriction factors in particle swarm optimization. In *Proceedings of the 2000 Congress on Evolutionary Computation (Cat. No. 00TH8512)* (pp. 84-88). USA: IEEE. <http://dx.doi.org/10.1109/CEC.2000.870279>.
- Ezzeldin, R. M., & Djebdjan, B. (2020). Optimal design of water distribution networks using whale optimization algorithm. *Urban Water Journal*, 17(1), 14-22. <http://dx.doi.org/10.1080/1573062X.2020.1734635>.
- Glover, F. (1989). Tabu Search - Part I. *ORSA Journal on Computing*, 1(3), 190-206. <http://dx.doi.org/10.1287/ijoc.1.3.190>.
- Jung, D., Kang, D., & Kim, J. H. (2018). Development of a hybrid harmony search for water distribution system design. *KJCE Journal of Civil Engineering*, 22(4), 1506-1514. <http://dx.doi.org/10.1007/s12205-017-1864-3>.
- Kaveh, A., & Dadras Eslamlou, A. (2020). *Metaheuristic optimization algorithms in civil engineering: new applications. Studies in Computational Intelligence*. Berlin: Springer. <http://dx.doi.org/10.1007/978-3-030-45473-9>.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of the 1995 IEEE International Conference on Neural Networks*. USA: IEEE. <https://doi.org/10.1109/ICNN.1995.488968>.

- Lee, H. M., Yoo, D. G., Sadollah, A., & Kim, J. H. (2016). Optimal cost design of water distribution networks using a decomposition approach. *Engineering Optimization*, 48(12), 2141-2156. <http://dx.doi.org/10.1080/0305215X.2016.1157689>.
- Marchi, A., Dandy, G., Wilkins, A., & Rohrlach, H. (2014). Methodology for comparing evolutionary algorithms for optimization of water distribution systems. *Journal of Water Resources Planning and Management*, 140(1), 22-31. [http://dx.doi.org/10.1061/\(ASCE\)WR.1943-5452.0000321](http://dx.doi.org/10.1061/(ASCE)WR.1943-5452.0000321).
- Monsef, H., Naghashzadegan, M., Jamali, A., & Farmani, R. (2019). Comparison of evolutionary multi objective optimization algorithms in optimum design of water distribution network. *Ain Shams Engineering Journal*, 10(1), 103-111. <http://dx.doi.org/10.1016/j.asej.2018.04.003>.
- Moosavian, N., & Kasaei Roodsari, B. (2014). Soccer league competition algorithm, a novel meta-heuristic algorithm for optimal design of water distribution networks. *Swarm and Evolutionary Computation*, 17, 14-24. <http://dx.doi.org/10.1016/j.swevo.2014.02.002>.
- Moosavian, N., & Lence, B. J. (2020). Flow-uniformity index for reliable-based optimal design of water distribution networks. *Journal of Water Resources Planning and Management*, 146(3), 04020005. [http://dx.doi.org/10.1061/\(ASCE\)WR.1943-5452.0001161](http://dx.doi.org/10.1061/(ASCE)WR.1943-5452.0001161).
- Mora-Melia, D., Iglesias-Rey, P. L., Martínez-Solano, F. J., & Muñoz-Velasco, P. (2016). The efficiency of setting parameters in a modified shuffled frog leaping algorithm applied to optimizing water distribution networks. *Water (Basel)*, 8(5), 182. <http://dx.doi.org/10.3390/w8050182>.
- Rathi, S., Gupta, R., Palod, N., & Ormsbee, L. (2020). Minimizing the variance of flow series using a genetic algorithm for reliability-based design of looped water distribution networks. *Engineering Optimization*, 52(4), 637-651. <http://dx.doi.org/10.1080/0305215X.2019.1598984>.
- Reca, J., & Martínez, J. (2006). Genetic algorithms for the design of looped irrigation water distribution networks. *Water Resources Research*, 42(5), 1-9. <http://dx.doi.org/10.1029/2005WR004383>.
- Reca, J., Martínez, J., & López, R. (2017). A hybrid water distribution networks design optimization method based on a search space reduction approach and a genetic algorithm. *Water (Basel)*, 9(11), 845. <http://dx.doi.org/10.3390/w9110845>.
- Saldarriaga, J., Páez, D., Salcedo, C., Cuero, P., López, L. L., León, N., & Celeita, D. (2020). A direct approach for the near-optimal design of water distribution networks based on power use. *Water (Basel)*, 12(4), 1037. <http://dx.doi.org/10.3390/w12041037>.
- Sheikholeslami, R., Zecchin, A. C., Zheng, F., & Talatahari, S. (2016). A hybrid cuckoo-harmony search algorithm for optimal design of water distribution systems. *Journal of Hydroinformatics*, 18(3), 544-563. <http://dx.doi.org/10.2166/hydro.2015.174>.
- Shen, Q., Shi, W. M., & Kong, W. (2008). Hybrid particle swarm optimization and tabu search approach for selecting genes for tumor classification using gene expression data. *Computational Biology and Chemistry*, 32(1), 52-60. PMID:18093877. <http://dx.doi.org/10.1016/j.compbiolchem.2007.10.001>.
- Tang, C., & Lee, E. (2018, 19-21 November). Hearing loss identification via wavelet entropy and combination of tabu search and particle swarm optimization. In *Proceedings of the 23rd International Conference on Digital Signal Processing* (pp. 1-5). USA: IEEE. <http://dx.doi.org/10.1109/ICDSP.2018.8631839>.
- Toshev, A. (2019). Particle swarm optimization and tabu search hybrid algorithm for flexible job shop scheduling problem – Analysis of test results. *Cybernetics and Information Technologies*, 19(4), 26-44. <http://dx.doi.org/10.2478/cait-2019-0034>.
- Yang, P., Peng, Y., Ye, B., & Miao, L. (2017). Integrated optimization of location assignment and sequencing in multi-shuttle automated storage and retrieval systems under modified 2N-command cycle pattern. *Engineering Optimization*, 49(9), 1604-1620. <http://dx.doi.org/10.1080/0305215X.2016.1261128>.
- Yang, Z., Qiu, H., Gao, L., Cai, X., Jiang, C., & Chen, L. (2019). A surrogate-assisted particle swarm optimization algorithm based on efficient global optimization for expensive black-box problems. *Engineering Optimization*, 51(4), 549-566. <http://dx.doi.org/10.1080/0305215X.2018.1477940>.
- Zheng, F., Simpson, A. R., & Zecchin, A. C. (2011). A combined NLP-differential evolution algorithm approach for the optimization of looped water distribution systems. *Water Resources Research*, 47(8), W08531. <http://dx.doi.org/10.1029/2011WR010394>.
- Zheng, F., Zecchin, A. C., Newman, J. P., Maier, H. R., & Dandy, G. C. (2017). An adaptive convergence-trajectory controlled ant colony optimization algorithm with application to water distribution system design problems. *IEEE Transactions on Evolutionary Computation*, 21(5), 773-791. <http://dx.doi.org/10.1109/TEVC.2017.2682899>.

Authors contributions

José Eloim Silva de Macêdo: Conceptualization, methodology, validation, formal analysis, investigation, data curation, writing – original draft, writing – review & editing.

José Roberto Gonçalves de Azevedo: Conceptualization, methodology, validation, formal analysis, investigation, writing – review & editing, supervision, project administration.

Saulo de Tarso Marques Bezerra: Conceptualization, methodology, validation, formal analysis, investigation, writing – review & editing, supervision.

Editor Chefe: Adilson Pinheiro

Editor Associado: Iran Eduardo Lima Neto