



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
NÚCLEO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL

SABRINA DA SILVA CORRÊA

**MODELO HÍBRIDO PARA SETORIZAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO
DE ÁGUA BASEADO EM TEORIA DOS GRAFOS E *PARTICLE SWARM*
*OPTIMIZATION***

Caruaru

2021

SABRINA DA SILVA CORRÊA

**MODELO HÍBRIDO PARA SETORIZAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO
DE ÁGUA BASEADO EM TEORIA DOS GRAFOS E *PARTICLE SWARM*
*OPTIMIZATION***

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal de Pernambuco para obtenção do título de Mestre em Engenharia Civil e Ambiental.

Área de concentração: Tecnologia Ambiental.

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

Caruaru

2021

Catálogo na fonte:
Bibliotecária – Paula Silva - CRB/4 - 1223

C824m Corrêa, Sabrina da Silva.
 Modelo híbrido para setorização de sistemas de distribuição de água baseado em teoria dos grafos e *particle swarm optimization*. / Sabrina da Silva Corrêa. – 2021. 83 f.; il.: 30 cm.

 Orientador: Saulo de Tarso Marques Bezerra.
 Dissertação (Mestrado) – Universidade Federal de Pernambuco, CAA, Engenharia Civil e Ambiental, 2021.
 Inclui Referências.

 1. Abastecimento de água – João Pessoa (PB). 2. Água – Qualidade – Medição.
 3. Controle da qualidade da água – João Pessoa (PB). 4. Água - Desperdício – João Pessoa (PB). 5. Hidráulica. 6. Algoritmos computacionais. I. Bezerra, Saulo de Tarso Marques (Orientador). II. Título.

CDD 620 (23. ed.)

UFPE (CAA 2021-002)

SABRINA DA SILVA CORRÊA

**MODELO HÍBRIDO PARA SETORIZAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO
DE ÁGUA BASEADO EM TEORIA DOS GRAFOS E *PARTICLE SWARM*
*OPTIMIZATION***

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal de Pernambuco para obtenção do título de Mestre em Engenharia Civil e Ambiental.

Aprovada em: 19/02/2021.

BANCA EXAMINADORA

Prof^o. Dr. Saulo de Tarso Marques Bezerra (Orientador)
Universidade Federal de Pernambuco

Prof^o. Dr. Heber Pimentel Gomes (Examinador Externo)
Universidade Federal da Paraíba

Prof^o. Dr. Marcele Elisa Fontana (Examinadora Externa)
Universidade Federal de Pernambuco

A Deus, pelo amor da tua benignidade e da tua verdade.

À minha mãe, que não mediu esforços para que eu chegasse até esta etapa da minha vida.

AGRADECIMENTOS

Agradeço a Deus pela saúde e força para perseguir meus sonhos e superar dificuldades, inclusive nesse momento obscuro de pandemia.

À minha mãe, Marinete Maria da Silva, a grande responsável pelas minhas conquistas, que sempre se dedicou totalmente e me incentivou a continuar seguindo meus sonhos.

Ao meu noivo, Gilberto Silva Raimundo Filho, por ter me encorajado diante de todas as dificuldades, pela sua paciência e compreensão nas fases de ausência, e principalmente por ter me dado auxílio em todos os momentos que eu precisava, tornando-se indispensáveis.

Ao meu orientador, Saulo de Tarso, pelo suporte e experiência fundamentais para a realização deste trabalho, por ter me dado oportunidade em fazer parte do meio acadêmico.

À Universidade Federal de Pernambuco e seus funcionários pela oportunidade e recursos oferecidos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), por fornecer apoio financeiro para a execução deste trabalho e para minha formação.

A todos os educadores que já tive, por terem formado as bases necessárias para que eu me tornasse o que sou.

Aos amigos do mestrado, em especial Thaise Suanne, Júlia de Souza, Andreia Azevedo e Maria Alice, por terem se mantido ao meu lado me motivando, auxiliando e proporcionando momentos de alegria nesses anos.

Aos meus avós, Dona Carminha e Antônio, por estarem ao meu lado, me incentivando e me apoiando.

Ao engenheiro Moisés Menezes Salvino, Diretor-Presidente da Hidrainfo Consultoria e Serviços LTDA, pelo fornecimento de dados utilizados nesta pesquisa.

E a todos os demais familiares e demais amigos, por torcerem pelo meu sucesso e que muitas vezes distantes se fizeram presentes, o meu muito obrigado.

RESUMO

A expansão acelerada das áreas urbanas, nos últimos anos, implicou no aumento da complexidade do gerenciamento dos sistemas de distribuição de água (SDAs), acarretando em altos índices de perdas de água. Diante disso, diversos estudos propõem a divisão dos SDAs para melhorar a gestão e a segurança operacional dos sistemas. A setorização facilita principalmente a implantação da macromedição e de medidas para o controle de perdas de água. Contudo, é complexo identificar qual é a melhor opção de setorização de SDAs, uma vez que existe um grande número de combinações e os modelos existentes na literatura trazem uma série de limitações ao projeto. Assim, esta pesquisa propõe o desenvolvimento de um modelo híbrido para o projeto ótimo de distritos de medição e controle (DMCs) em sistemas de distribuição de água. A metodologia proposta combina os princípios da teoria dos grafos, com aplicação do algoritmo *Dijkstra shortest path* (DSP) e o algoritmo metaheurístico *binary particle swarm optimization* (BPSO) para minimizar os vazamentos nas tubulações por meio do controle da pressão e para a minimização dos custos de operação. O modelo foi aplicado em três sistemas de distribuição reais localizados na cidade de João Pessoa – PB. Os resultados indicam eficiência no projeto de setorização, com soluções ótimas obedecendo às restrições impostas, e semelhantes à setorização projetada por empresa especializada. Conclui-se que o estudo apresenta uma abordagem prática e eficaz para a realização de projetos de distritos de medição e controle de sistemas de abastecimento de água.

Palavras-chave: Sistemas de abastecimento de água. Distritos de medição e controle. Perdas de água. Eficiência hidráulica. *Binary particle swarm optimization* (BPSO). *Dijkstra shortest path* (DSP).

ABSTRACT

The accelerated expansion of urban areas in recent years has led to an increase in the complexity of managing water distribution systems (WDS), resulting in high rates of water loss. Therefore, several studies propose the division of WDS to improve the management and operational security of systems. The sectorization facilitates the implementation of macromeasuring and measures to control water losses. However, it is complex to identify which is the best option for sectorization, since there are a large number of combinations, and the method in the literature bring a series of limitations to the project. This research proposes the development of a hybrid model for the optimal design of district metered areas (DMA) in water distribution systems. The proposed methodology combines the principles of graph theory, with the application of the Dijkstra shortest path (DSP) algorithm, and the meta-heuristic algorithm binary particle swarm optimization (BPSO) to minimize leaks in the pipes by means of pressure control, and to minimize the project costs. The model was applied to three real distribution systems located in the city of João Pessoa - PB. The results indicate efficiency in the sectorization project, with optimal solutions obeying the imposed restrictions, and similar to the sectorization designed by a specialized company. It is concluded that the study presents a plausible and effective model for the realization of projects of district metered areas.

Keywords: Water distribution systems. District metered areas (DMAs). Water losses. Hydraulic efficiency. Binary particle swarm optimization (BPSO). Dijkstra shortest path (DSP).

LISTA DE ILUSTRAÇÕES

Figura 1 –	Configuração típica de distritos de medição e controle.	15
Figura 2 –	Mapa de Königsberg.	21
Figura 3 –	Grafo de Euler.	22
Figura 4 –	Influência das parcelas de inércia, cognitiva e social no processo de busca.	33
Fluxograma 1 –	Etapas do modelo híbrido de setorização proposto.	41
Figura 5 –	Rede Apulian.	51
Figura 6 –	Setorização da Rede Apulian através do algoritmo DSP.	53
Figura 7 –	Solução otimizada da setorização da Rede Apulian.	53
Mapa 1 –	Mapa de pressão da Rede Apulian: (a) antes e (b) depois da setorização.	54
Mapa 2 –	Mapa territorial da cidade de João Pessoa – PB.	55
Mapa 3 –	Bairros por área de influência dos reservatórios da cidade de João Pessoa.	56
Figura 8 –	Sistema de distribuição de água da ZP R37.	56
Figura 9 –	Setorização da Zona de Pressão R37 através do algoritmo DSP.	58
Figura 10 –	Solução otimizada do projeto de setorização da Zona de Pressão R37.	59
Mapa 4 –	Mapa de pressão da Zona de Pressão R37 (a) antes e (b) depois da setorização.	60
Figura 11 –	Sistema de distribuição de água da ZP R5.	61
Figura 12 –	Setorização da Zona de Pressão R5 através do algoritmo DSP.	62
Figura 13 –	Solução otimizada do projeto de setorização da Zona de Pressão R5.	63
Mapa 5 –	Mapa de pressão da Zona de Pressão R5 (a) antes e (b) depois da setorização.	64
Figura 14 –	Sistema de distribuição de água da ZP R1-R23.	65
Figura 15 –	Setorização da Zona de Pressão R1-R23 através do algoritmo DSP.	66
Figura 16 –	Solução otimizada do projeto de setorização da Zona de Pressão R1-R23.	68
Mapa 6 –	Mapa de pressão da Zona de Pressão R1-R23 (a) antes e (b) depois da setorização.	68
Figura 17 –	Projeto de setorização da Zona de Pressão R37 (a) modelo proposto e (b) Hidrainfo.	70
Figura 18 –	Projeto de setorização da Zona de Pressão R5 (a) modelo proposto e (b) Hidrainfo.	70
Figura 19 –	Projeto de setorização da Zona de Pressão R1-R23 (a) modelo proposto e (b) Hidrainfo.	71

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ACO	<i>Ant colony optimization</i>
ALO	<i>Ant lion optimizer</i>
BFO	<i>Bacterial foraging optimization</i>
BFS	<i>Breadth-first search</i>
DA	<i>Dragonfly algorithm</i>
DFS	<i>Depth-first search</i>
DMC	Distrito de medição e controle
DSP	<i>Dijkstra shortest path</i>
FAVAD	<i>Fixed and Variable Area Discharges</i>
IDE	<i>Integrated development environment</i>
KH	<i>Krill head</i>
MOPSO	<i>Multi-objective particle swarm optimization</i>
PSO	<i>Particle swarm optimization</i>
SCADA	Sistema de supervisão e aquisição de dados
SDA	Sistema de distribuição de água
SFL	<i>Shuffled frog-leaping</i>
VRP	Válvula redutora de pressão
WOA	<i>Whale optimization algorithm</i>
ZP	Zona de pressão

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Objetivos	13
1.2	Estrutura da Dissertação	13
2	REFERENCIAL TEÓRICO E METODOLÓGICO	15
2.1	Distrito de Medição e Controle (DMC)	15
2.1.1	O Estado da Arte.....	17
2.2	Teoria dos Grafos	21
2.2.1	Propriedade Matemática dos Grafos.....	22
2.2.2	<i>Dijkstra Shortest Path (DSP)</i>	23
2.3	Métodos Metaheurísticos	25
2.4	<i>Particle Swarm Optimization (PSO)</i>	30
2.4.1	<i>Binary Particle Swarm Optimization (BPSO)</i>	34
2.5	Síntese Conclusiva	38
3	MATERIAIS E MÉTODOS	40
3.1.	Tubulação Principal	42
3.2.	Agrupamento de Nós	42
3.3.	Otimização dos Distritos de Medição e Controle	44
3.3.1.	Função Objetivo.....	45
3.3.2.	Variáveis de Decisão	48
3.3.3.	Restrições.....	48
4	RESULTADOS E DISCUSSÕES	51
4.1.	Rede Apulian	51
4.2.	Estudo de Caso Real	54
4.2.1.	Zona de Pressão R37	56
4.2.2.	Zona de Pressão R5	60
4.2.3.	Zona de Pressão R1-R23	64
4.3.	Análise e Discussão dos Resultados	69
5	CONSIDERAÇÕES FINAIS	73
5.1	Conclusões	73
5.2	Contribuições	74
5.3	Limitações e Recomendações para Trabalhos Futuros	74
	REFERÊNCIAS	76

1 INTRODUÇÃO

Assegurar a disponibilidade e gestão sustentável da água para todos os indivíduos é um dos objetivos da Agenda 2030 para o desenvolvimento sustentável, e os países em desenvolvimento apresentam dados e projeções que indicam grandes dificuldades para alcançar tal fim. Nesse sentido, a comunidade técnica-científica mundial tem buscado soluções sustentáveis de maneira a eficientizar a gestão hídrica em diferentes locais do mundo.

No setor de saneamento, a expansão acelerada das áreas urbanas intensificou a complexidade da gestão dos sistemas de abastecimento de água. Diante disso, diversos estudos propõem a divisão dos sistemas de distribuição de água em redes menores para melhorar o gerenciamento e a segurança operacional (FERRARI; SAVIC; BECCIU, 2014; ALVISI; FRANCHINI, 2014; DI NARDO *et al.*, 2013; GIUSTOLISI; RIDOLFI, 2014; LAUCELLI *et al.*, 2017; ZHANG *et al.*, 2019). Esse método é chamado de setorização de sistemas de distribuição de água (SDAs) (DI NARDO *et al.*, 2013).

A setorização consiste na divisão do sistema em redes de menor dimensão, com fronteiras bem conhecidas e delimitadas. Essas redes são chamadas de Setores de Medição, Distritos de Medição e Controle (DMCs) ou Zonas de Medição e Controle. Os DMCs são criados por meio do fechamento de registros ou desconexão de tubulações, de modo que a vazão fornecida ao sistema possa ser medida e controlada. É importante ressaltar que é comum, nas empresas de saneamento, a divisão dos sistemas de abastecimento de água em grandes setores, que não necessariamente são DMCs (BEZERRA; GOMES, 2019).

A setorização vem sendo aplicada com sucesso em sistemas de abastecimento de água do mundo inteiro, pois permite avaliar as perdas de água por meio de um balanço que compara a vazão macromedida, na entrada do DMC, com as micromedidas pelos consumidores contidos na área de abrangência do distrito correspondente. O cálculo do balanço hídrico é a base para a implementação das técnicas *bottom up* (de baixo para cima) de avaliação de perdas de água. Além disso, permite adequar as pressões de serviço dentro de limites aceitáveis, a detecção de vazamentos visíveis e não visíveis, a redução de obras de reabilitação, o gerenciamento da qualidade da água, e a proteção do distrito a contaminação acidental ou intencional (GOMEZ; CUBILO; MARTÍN, 2014; DI NARDO *et al.*, 2015; FERRARI; SAVIC, 2015; PERELMAN *et al.*, 2015; ZHENG *et al.*, 2017; ZHANG *et al.*, 2017; RAHMAN; WU, 2018; LIU; HAN, 2018; ZHANG *et al.*, 2019).

Reparos de vazamentos, substituição de tubulações e reabilitação de redes podem ser alcançados mais rapidamente e de forma mais simples em setores isolados, porque o processo de parada de operação é mais simples durante a manutenção, não causando alterações nas outras partes das redes (DI NARDO *et al.*, 2013), contribuindo com as melhores práticas endossadas pela comunidade técnica-científica.

Contudo, é complexo identificar qual é a melhor opção de setorização de sistemas de distribuição de água, uma vez que existe um grande número de combinações, até mesmo no projeto de pequenas redes (DI NARDO; DI NATALE, 2011). Procurar as posições de inserção dos dispositivos (tanto os medidores de vazão quanto as válvulas de seccionamento) que possam dividir as redes em DMCs e ainda atender aos requisitos hidráulicos é computacionalmente pesado. Atualmente, a quase totalidade dos projetos de setorização de sistemas reais são elaborados com base na experiência dos projetistas, por tentativa e erro. O projeto de setorização é um desafio complexo para os técnicos, porque pelo menos três requisitos cruciais devem ser satisfeitos: 1) conectividade da rede, ou seja, cada nó da rede de distribuição de água deve ser conectado a pelo menos uma fonte de água; 2) atendimento da pressão mínima, ou seja, todos os nós devem ter pressão igual ou superior ao nível mínimo requerido para atender a demanda de água dos usuários; 3) o número de medidores de vazão e registros deve ser minimizado para reduzir custos e complexidade de gerenciamento (DI NARDO *et al.*, 2018).

Buscando o desenvolvimento de métodos para o projeto ótimo de distritos de medição, pode-se utilizar a teoria dos grafos e técnicas metaheurísticas. Os princípios da teoria dos grafos são, geralmente, adotados para o agrupamento dos nós e, conseqüentemente, formação de distritos (JACOBS; GOULTER, 1988; ALVISI; FRANCHINI, 2014; DI NARDO *et al.*, 2013; ZHANG *et al.*, 2019). A topologia da rede de distribuição de água pode ser representada através de estruturas de grafos, onde os vértices representam os nós e as arestas representam as tubulações. Os modelos encontrados na literatura geralmente são baseados na análise de cluster (HERRERA *et al.*, 2010; DI NARDO *et al.*, 2013), detecção da estrutura da comunidade (DIAO; ZHOU; RAUCH, 2013; DIAO *et al.*, 2014; DIAO *et al.*, 2016; CIAPONI; MURARI; TODESCHINI, 2016) e análise do caminho mais curto (TZATCHKOV; ALCOCER-YAMANAKA; ORTÍZ, 2006; ZHANG *et al.*, 2019)

Todavia, tais modelos trazem algumas limitações ao projeto de setorização. Nos resultados dos modelos fundamentados na detecção de comunidade, é necessária a modificação dos principais parâmetros para obter mais de um resultado. Além disso, a maioria dos modelos utiliza função de objetivo único, o que pode ser ineficiente para problemas de setorização.

Outro fator importante a ser considerado é alto custo computacional do processo de otimização. Portanto, métodos metaheurísticos devem ser considerados para obter soluções ótimas em um tempo razoável. Dentre as técnicas metaheurísticas, o *particle swarm optimization* (PSO) é um dos métodos mais promissores no campo da otimização numérica (BANSAL *et al.*, 2014). Além disso, o PSO é uma técnica de otimização recomendada para esse tipo de projeto, uma vez que este algoritmo de otimização vem se destacando pela sua simplicidade, robustez e eficiência. O seu desenvolvimento se baseia no comportamento coletivo de animais que vivem em sociedade, tais como enxame de abelhas, bando de pássaros e cardume de peixes. O algoritmo PSO se destaca em relação ao algoritmo genético, uma vez que tem apresentado melhores resultados e menor tempo de processamento (MORAES; NAGANO, 2012).

Portanto, é evidente a necessidade do desenvolvimento de um modelo que seja capaz de realizar a setorização em sistemas de distribuição de água levando em consideração diversos fatores, tais como custos, pressão, tamanho e isolamento dos distritos, e ainda utilizar técnicas metaheurísticas de modo a obter soluções ótimas em um período de tempo razoável.

1.1 Objetivos

Objetiva-se com esta pesquisa o desenvolvimento de um modelo híbrido para a setorização de sistemas de distribuição de água.

Para atender ao objetivo geral, têm-se os seguintes objetivos específicos:

- Desenvolver uma ferramenta computacional para o projeto ótimo de distritos de medição e controle de sistemas de distribuição de água, baseado na teoria dos grafos e *binary particle swarm optimization*, que vise à minimização de vazamentos nas tubulações;
- Projetar a setorização de sistemas de distribuição de água reais localizados na cidade de João Pessoa-PB;
- Avaliar os impactos dos distritos de medição e controle em relação à redução de perdas de água em estudos de caso;

1.2 Estrutura da Dissertação

Além deste capítulo introdutório, o trabalho apresenta os seguintes capítulos:

- Capítulo 2 – Referencial Teórico e Metodológico: são discutidos os conceitos fundamentais do trabalho e a revisão de literatura;

- Capítulo 3 – Materiais e Métodos: é proposto e caracterizado o modelo híbrido proposto neste trabalho;
- Capítulo 4 – Resultados e Discussões: aplicação do modelo proposto em sistemas de destruição de água reais, e os resultados são discutidos e comparados com projetos de setorização realizados por empresa especializada;
- Capítulo 5 – Considerações Finais: são apresentadas as conclusões, vantagens e contribuições da pesquisa, além das limitações e sugestões para trabalhos futuros.

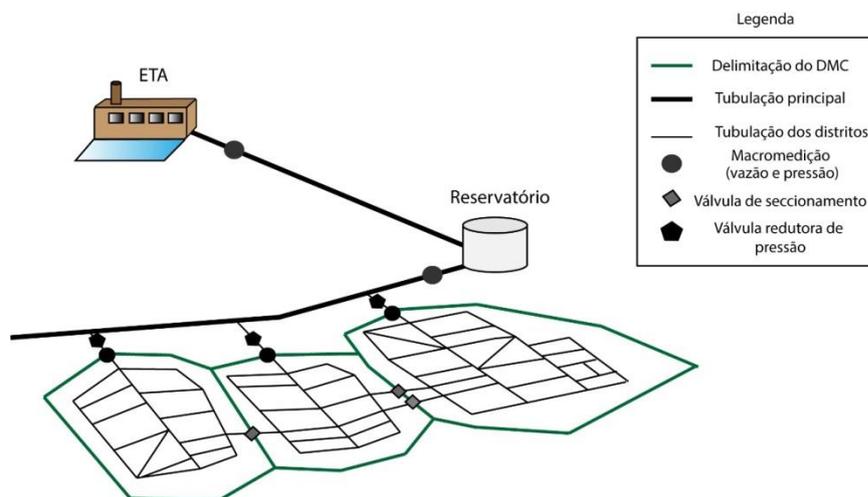
2 REFERENCIAL TEÓRICO E METODOLÓGICO

Neste capítulo são apresentados e discutidos os conceitos fundamentais que baseiam o presente estudo. Explanou-se sobre projetos de distritos de medição e controle, assim como sua aplicação em sistemas de distribuição de água e propostas de projetos ótimos encontrados na revisão de literatura. Além disso, outros conceitos como a teoria dos grafos, métodos metaheurísticos, em especial o *particle swarm optimization*, utilizados na metodologia proposta nesse trabalho, foram fundamentados.

2.1 Distrito de Medição e Controle (DMC)

A setorização, como técnica de apoio à gestão de sistemas de distribuição de água, foi introduzida no Reino Unido, no início dos anos 80, e tem sido progressivamente adotada pelas empresas de saneamento. O relatório *Report 26 Leakage Control Policy & Practice* (1980) apresentou os distritos de medição e controle como redes de distribuição de água menores criadas pelo fechamento de registros ou desconexão de trechos, de modo que as vazões e pressões do sistema possam ser medidas e/ou controladas, conforme a Figura 1.

Figura 1 – Configuração típica de distritos de medição e controle.



Fonte: A Autora (2021).

Campbell *et al.* (2016) definem a setorização como uma técnica destinada a melhorar o controle operacional dos sistemas de distribuição de água, incluindo, entre outros, gerenciamento de vazamentos e pressões, monitoramento da qualidade da água, agilização das atividades de reparo e definição de cronogramas de fornecimento para abastecimento de água

com intermitência. Também melhora o gerenciamento dos sistemas, pois subsidia a definição dos componentes do balanço hídrico e reduz os riscos à segurança da água (LAUCELLI *et al.*, 2017).

No entanto, dividir uma rede de distribuição de água em DMCs reduz o número de caminhos de fluxo para os nós de demandas, o que pode causar estagnação no sistema, e provocar problemas de qualidade da água, pressão não uniforme e redução de confiabilidade (FERRARI; SAVIC; BECCIU, 2014). Portanto, é importante que o projeto de distritos de medição e controle atenda aos critérios e diretrizes apresentados na literatura. Recentemente, indicações são dadas para aumentar a eficiência dos DMCs. Três fatores devem ser considerados no projeto: as tubulações principais devem ser mantidas separadas dos DMCs para garantir um abastecimento de água flexível e confiável; cada DMC deve ser conectado diretamente à rede principal; e os distritos não devem ter ligações ativas entre si, ou seja, devem ser isolados (FERRARI; SAVIC; BECCIU, 2014).

Alvisi e Franchini (2013) resumem os passos para o projeto de DMCs em: determinar o método de alocação dos nós da rede de distribuição de água entre os vários distritos, de maneira que cada DMC respeite o limite de ligações preestabelecido; determinar quantos e quais trechos precisam ser fechadas para delimitar os distritos, de maneira a não penalizar excessivamente a confiabilidade do sistema e garantir a manutenção de níveis mínimos de serviço; e por fim reabilitar a rede de distribuição de água para adequar o sistema às exigências impostas, como, por exemplo, atendimento da pressão mínima em todos os nós.

Em relação ao tamanho ideal dos distritos, Farley (2001) propôs que, ao considerar a análise do fluxo noturno e o local de vazamento, o tamanho de um DMC deveria ser menor que 5.000 conexões de clientes. De outra perspectiva, o maior DMC deve conter entre 150 a 200 hidrantes, 2.500 conexões de usuário com 3 ou 30 km de tubulações principais (MACDONALD; YATES, 2005). Zhang *et al.* (2019) afirmam que para uma cidade com baixa densidade populacional, conexões entre 500 e 5.000 clientes são do tamanho mais comum, enquanto que para uma cidade com alta densidade populacional, o tamanho apropriado pode ser muito maior.

No Brasil, a NBR 12218 (ABNT, 2017) cita as seguintes diretrizes para elaboração de projetos de distritos de medição e controle:

- O DMC deve contemplar no máximo 5.000 ligações;
- A extensão máxima da rede abrangida pelo distrito é de 25 km;

- As dimensões mínimas devem levar em consideração a viabilidade técnica, econômica, financeira, bem como as características locais;
- O processo de delimitação do DMC deve minimizar o custo de instalação e manutenção do sistema, procurando seguir a topologia natural, as fronteiras hidráulicas da rede, e ter como base as zonas de pressão e outros subsistemas já existentes;
- Recomenda-se o seccionamento das redes limítrofes, evitando-se ao máximo manter ou instalar válvulas de seccionamento (registros);
- O número de pontos de alimentação do DMC deve ser o mínimo possível;
- O DMC deve ser equipado com medidores de vazão em todas as entradas e saídas, e medidores de pressão nos pontos críticos da rede, que podem ter previsão de instalação permanente ou dispositivo para sua inserção, quando da realização de coleta de dados operacionais.

2.1.1 O Estado da Arte

De fato, a experiência mostrou que a implementação dos distritos de medição e controle fornece uma série de benefícios para os sistemas de distribuição de água. Essa estrutura facilita a implantação de medidas para a minimização de perdas de água reais no sistema por meio, por exemplo, do gerenciamento de pressão (BABIC; DUKIC; STANIC, 2014; XU *et al.*, 2014; VO; MAI; NGUYEN, 2018; BERARDI *et al.*, 2019), da identificação e localização de perdas por meio do acompanhamento da vazão mínima noturna (BABIC; DUKIC; STANIC, 2014; SOARES *et al.*, 2017) e da utilização de sistema de supervisão e aquisição de dados (SCADA) (MACDONALD; YATES, 2005; SOARES *et al.*, 2017). Soares *et al.* (2017) analisaram a setorização de redes de distribuição de água com o apoio de sistemas SCADA. Ao investigar a setorização do SDAs de Florianópolis-SC, constataram que a implantação de DMCs possibilitou a identificação de vazamentos de maneira mais ágil, permitindo reduzir o volume de perdas físicas.

Laucelli *et al.* (2017) propuseram um modelo para o projeto ótimo de DMCs com três objetivos que minimizaram o número de medidores de vazão, e as perdas reais e aparentes. Os resultados mostraram que a implementação da setorização pode permitir a redução de vazamentos em sistemas com excesso de capacidade hidráulica. Jitong e Jothityangkoon (2017) utilizaram o modelo de setorização proposto por Di Nardo *et al.* (2013) e Laucelli *et al.* (2017) no SDA Lop Buri Branch, Tailândia. Os pesquisadores obtiveram resultados

bastante satisfatórios, pois ocorreu uma diminuição no vazamento em cerca de 7%, representando uma economia considerável para a empresa de abastecimento local.

Ilaya-Ayza *et al.* (2017) propuseram uma nova metodologia para a setorização de redes de distribuição de água que operam com fornecimento intermitência, tendo em vista a complexidade desses sistemas. O modelo foi aplicado no SDA de Oruro, Bolívia, e foi obtido um melhor desempenho do sistema. A setorização minimizou as pressões, garantido assim uma maior equidade na rede e um melhor gerenciamento dos padrões de intermitência.

A setorização também permite a localização e operação ideal das válvulas redutoras de pressão (VRPs). Babic, Dukic e Stanic (2014) realizaram um estudo de caso em um DMC de Kotez, Sérvia, instalando uma VRP de saída fixa na tubulação de entrada do distrito. Os resultados obtidos mostram claramente a influência positiva na redução de perdas de água (vazamento) e consumo de água devido ao controle de pressão. Vo, Mai e Nguyen (2018) analisaram a setorização do SDA de Phan Rang, Vietnã. A partir da análise das medições de vazão, foi identificada a localização de vazamentos de água na rede, tornando mais ágil a identificação do local de instalação da VRP. Berardi *et al.* (2019) propuseram uma metodologia integrada para a redução de perdas de água, integrando o projeto ótimo de DMCs com a localização ideal de VRPs. Os pesquisadores aplicaram o modelo em uma rede de distribuição de água no sul da Itália. A solução ótima buscou a minimização do volume perdido por vazamentos e da instalação de medidores de vazão.

A maioria dos projetos de setorização é realizada com base na experiência dos projetistas, especialmente de acordo com os limites “naturais” e administrativos das SDAs. Esse método é subjetivo e precisa fazer pleno uso das condições de contorno do problema, como rios, estradas principais e divisões administrativas (ZHANG *et al.*, 2019).

Para atender as diversas diretrizes atribuídas ao projeto de distritos de medição e controle, diversos pesquisadores estão propondo modelos para os projetos de setorização. A identificação de soluções viáveis para a setorização de sistemas reais é muita complexa, tendo em vista que existe um grande número de alternativas, mesmo em redes de pequeno porte. (DI NARDO; DI NATALE, 2011). No caso de sistemas de distribuição de água já implantados, que geralmente foram projetados em estágios sucessivos e não foram concebidos considerando a divisão em distritos, a complexidade é aumentada.

Os princípios da teoria dos grafos estão, geralmente, sendo adotados para o agrupamento dos nós e, conseqüentemente, formação de setores em sistemas de distribuição de água (DI NARDO *et al.*, 2013; ALVISI; FRANCHINI, 2014; ZHANG *et al.*, 2019). Herrera *et al.* (2010) desenvolveram uma metodologia para o projeto de setorização utilizando

o agrupamento espectral por meio de grafos. Para isso, foi necessário elaborar a matriz de adjacência do grafo com as informações e restrições da rede de distribuição de água. Os resultados indicam que é possível a divisão do sistema em distritos não isolados com quantidades pré-estabelecidas pelo projetista, porém o modelo busca apenas minimizar a quantidade de trechos (válvulas de seccionamento) que devem ser fechados para a repartição, não levando em consideração outros benefícios para o sistema.

Do mesmo modo, Di Nardo *et al.* (2013) propuseram um modelo de otimização a partir do agrupamento espectral para obter os limites dos DMCs e o algoritmo genético para obter os locais ideais de válvulas de seccionamento e medidores de vazão, minimizando a energia dissipada ao longo da rede. Contudo, minimizar a energia dissipada da rede requer que o sistema disponibilize diversas fontes de alimentação. Além disso, utilizar uma função monobjetivo em problemas de setorização pode ser ineficiente.

Outra forma de realizar a setorização encontrada na literatura é através da detecção da estrutura da comunidade dos sistemas de distribuição de água, através do índice de modularidade. Essa técnica foi utilizada pela primeira vez por Diao, Zhou e Rauch (2013), cuja metodologia proposta se baseia na minimização do número de tubulações entre os distritos. Os resultados mostram que o modelo aplicado não garante encontrar a solução ótima global.

Posteriormente, Diao *et al.* (2014) e Diao *et al.* (2016) desenvolveram um modelo de decomposição de camada dupla mais completa com base na detecção da comunidade. A principal desvantagem do modelo determinístico proposto é otimizar as redes de tubulação principal e comunidades separadamente, o que pode resultar em discrepância inevitável da solução ótima global.

Ciaponi, Murari e Todeschini (2016) usaram a detecção de comunidade para determinar os distritos, otimizando o número de entradas das redes. Apesar de o modelo apresentar diversas soluções viáveis de setorização, com seu desempenho hidráulico avaliado por meio dos indicadores de pressão e o índice de resiliência, os aspectos econômicos não são incluídos diretamente no procedimento automatizado. Além do mais, cabe ressaltar que o modelo proposto não conseguiu conciliar a homogeneidade do tamanho dos distritos com a sua independência.

E por fim, há modelos que consideram a análise de caminho como base para o projeto de distritos de medição e controle. Tzatchkov, Alcocer-Yamanaka e Ortíz (2006) foram os primeiros a identificar que algoritmos baseados na teoria dos grafos como o algoritmo *depth-first search* (DFS) e o algoritmo *breadth-first search* (BFS) podem ser

utilizados no projeto de setorização. Em seguida, Di Nardo e Di Natale (2011) propuseram um procedimento de apoio à decisão que auxilia os projetistas na identificação de distritos com no algoritmo *dijkstra shortest path* (DSP) para a identificação de caminhos de energia mínima dissipada. O modelo ajuda a identificar as entradas dos distritos e os trechos que devem ser fechados para isolar os setores. Apesar de a metodologia determinar distritos com valores de índice de resiliência próximos da rede antes do procedimento de setorização, o modelo não garante que a solução viável seja a solução ótima, uma vez que o algoritmo tem como critério de parada a primeira solução viável.

Alvisi e Franchini (2013) analisaram uma metodologia para a criação automática de DMCs baseado no algoritmo BFS, e no algoritmo DSP. Os resultados obtidos mostram que o procedimento permite identificar boas soluções de resiliência e mínimas pressões. Porém, o modelo é simplificado e fixa o número de setores, além disso, os distritos formados não são isolados.

No ano seguinte, Ferrari, Savic e Becciu (2014) investigaram a criação de DMCs isolados com o auxílio do algoritmo BFS, adotando como critério o tamanho mínimo e máximo dos distritos, a conexão de cada DMC à fonte de abastecimento de água e a ausência de ligações entre os distritos. Um procedimento de bissecção recursiva foi aplicado para determinar os distritos, enquanto um algoritmo foi adotado para verificar o abastecimento dos DMCs e a conectividade entre os nós. O modelo obteve diferentes soluções para a rede de distribuição de água avaliada, atendendo aos critérios de tamanho, pressão mínima e demanda. Portanto, é necessário ainda que o tomador de decisão avalie cada solução para indicar a melhor a ser utilizada no sistema de distribuição de água que se deseja setorizar.

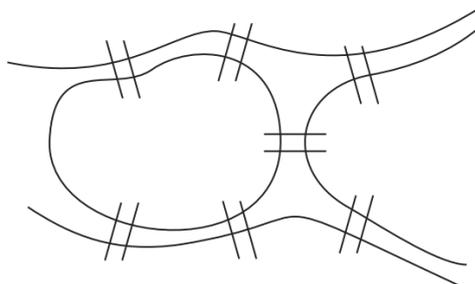
Mais tarde, surgiram abordagens baseadas em modelos de otimização multiobjetivos. Hajebi *et al.* (2015) desenvolveram um modelo de setorização utilizando a teoria dos grafos e otimização multiobjetivo. O modelo proposto se baseia em um novo algoritmo heurístico definido por dois estágios: primeiro gera um conjunto de soluções viáveis estruturalmente (ou seja, soluções que atendem aos requisitos de isolamento de setores, acesso direto a pelo menos uma fonte, limitações de tamanho do distrito e conectividade dos particionados da rede); em seguida, as melhores soluções são identificadas dentro do conjunto de soluções viáveis estruturalmente, considerando os valores de suas funções objetivo, considerando os requisitos hidráulicos e econômicos. A desvantagem desse modelo está relacionada à necessidade de definir uma série de distritos para depois serem analisados, dessa forma, a otimização não tem influência no conjunto de soluções viáveis.

Campbell *et al.* (2015) desenvolveram uma metodologia baseada em conceitos derivados da teoria das redes sociais, algoritmo de Walktrap (PONS; LATAPY, 2006), e na análise do caminho mais curto, também utilizaram o processo de otimização multiobjetivo por meio do algoritmo de PSO. Recentemente, Zhang *et al.* (2019) apresentaram um modelo de setorização utilizando otimização multiobjetivo, baseado no algoritmo genético em conjunto com o algoritmo DSP. No entanto, ambas as metodologias fornecem em diferentes etapas, soluções viáveis, de onde a equipe técnica deve ainda analisar e selecionar a solução mais conveniente.

2.2 Teoria dos Grafos

Grafos são estruturas matemáticas que permitem codificar relacionamento entre pares de objeto. O primeiro problema modelado em um grafo data de 1736 quando um matemático suíço, Leonhard Euler, que demonstrou que não existia solução para o problema das sete pontes de Königsberg (EULER, 1741). A cidade de Königsberg era cortada pelo Rio Pregel, que possuía duas ilhas, conforme a Figura 2. Como era muito complicado fazer o transporte de pessoas e de cargas através de barcos, foram construídas sete pontes para auxiliar no deslocamento entre as duas ilhas e as duas margens. Após algum tempo as pessoas começaram a se perguntar se era possível sair de sua casa, passar por cada ponte exatamente uma vez e voltar para o seu lar.

Figura 2 – Mapa de Königsberg.

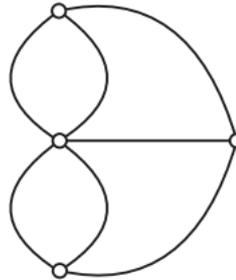


Fonte: A Autora (2021).

Para resolver o problema, Euler montou um diagrama que representasse o mapa da cidade. O pesquisador representou as ilhas e as margens como vértices (pontos) e as pontes como arestas (ligações entre os pontos), conforme a Figura 3. Esse esquema de vértices e arestas é denominado grafo. E a partir desse, Euler provou que tal caminho era impossível,

pois existiam mais de dois vértices com número ímpar de arestas incidentes, ou seja, vértices com grau ímpar. Para o problema ser possível, o grafo deveria conter no máximo dois vértices de grau ímpar (EULER, 1741).

Figura 3 – Grafo de Euler.



Fonte: A Autora (2021).

Após a publicação de Euler, muito se estudou e formulou sobre a teoria dos grafos. A área se tornou bastante difundida, principalmente pela capacidade que os grafos têm de representação de uma grande variedade de problemas. A teoria estuda objetos combinatórios (grafos) que representam problemas em vários ramos da matemática, da informática, da engenharia e da indústria.

2.2.1 Propriedade Matemática dos Grafos

Como já mencionado, um grafo consiste em dois tipos de elementos, nomeados vértices e arestas, ou seja, trata-se de um par (V, A) . Uma aresta pode ser definida como um conjunto de dois vértices e pode ser representada por $\{v_1, v_2\}$. Os grafos podem ser classificados em dirigidos ou não dirigidos. O grafo é dito dirigido (ou direcionado) quando as arestas têm sentido definido, saem de um vértice em direção a outro vértice $\{v_1, v_2\} \neq \{v_2, v_1\}$, nesse caso as arestas são pares ordenados. O grafo não dirigido (ou não direcionado) é composto por arestas que não possuem sentido definido $\{v_1, v_2\} = \{v_2, v_1\}$, logo as arestas não são pares ordenados de vértices.

Os dois vértices de uma aresta são considerados adjacentes ou vizinhos um ao outro. Em grafos não dirigidos, a relação de adjacência entre os vértices é simétrica. A quantidade de vértices presentes em um grafo define a sua ordem, enquanto que a quantidade de arestas o tamanho do grafo.

Em grafos não dirigidos, o grau de um vértice é número de arestas que incidem neste, enquanto nos grafos dirigidos, o grau de um vértice é o número de arestas que saem do vértice

mais o número de arestas que chegam neste. Se todos os vértices de um grafo têm o mesmo grau, o grafo é classificado como regular. Uma proposição útil na teoria dos grafos é que a soma dos graus dos vértices de um grafo é igual ao dobro de número de arestas.

É importante salientar que um caminho é uma sequência alternada entre vértices e arestas. Para cada vértice, do primeiro ao último, há uma aresta conectando os vértices na sequência. Se um grafo é ponderado, isto é, existe um conjunto de pesos associados a cada uma de suas arestas, o comprimento do seu caminho é definido como a soma dos pesos de suas arestas. Nos grafos não ponderados, o comprimento do seu caminho é o número de suas arestas.

Um grafo pode ser chamado de ciclo se, a partir de um determinado vértice, for possível percorrer um caminho que chegue ao mesmo vértice. E ainda, um grafo pode ser classificado como conexo se há um caminho entre qualquer par de vértices, e se não for o caso, ele é chamado desconexo. Um grafo que não contém um ciclo é chamado floresta, e caso a floresta seja um grafo conexo, então é chamado árvore.

É comum representar grafos através de matrizes de adjacência. Uma matriz de adjacência A de um grafo com n vértices é uma matriz $n \times n$, em que:

$$A [v_i, v_j] = 1, \text{ se há aresta entre os vértices } v_i \text{ e } v_j; \text{ e}$$

$$A [v_i, v_j] = 0, \text{ caso contrário.}$$

No caso de grafos não direcionados, a matriz de adjacência será sempre simétrica, e assimétrica no caso de grafos direcionados. Se o grafo for ponderado, a matriz armazena os pesos da aresta, ou seja, o elemento $A [v_i, v_j] = \text{peso}$, ou 0 caso não exista conectividade.

Diante da facilidade em resolver problemas complexos através das estruturas em grafos, diversos pesquisadores desenvolveram algoritmos baseados na teoria dos grafos. Dentre os mais comuns estão os algoritmos *depth-first search* (DFS), *breadth first search* (BFS) e *Dijkstra shortest path* (DSP). Este trabalho utiliza o algoritmo DSP para o projeto de distritos de medição e controle, porque este permite encontrar os menores caminhos que a água percorre do reservatório até os pontos de consumo.

2.2.2 *Dijkstra Shortest Path* (DSP)

O algoritmo *Dijkstra shortest path* (DIJKSTRA, 1959) vem sendo adotado para resolver problemas de caminho mais curto em diversas áreas, tais como: transportes

(CINTRANO; CHICANO; ALBA, 2019), abastecimento de água (RAHMAN; WU, 2018), engenharia mecânica (WU *et al.*, 2017), geologia (ZHANG *et al.*, 2020), esportes (WAHYUNINGSIH; SYAHREZA, 2018), tecnologia da informação (ENAYATTABAR; EBRAHIMNEJAD; MOTAMENI, 2018).

Em termos de peso total das arestas de um grafo definido positivo e ponderado, o algoritmo DSP calcula o caminho mais curto entre um vértice inicial e um vértice final. A representação do grafo pode se dar através da matriz de adjacência A , em que:

$$A [v_1, v_2] = w_{v_1, v_2}, \text{ onde } w \text{ refere-se ao peso da aresta; e}$$

$$A [v_1, v_2] = \text{infinito, se não houver conectividade}$$

Para cada vértice v do grafo, mantém-se um atributo $d[v]$ que representa a estimativa de caminho mais curto. Também se armazena o vértice que precede o vértice $v(p[v])$. O algoritmo de DSP pode ser descrito por meio do Algoritmo 1:

Algoritmo 1: Pseudocódigo do algoritmo DSP

```

1 DSP (A):
2 | Para cada  $v$  em  $A$  faça:
3 | |  $d [v] = \text{infinito}$ 
4 | |  $p [v] = \text{nulo}$ 
5 | Fim
6 |  $d [s] = 0$ 
7 |  $Q = V [A]$ 
8 |  $S = \text{vazio}$ 
9 | Enquanto  $Q \neq \text{vazio}$  faça:
10 | |  $u = \text{mínimo } Q$ 
11 | |  $S = \text{acrescentar } u$ 
12 | | Para cada  $v$  adjacente de  $u$  faça:
13 | | | Se  $d [v] > d [u] + A [u, v]$  faça:
14 | | | |  $d [v] = d [u] + A [u, v]$ 
15 | | | |  $p [v] = u$ 
16 | | | Fim
17 | | Fim
18 | Fim
19 Fim

```

Fonte: Dijkstra (1959).

2.3 Métodos Metaheurísticos

A aplicação de algoritmos de otimização aos problemas da área de Engenharia se intensificou nas últimas décadas. Devido à complexidade de diversos tipos de projetos, cujo espaço de busca aumenta exponencialmente com o número de variáveis de entrada, as técnicas metaheurísticas concebidas como algoritmos inteligentes de autoaprendizagem surgiram para combater eficientemente esse tipo de paradigma de otimização rígida (MANJARRES *et al.*, 2013). Os algoritmos mais recentes são decorrentes de estudos e imitações de processos e comportamentos inteligentes que surgem na natureza, sociologia, biologia, entre outros.

Em especial, os algoritmos bioinspirados, baseados em populações e metaheurística, vêm sendo usados para resolver problemas de busca e otimização em vários domínios de problemas para os quais soluções robustas são difíceis ou impossíveis de encontrar usando abordagens tradicionais como a programação matemática. O princípio fundamental desses algoritmos utiliza um método construtivo para a obtenção da população inicial (soluções factíveis iniciais) e uma técnica de busca local para melhorar a solução da população, considerando que os indivíduos (soluções) dessa população são evoluídos de acordo com regras especificadas que consideram o intercâmbio de informações entre os indivíduos. Esse processo conduz a população em direção à obtenção de uma solução ótima. Tais algoritmos são conhecidos como algoritmos de computação evolutiva, ramo da inteligência computacional (SERAPIÃO, 2009).

Dois abordagens evolutivas baseadas em populações têm se destacado: algoritmos evolutivos e algoritmos de enxames. Os algoritmos evolutivos tradicionalmente incluem algoritmos genéticos (HOLLAND, 1975), programação evolutiva, estratégias evolutivas (JONG, 2006), programação genética (KOZA *et al.*, 2003), algoritmos de estimação de Distribuição (PELIKAN, 2006) e algoritmos genéticos competentes (GOLDBERG, 2002).

Os algoritmos de enxame são um conjunto de técnicas baseadas no comportamento coletivo de sistemas auto-organizados, distribuídos, autônomos, flexíveis e dinâmicos. Estes sistemas são formados por uma população de agentes computacionais simples que possuem a capacidade de perceber e modificar o seu ambiente de maneira local. Esta capacidade torna possível a comunicação entre os agentes, que captam as mudanças no ambiente geradas pelo comportamento de seus congêneres. Embora não exista uma estrutura centralizada de controle que estabelece como os agentes devem se comportar, e mesmo não havendo um método

explícito do ambiente, as interações locais entre os agentes geralmente levam ao surgimento de um comportamento global que se aproxima da solução do problema (SERAPIÃO, 2009).

Os algoritmos de enxame incluem: *ant colony optimization* (DORIGO; MANIEZZO; COLORNI, 1991), *artificial bee colony* (KARABOGA; BASTURK, 2007), *bacterial foraging optimization* (PASSINO, 2002), *shuffled frog-leaping* (EUSUFF; LANSEY, 2003), *krill herd* (GANDOMI; ALAVI, 2012), *spider monkey optimization* (BANSAL *et al.*, 2014), *grey wolf optimization* (MIRJALILI; MIRJALILI; LEWIS, 2014), *ant lion optimizer* (MIRJALILI, 2015a), *moth-flame optimization* (MIRJALILI, 2015b), *whale optimization algorithm* (MIRJALILI; LEWIS 2016), *dragonfly algorithm* (MIRJALILI, 2016), e *particle swarm optimization* (KENNEDY; EBERHART, 1995).

O algoritmo *ant colony optimization* (ACO) foi introduzido por Dorigo, Maniezzo e Colorni (1991), que desenvolveram um modelo computacional com tais conceitos para resolver o famoso problema do caixeiro viajante. O algoritmo proposto baseia-se em um grupo de “formigas artificiais” que liberam feromônio durante o seu trajeto e seguem “trilhas de feromônio artificial” para encontrar o menor caminho entre todas as cidades. O termo algoritmo ACO é um termo genérico que designa um procedimento geral de uma classe de metaheurística baseada no comportamento de formigas. Assim, embora todo algoritmo ACO seja um algoritmo de formiga, o contrário não é verdadeiro.

O *artificial bee colony* é baseado no comportamento das abelhas. Diversas abordagens relativas a diferentes características comportamentais das abelhas foram propostas, produzindo algoritmos distintos (SERAPIÃO, 2009). Lucic e Teodorovic (2001) foram os primeiros pesquisadores a empregar os princípios básicos da inteligência coletiva das abelhas na solução de problemas de otimização combinatorial, introduzindo o algoritmo *Bee System*. Em função dos diferentes mecanismos empregados, o algoritmo de colônia de abelhas pode ser categorizado basicamente em três linhas: comportamento de coleta de alimento, comportamento de acasalamento e conceito de abelha rainha (BAYKASOGLU; OUMLZBAKR; TAPK, 2007).

Dentre os algoritmos baseados no comportamento de coleta de alimento, tem-se: *bee system* (LUCIC; TEODOROVIC, 2001), *beehive* (WEDDE; FAROOQ; ZHANG, 2004), *virtual bee algorithm* (YANG, 2005), *bee colony optimization* (TEODOROVIC; DELL’ORCO, 2005), *bees swarm optimization* (DRIAS; SADEG; YAHY, 2005), *bees algorithm* (PHAM *et al.*, 2006), *artificial bee colony* (KARABOGA; BASTURK, 2007), *bee collecting pollen algorithm* (LU; ZHOU, 2008). Entre os algoritmos baseados no acasalamento desses insetos voadores, tem-se: *marriage in honey-bee optimization*

(ABBASS, 2001), *honey-bee mating optimization* (BOZORG HADDAD *et al.*, 2006). E, por fim, o conceito da abelha rainha pode ser entendido como a partícula fundamental para o desenvolvimento da colmeia, onde as características dos indivíduos serão diretamente dependentes da qualidade da abelha-rainha. Pode-se observar esse método nos algoritmos *queen-bee evolution* (SUNG, 2003) e *bee crossover* (KARA, 2004).

O algoritmo *bacterial foraging optimization* (BFO) foi proposto por Passino (2002). Essa técnica é baseada nas estratégias de localização, manipulação e ingestão de alimentos de células da bactéria *Escherichia Coli*. Para convergir à solução ótima, o algoritmo se baseia no mecanismo chamado quimiotaxia, locomoção orientada das bactérias. Além do BFO, é comum encontrar na literatura o *bacteria chemotaxis* (MULLER *et al.*, 2002), *bacterial swarming algorithm* (TANG; WU; SAUNDERS, 2007), e os algoritmos híbridos *bacterial swarm optimization* (BISWAS *et al.*, 2007) e *bacterial foraging optimization oriented by particle swarm optimization* (KORANI, 2008).

O algoritmo *shuffled frog-leaping* (SFL), proposto por Eusuff e Lansey (2003), foi desenvolvido para resolver problemas de otimização combinatória através da metaheurística. O algoritmo SFL é baseado no comportamento dos sapos, onde um conjunto virtual de sapos é inicializado no espaço de busca, e nesse há um número de pedras em localizações discretas (posições das soluções), nas quais os sapos (soluções) podem saltar para encontrar a pedra que possui a quantidade máxima de alimento disponível. É interessante observar que o algoritmo SFL é uma metáfora de pesquisa cooperativa de base populacional inspirada na memética natural (EUSUFF; LANSEY; PASHA, 2006). Ou seja, os sapos comunicam-se uns com os outros, melhorando seus memes (ideias) usando a informação dos outros. A melhoria de um meme resulta em alterar a posição de um único sapo pela mudança no tamanho do salto (memotipo) do sapo.

O algoritmo de otimização *krill herd* (KH), proposto por Gandomi e Alavi (2012), é inspirado no comportamento de um crustáceo antártico chamado krill. O agrupamento dos indivíduos krill é um processo multiobjetivo, incluindo dois objetivos principais, aumentar a densidade populacional do krill e alcançar os alimentos. Esse processo é levado em consideração na formulação do algoritmo metaheurístico KH para resolver problemas de otimização. A atração dependente da densidade do krill e a localização de alimentos são usadas como objetivos que finalmente levam o krill a se agrupar em torno dos mínimos. Nesse processo, um enxame de krill é inicializado, o individual avança para a melhor solução quando procura a maior densidade e alimento. Ou seja, quanto mais próxima a distância da alta densidade e dos alimentos, menor a função objetivo.

O *spider monkey optimization* é baseado no comportamento social inteligente dos macacos-aranha, e foi introduzido por Bansal *et al.* (2014). Esses indivíduos se organizam em grupos e subgrupos em busca de comida, guiados por um líder em cada conjunto de seres. Existem dois parâmetros de controle importantes necessários para introduzir na estratégia proposta: um é líder global e outro é líder local, que ajuda os grupos e subgrupos a tomarem decisões apropriadas, e convergir para a solução ótima.

O *grey wolf optimization*, proposto por Mirjalili, Mirjalili e Lewis (2014), é inspirado na hierarquia de liderança e nos mecanismos de caça do lobo cinzento. Quatro tipos de lobos cinzentos, como alfa, beta, delta e ômega, são empregados para simular a hierarquia de liderança. A solução mais adequada é representada pelo lobo alfa, consequentemente, a segunda e terceira melhores soluções são denominadas beta e delta, e o restante das soluções candidatas é assumido pelo lobo ômega. Neste algoritmo, a otimização é guiada pelos lobos alfa, beta e delta, que cercam e atacam a solução ótima.

Mirjalili (2015a) propõem o algoritmo *ant lion optimizer* (ALO) para resolver problemas de otimização. O ALO foi inspirado na caça inteligente das larvas das formigas-leão, que constroem armadilhas de funil cônico na areia para capturar presas. As posições das caças (soluções) são conhecidas e armazenadas na matriz. Para avaliar cada posição, uma função de otimização é utilizada, e as posições das formigas-leão é atualizada até o algoritmo determinar a solução ótima.

O algoritmo *moth-flame optimization* foi desenvolvido por Mirjalili (2015b). A principal inspiração deste algoritmo é o método de voo das mariposas, chamado voo de orientação transversal. As mariposas voam à noite mantendo um ângulo fixo em relação à lua, um mecanismo muito eficaz para viajar em linha reta por longas distâncias. No entanto, quando as mariposas veem uma luz artificial, essas tentam manter um ângulo semelhante com a luz para voar em linha reta. Como essa luz é extremamente próxima, manter um ângulo semelhante à fonte de luz causa um caminho espiral inútil. Neste algoritmo, as soluções candidatas são representadas pelas mariposas, e as variáveis do problema são a posição das mariposas no espaço. Portanto, as mariposas podem voar no espaço alterando seus vetores de posição. E as luzes artificiais são as melhores posições assumidas pelas mariposas. Logo, cada mariposa procura em torno de luz artificial e a atualiza no caso de encontrar uma solução melhor. Com esse mecanismo, uma mariposa não perde sua melhor solução.

Recentemente, o *whale optimization algorithm* (WOA) foi proposto por Mirjalili e Lewis (2016), e foi inspirado pelo comportamento de caça das baleias jubartes, que criam uma rede de bolhas na água em torno da presa. Semelhante a outros algoritmos populacionais,

o WOA usa um conjunto de soluções candidatas aleatórias (população) e usa três regras para atualizar e melhorar a posição das soluções candidatas, envolver a presa, atualizar a posição em espiral e buscar a presa. O WOA sofre com convergência prematura, o que faz com que o algoritmo fique preso em ótimos locais. Para superar essa limitação, Bozorgi e Yazdani (2019) propõem o WOA hibridizado com evolução diferencial, que possui boa capacidade de exploração para problemas de otimização de funções. O método é denominado *improved WOA*.

O *dragonfly algorithm* (DA), proposto por Mirjalili (2016), se baseia no comportamento estático e dinâmico do enxame de libélulas. O DA desenvolvido com base na estrutura do algoritmo PSO, para atualizar a posição das libélulas artificiais em um espaço de pesquisa e simular seus movimentos, dois vetores são considerados: passo e posição. Esses vetores armazenam as direções do movimento/velocidade e posição das libélulas, respectivamente. Além do DA, que resolve problemas contínuos, Mirjalili (2016) também propõe o *binary* DA para resolver problemas binários e também o *multi-objective* DA para problemas com mais de uma função objetiva.

O algoritmo *particle swarm optimization* (PSO), traduzido no português para otimização por enxames de partículas, foi introduzido pelo psicólogo social James Kennedy e pelo engenheiro eletricitista Russel Eberhart em 1995 (KENNEDY; EBERHART, 1995). O PSO é inspirado na dinâmica e comportamento “social” observados em muitas espécies de pássaros, insetos e cardumes de peixes, que iniciam a busca por alimentos de forma aleatória, mas que se organizam rapidamente para criar um padrão de busca coletivo.

Além do algoritmo PSO clássico que resolve problemas contínuos através da função monobjetivo, estão disponíveis na literatura diversas modificações. Kennedy e Eberhart (1997) propuseram uma modificação no PSO para manipular variáveis binárias e discretas, o *binary particle swarm optimization* (BPSO). Em seguida, surgiram novos algoritmos BPSO melhorados, tais como: *novel binary* PSO (KHANESAR; TESHNEHLAB; SHOOREHDELI, 2007), *new binary* PSO (NEZAMABADI-POUR; ROSTAMI; FARSANGI, 2008), *binary* PSO baseado na probabilidade (MENHAS *et al.*, 2011), *sticky binary* PSO (NGUYEN; XUE; ANDREAE, 2016), entre outros. Moore e Chapman (1999) propuseram a primeira extensão da estratégia de PSO para resolver problemas multiobjetivos, ou seja, o *multiobjective particle swarm optimization* (MOPSO). No entanto, atualmente existem dezenas de propostas diferentes de MOPSO, aos quais se enquadram nos mais diversos e variados problemas. Além desses, existe os algoritmos híbridos, tendo como exemplo o *Chaotic and Gaussian local search based particle swarm optimization* (CGPSO) proposto por Jia *et al.* (2011), *hybrid*

particle swarm optimization incorporating fuzzy reasoning and a weighted particle (HPSOFW) proposto por Li *et al.* (2015), *Adaptive Learning based PSO Algorithm* (ALPSO) proposto por Wang *et al.* (2018), entre outros.

2.4 Particle Swarm Optimization (PSO)

O algoritmo PSO foi inicialmente proposto para resolver problemas contínuos, faz parte do grupo de algoritmos de enxames inteligentes. Em termos gerais, o algoritmo é inicializado através de uma população de indivíduos, simbolizando o enxame de pássaros, onde cada indivíduo representa uma partícula que se move no espaço de busca. O objetivo do enxame é encontrar o local com comida ou o ninho, representando a solução ótima do problema proposto. O direcionamento da movimentação de cada indivíduo é influenciado pela própria experiência da partícula, sistema cognitivo, e através do conhecimento das partículas vizinhas, sistema social. Portanto, a probabilidade de que um determinado indivíduo tome uma decisão será uma função de seu desempenho no passado e do desempenho de alguns de seus vizinhos.

Kennedy, Eberhart e Shi (2001) utilizaram três princípios para resumir o processo de adaptação cultural: avaliação, comparação e imitação. Na avaliação, os indivíduos possuem a capacidade de sentir o ambiente de forma a estimar seu próprio comportamento. Em seguida, os indivíduos usam uns aos outros como referência comparativa, e por fim, a imitação é central em organizações sociais e é importante para a aquisição e manutenção das habilidades mentais.

Desse modo, o algoritmo PSO emprega dois princípios sócio métricos que representam dois tipos de informações importantes no processo de decisão. O primeiro princípio (*Gbest*) conecta conceitualmente todos os membros de uma população entre si, corresponde a melhor posição no espaço de busca percorrido por alguma das partículas associada a todo o enxame, como consequência, o comportamento de cada partícula é influenciado pelo comportamento de todas as outras partículas. O segundo princípio (*Pbest*) é a melhor posição individual que cada partícula percorreu no espaço de busca. Ambas as métricas são medidas por uma função de avaliação, também chamada função objetivo ou de aptidão, *fitness*, que corresponde à otimalidade da solução do problema.

Nessa técnica de otimização, a posição ocupada por cada partícula representa uma possível solução “x” do problema. Inicialmente, esta posição e velocidade de deslocamento “v” de cada partícula são determinadas aleatoriamente. A cada passo de tempo (iteração), a

qualidade da posição de cada uma das partículas é avaliada de acordo com a função objetivo, e uma nova velocidade é calculada a partir de três parâmetros: sua inércia, sua melhor posição já ocupada $Pbest$, e a melhor posição já encontrada pelo enxame $Gbest$, conforme mostra a Equação 1:

$$v_i^{k+1} = \omega \cdot v_i^k + c_1 \cdot rand_1 \cdot (Pbest_i^k - X_i^k) + c_2 \cdot rand_2 \cdot (Gbest_i^k - X_i^k) \quad (1)$$

Onde: ω corresponde ao peso de inércia; c_1 e c_2 são constantes limitadas a um intervalo finito correspondendo a componentes cognitivo e social, respectivamente; $rand$ gera valores aleatórios entre 0 e 1.

Uma vez que a velocidade da partícula é calculada, a posição da partícula i na próxima iteração é estabelecida como uma influência aditiva da posição antiga e da velocidade calculada, sendo expressa pela Equação 2. Assim, garante-se certa aleatoriedade no processo de busca, além de considerar o desempenho de cada partícula e o desempenho do grupo, o que torna o método rápido e eficiente.

$$X_i^{k+1} = X_i^k + v_i^{k+1} \quad (2)$$

Para limitar a velocidade de uma partícula para que o sistema não extrapole o espaço de busca, são impostos limites, $v_{m\acute{a}x}$, para seus valores em cada dimensão do espaço de busca:

$$\begin{aligned} \text{Se } v_i > v_{m\acute{a}x} \text{ ent\~{a}o } v_i &= v_{m\acute{a}x}, \\ \text{Se } v_i < -v_{m\acute{a}x} \text{ ent\~{a}o } v_i &= -v_{m\acute{a}x}. \end{aligned}$$

O algoritmo PSO é repetido até que um critério de terminação é atingido ou as mudanças nas velocidades das partículas estejam perto de zero. Além disso, o conjunto inicial de partículas X_i é gerado de forma aleatória e espalhado pelo espaço de busca conforme a Equação 3:

$$X_i^I \leq X_i \leq X_i^S \quad (3)$$

Onde: X_i^I e X_i^S correspondem aos limites inferior e superior das posições das partículas, respectivamente. As dimensões das partículas são determinadas pelo problema a ser

otimizado de acordo com o número de variáveis de projeto. O pseudocódigo do algoritmo, em sua forma padrão (topologia global), é descrito no Algoritmo 2.

Algoritmo 2: Pseudocódigo do PSO

```

1 InicializeEnxame ();
2 Inicialize aleatoriamente a posição inicial (x) de cada partícula;
3 Atribua uma velocidade inicial (v) igual para todas as partículas;
5 Para cada iteração faça:
6 | Para cada partícula faça:
7 | | Para cada dimensão faça:
8 | | | Atualiza a velocidade
9 | | | Atualiza a posição
10| | Fim
11| | Calcula o fitness
12| Fim
13| Atualiza o best()
14| Se fitness_atual < melhor_fitness_individual então:
15| | melhor_fitness_individual = fitness_atual;
16| Fim
17| Se fitness_atual < melhor_fitness_vizinhança então:
18| Fim
19 Fim

```

Fonte: Kennedy e Eberhart (1995).

O peso de inércia ω foi adicionado por Shi e Eberhart (1998) para modificar o cálculo, atualizando a velocidade. Esse parâmetro proporciona o equilíbrio entre a exploração global e local, resultando em uma quantidade de iterações menores para encontrar uma boa solução. O peso de inércia ω tem efeito significativo no comportamento do algoritmo, indica a capacidade da partícula em manter sua atual trajetória. Shi e Eberhart (1998) demonstraram que:

Se $\omega < 0,8$ o PSO concentra suas pesquisas em explorações locais.

Se $\omega > 1,2$ o PSO pesquisará globalmente em novas áreas.

Se $0,8 < \omega < 1,2$, é mais provável que o PSO encontre o ideal global após um número médio de iterações.

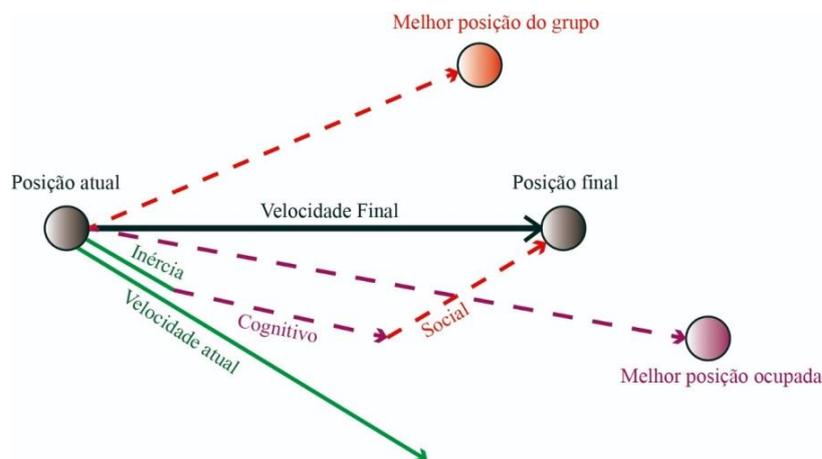
As descobertas sobre o peso da inércia ω levam à proposta de reduzir ω à medida que o algoritmo progride. No início da otimização, valores maiores de ω promove a exploração global, permitindo que o enxame se espalhe mais amplamente para encontrar áreas de solução. Posteriormente, valores menores para ω incentiva a exploração local, o que permite ao enxame pesquisar cuidadosamente em torno das melhores áreas. Desse modo, Shi e Eberhart (1999) propõem utilizar uma variação linear da inércia com um valor inicial de 0,9 e final de 0,4, conforme Equação 4.

$$\omega_i = (\omega_{ini} - \omega_{fim}) \frac{(N-i)}{N} + \omega_{ini} \quad (4)$$

Onde: ω_{ini} e ω_{fim} são os pesos de inércia inicial e final, respectivamente; N é o número total de iterações e i é a iteração atual.

Os fatores cognitivos e sociais, c_1 e c_2 , também influenciam a exploração das partículas no espaço de busca. São comumente definidos com o valor 2 (EBERHART; SHI, 2000). O fator *rand* são valores aleatórios que ajuda a partícula a não se perder em mínimos locais. A Figura 4 ilustra a influência de cada uma das parcelas da velocidade (Equação 1) no processo de busca.

Figura 4 – Influência das parcelas de inércia, cognitiva e social no processo de busca.



Fonte: A Autora (2021).

Além desses parâmetros, Clerc (1999) propôs o uso de um fator de constrição K para garantir a convergência do PSO, demonstrado na Equação 5:

$$K = \frac{2}{(c-2+\sqrt{c^2-4.c})} \quad (5)$$

Eberhart e Shi (2000) mostraram que a abordagem de constrição supera a abordagem padrão com ω se $c > 4$ e $v_{\text{máx}}() = x_{\text{máx}} \cdot v_{\text{máx}}$ é o limite superior e inferior de cada elemento do vetor de velocidade v . $x_{\text{máx}}$ é o intervalo máximo de inicialização de cada elemento do vetor de posição p . O fator K deve ser multiplicado com a velocidade, conforme a Equação 6:

$$v_i^{k+1} = K(v_i^k + c_1 \cdot \text{rand}_1 \cdot (Pbest_i^k - X_i^k) + c_2 \cdot \text{rand}_2 \cdot (Gbest_i^k - X_i^k)) \quad (6)$$

O algoritmo PSO é um método de otimização irrestrito, portanto, funções de penalização devem ser adicionadas à função objetivo para que as condições sejam atendidas. Para cada problema estudado deverão ser formuladas as funções de penalização e objetivo adequadas, utilizando um critério de parada.

2.4.1 Binary Particle Swarm Optimization (BPSO)

Kennedy e Eberhart (1997) propuseram a reformulação do algoritmo PSO para operar em variáveis binárias discretas, essa modificação ficou conhecida como *binary particle swarm optimization* (BPSO). Na versão binária, cada partícula representa sua posição em valores binários 0 ou 1. Nesse caso, a velocidade de uma partícula é definida como a probabilidade de a partícula mudar a sua trajetória para 1. Em outras palavras, se $v = 0,2$, há uma chance de vinte 20% de “x” ser 1, e uma chance de 80% de “x” ser 0.

O espaço de pesquisa no BPSO é considerado como um hipercubo no qual uma partícula pode ser vista se movendo para os cantos mais próximos e mais afastados do hipercubo, invertendo vários números de bits. A velocidade de movimento é definida em termos de mudanças de probabilidades de que um bit estará em um estado ou no outro. Assim, uma partícula se move em um espaço de estado restrito a 0 e 1 em cada dimensão, onde cada “v” representa a probabilidade do bit “x” assumir o valor 1.

Com essa definição, a Equação 1 (velocidade) permanece inalterado, exceto que agora as posições das partículas são números inteiros, 0 ou 1, e o intervalo da velocidade devem ser restringidos em $[0,1]$, uma vez que se trata de probabilidade. A função de normalização usada aqui é uma função sigmoide como pode ser descrita na Equação 7:

$$Sig(v_i^k) = \frac{1}{(1+e^{-(v_i^k)})} \quad (7)$$

Logo, a Equação 1 é usada para atualizar o vetor de velocidade da partícula, enquanto a nova posição da partícula é obtida pela Equação 8. Nesse caso, as partículas do enxame são vistas como probabilidades. Diferente do PSO clássico em que trajetórias são definidas como mudanças de posição, na versão binária do PSO, trajetórias são mudanças na probabilidade de uma partícula assumir um valor zero ou um.

$$\begin{aligned} X_i^{k+1} &= 1, \text{ se } r_i < Sig(v_i^k) \\ X_i^{k+1} &= 0, \text{ caso contrário} \end{aligned} \quad (8)$$

O conceito da velocidade muda totalmente no BPSO. Um valor limite de velocidade provoca a limitação da probabilidade final da posição da partícula. Por exemplo se $v_i^k \text{ máx} = 6$, as probabilidades serão limitadas entre 0,9975 e 0,0025. Vale ressaltar também que, enquanto a velocidade alta aumenta o intervalo explorado por uma partícula na versão do PSO clássico, o oposto ocorre na versão binária; velocidades menores permite uma maior taxa de mutação.

O algoritmo BPSO apresenta dois problemas e preocupações: o primeiro está relacionado com os parâmetros utilizados no método e o segundo está relacionado com a memória das partículas. De fato, a compreensão da velocidade nesse método, difere da compreensão de velocidade na técnica do PSO clássico. Uma das dificuldades encontradas é na escolha do valor adequado para o peso de inércia ω . Para o PSO binário, Khanesar, Teshnehlab e Shoorehdeli (2007) afirmam que:

$\omega < 1$, impede a convergência.

$-1 < \omega < 1$, a velocidade torna-se 0 ao longo do tempo, e $sig(0) = 0,5$.

$\omega > 1$, a velocidade aumenta com o tempo, e todos os bits mudam para 1.

$\omega < -1$, a velocidade diminui com o tempo e todos os bits mudam para 0.

Portanto, o método apresenta um problema, e a remoção do termo de inércia não pode melhorar o BPSO, uma vez que a direção anterior seria perdida. É desejável que o algoritmo seja bastante insensível aos valores selecionados para ω . Usar valores negativos não faz sentido, porque esse termo fornece o efeito de direções anteriores na próxima direção da

partícula. Usar um valor negativo para este parâmetro não é lógico. Além disso, a Equação 8, posição da partícula, é totalmente independente do valor ocupado anteriormente.

Para superar os problemas citados, a literatura cita diversos algoritmos BPSO modificados, aos quais incluem: *novel binary* PSO (KHANESAR; TESHNEHLAB; SHOOREHDELI, 2007), *new binary* PSO (NEZAMABADI-POUR; ROSTAMI; FARSANGI, 2008), *binary* PSO baseado na probabilidade (MENHAS *et al.*, 2011), *sticky binary* PSO (NGUYEN; XUE; ANDREAE, 2016). Foi escolhido, neste trabalho, o algoritmo BPSO apresentado por Khanesar, Teshnehlab e Shoorehdeli (2007), tendo em vista que este é o mais adotado em trabalhos recentes. Nesse novo método, a velocidade de uma partícula é a taxa na qual a partícula altera o valor do seu bit, como na versão clássica do PSO. Além disso, esse método mostra-se mais eficiente que outros algoritmos como algoritmo genético.

Dois vetores para cada partícula são introduzidos V_i^0 e V_i^1 . O vetor V_i^0 é a probabilidade de a partícula mudar para 0, enquanto o vetor V_i^1 é a probabilidade de a partícula mudar seu valor para 1. Como na atualização da Equação dessas velocidades, que será introduzida posteriormente, é utilizado o termo de inércia, essas velocidades não são complementares. Portanto, a probabilidade de alteração no bit da i -ésima partícula é simplesmente definida através da Equação 9:

$$\begin{aligned} V_i^c &= V_i^1, \text{ se } x_i = 0 \\ V_i^c &= V_i^0, \text{ se } x_i = 1 \end{aligned} \quad (9)$$

Dessa forma, a velocidade da partícula é simplesmente calculada. A atualização dos vetores V_i^0 e V_i^1 ocorre da seguinte forma: considere a melhor posição visitada até agora para uma partícula é P_{best} e a melhor posição global para a partícula é G_{best} . Considere também que o bit da i -ésima melhor partícula é 1. Portanto, para guiar o bit da i -ésima partícula para sua melhor posição, a velocidade de mudança para 1 (V_i^1) para essa partícula aumenta e a velocidade de mudança para zero (V_i^0) diminui. Usando esse conceito, as seguintes regras podem ser extraídas através das Equações 10:

$$\begin{aligned} \text{Se } P_{best} &= 1, \text{ então } d_{i,1}^1 = c_1 \cdot rand_1 \text{ e } d_{i,1}^0 = -c_1 \cdot rand_1 \\ \text{Se } P_{best} &= 0, \text{ então } d_{i,1}^1 = -c_1 \cdot rand_1 \text{ e } d_{i,1}^0 = c_1 \cdot rand_1 \\ \text{Se } G_{best} &= 1, \text{ então } d_{i,2}^1 = c_2 \cdot rand_2 \text{ e } d_{i,2}^0 = -c_2 \cdot rand_2 \\ \text{Se } G_{best} &= 0, \text{ então } d_{i,2}^1 = -c_2 \cdot rand_2 \text{ e } d_{i,2}^0 = c_2 \cdot rand_2 \end{aligned} \quad (10)$$

Onde: d_i^0 e d_i^1 armazenam valores temporários. Então, os vetores V_i^0 e V_i^1 podem ser atualizados através das Equações 11 e 12:

$$V_i^1 = \omega \cdot V_i^1 + d_{i1}^1 + d_{i2}^1 \quad (11)$$

$$V_i^0 = \omega \cdot V_i^0 + d_{i1}^0 + d_{i2}^0 \quad (12)$$

De fato, neste algoritmo, se a melhor variável global for zero ou se a melhor variável local for zero, a velocidade V_i^0 será aumentada. E a probabilidade de mudar para 1 também diminui com a mesma taxa. Além disso, se a melhor variável global for um 1 V_i^1 é aumentado e V_i^0 diminui. Nesta abordagem, a direção de mudança encontrada anteriormente é mantida e usada para que as partículas utilizem a direção encontrada anteriormente, ou seja, a memória é armazenada. Depois de atualizar a velocidade das partículas, a velocidade da mudança é obtida na Equação 9 e um processo de normalização é realizado. Usando a função sigmoide, conforme apresentado na Equação 7. E então o próximo estado das partículas é calculado a partir da Equação 13:

$$X_i^{k+1} = \overline{X}_i^k, \text{ se } r_i < \text{Sig}(v_i^k) \quad (13)$$

$$X_i^{k+1} = X_i^k, \text{ caso contrário}$$

Onde: $\overline{X}_i^k = 1$ se $X_i^k = 0$, e $\overline{X}_i^k = 0$ se $X_i^k = 1$. O significado dos parâmetros usados no cálculo da velocidade (Equação 6) são exatamente iguais aos do PSO clássico (contínuo). O peso da inércia mantém a direção anterior dos bits da partícula para o melhor bit pessoal ou o melhor bit global, seja 1 ou 0. Além disso, o significado da velocidade é o mesmo que o significado da velocidade na versão contínua do PSO, que é a taxa de variação na posição das partículas. Também como no PSO contínuo, se o valor máximo de velocidade considerado for grande, a pesquisa aleatória ocorrerá. Valores pequenos para velocidade máxima fazem com que a partícula se mova menos. Aqui também os estados anteriores dos bits das partículas estão levando em consideração, enquanto no PSO binário, apenas a velocidade determina o próximo valor da partícula.

Esse novo método proposto por Khanesar, Teshnehlab e Shoorehdeli (2007) foi aplicado em diversas áreas de pesquisa, tais como em Prescilla e Selvakumar (2013a, 2013b), e Scheel *et al.* (2015). Prescilla e Selvakumar (2013a) identificaram a melhoria do desempenho do método, enquanto a Prescilla e Selvakumar (2013b) comprovaram a eficácia

do algoritmo, demonstrando a necessidade de poucas iterações para alcançar soluções viáveis. Scheel *et al.* (2015) maximizaram a injeção de energia renovável em um sistema, além disso o bom desempenho do algoritmo para encontrar soluções ótimas mesmo em redes altamente congestionadas, com tamanho de enxame pequeno, permitiu o uso eficaz na operação e planejamento do sistema.

2.5 Síntese Conclusiva

Neste capítulo foram apresentados os conceitos e fundamentos sobre a setorização em sistemas de distribuição de água, seus benefícios, modelos propostos e estudos de casos. Além disso, foram apresentados conceitos da teoria dos grafos e dos métodos metaheurísticos, em especial o algoritmo *particle sawarm optimization*.

A revisão de literatura sobre as técnicas e projetos de distritos de medição e controle permitiu o desenvolvimento do senso crítico sobre as principais características e dificuldades desse tópico. Desta revisão, verificou-se que alguns modelos citados possuem limitações para serem aplicados em sistemas reais. Nos resultados dos modelos fundamentados na detecção de comunidade é necessária a modificação dos principais parâmetros para obter mais resultados, já que somente um resultado é obtido. Além disso, os diâmetros das tubulações são geralmente considerados como os pesos sem levar em conta os fatores hidráulicos (CAMPBELL *et al.*, 2015). A otimização do desempenho hidráulico e a eficiência na redução de vazamentos são indispensáveis independentemente do modelo utilizado.

Outra questão importante de ser mencionada é que a otimização de objetivo único é comumente usada na maioria dos modelos citados. No entanto, o projeto de DMC é um problema complexo em redes de distribuição de água, e mais de um objetivo devem ser considerados. Muitos fatores, como estabilidade de pressão, economia do projeto de reconstrução e tamanho e homogeneização dos distritos, também devem ser levados em consideração.

O problema de setorização é caracterizado por requisitos estruturais e hidráulicos que tornam as técnicas existentes de particionamento de grafos inadequadas para encontrar uma boa solução. É verdade que a topologia da rede de distribuição de água pode ser representada através de estruturas de grafos e diminuir a complexidade do problema. No entanto, na divisão de grafos não é possível obter a melhor solução em um tempo de computação razoável, quando o tamanho do grafo aumenta, pode-se presumir que o tempo de execução de um algoritmo capaz de resolver o problema cresça exponencialmente. Portanto, métodos

metaheurísticos devem ser considerados para obter soluções ótimas em um tempo razoável. O *binary particle swarm optimization*, apresentando neste capítulo, mostra-se um algoritmo apropriado para resolver esse problema.

Diante das limitações apresentadas, foi identificadas as oportunidades de pesquisa que motivaram o presente estudo sobre projetos de setorização. Assim, como proposta este trabalho busca desenvolver um modelo que combine técnicas fundamentadas na teoria dos grafos e técnicas metaheurísticas, que seja capaz de projetar distritos ótimos de medição e controle em sistemas de distribuição de água, de forma a atender às restrições impostas e superar as limitações encontradas na literatura.

3 MATERIAIS E MÉTODOS

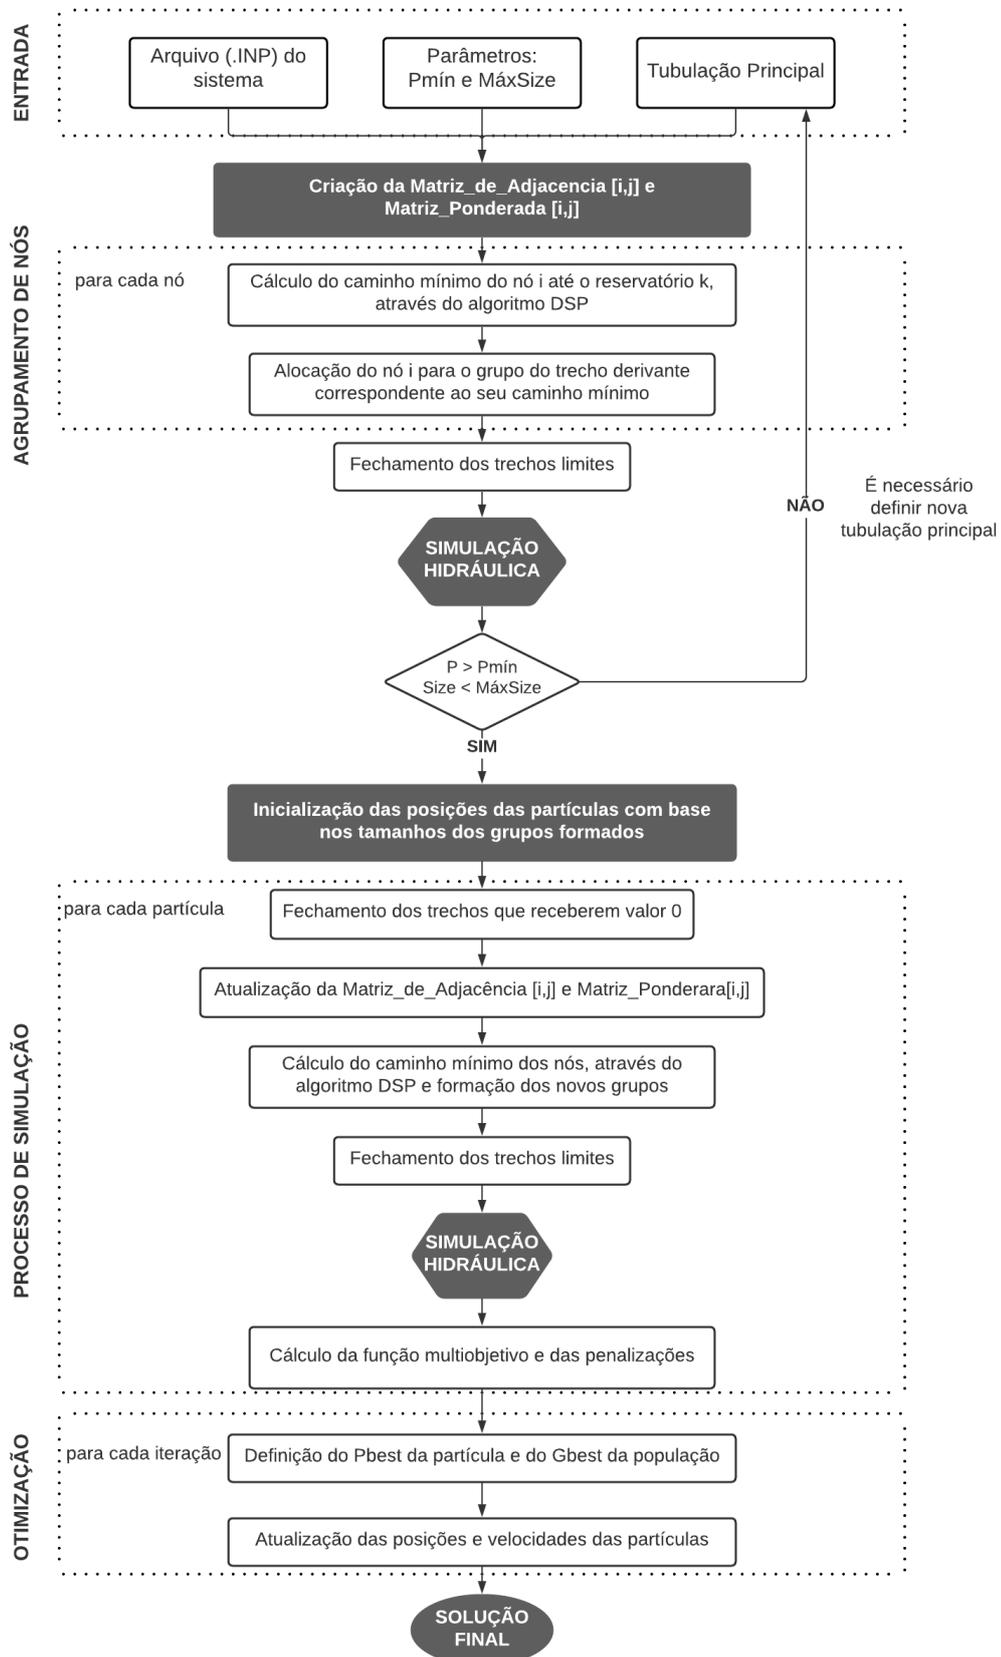
A pesquisa utilizada neste trabalho é descritiva e exploratória. A abordagem de setorização proposta foi desenvolvida na linguagem de programação Python através do *integrated development environment* (IDE) livre PyCharm Community 2019.3.1, com o auxílio da biblioteca Epanettools, pacote que permite ao usuário utilizar todas as funções do kit de ferramentas do *software* EPANET 2.00.12 nos *scripts* Python.

De modo geral, os DMCs são definidos através da inserção de válvulas de seccionamento (registros) de modo a agrupar nós e trechos em setores isolados. Localizar os trechos que devem receber válvulas e medidores de vazão foi o objetivo da pesquisa. As válvulas de seccionamento devem ser inseridas em trechos que se deseja fechar o fluxo, para isolar os setores ou limitar as tubulações de entrada do setor. Os medidores de vazão devem ser instalados na entrada dos distritos, a fim de possibilitar o controle e gestão dos sistemas.

Com vista à obtenção da solução para o problema proposto, a metodologia foi constituída fundamentalmente por: (1) Definição da tubulação principal; (2) transformação da topologia da rede de distribuição de água em estrutura de grafos e agrupamento dos nós com o auxílio do algoritmo DSP (DIJKSTRA, 1959) e, (3) otimizar a criação de DMCs. Inicialmente, os dados da rede, que se deseja realizar a setorização, são lidos a partir do arquivo de entrada (.INP) gerado no *software* Epanet, através da biblioteca Epanettools. O projetista deve definir a tubulação principal e informar parâmetros tais como a pressão mínima do sistema e tamanho máximo que os distritos devem possuir. O Fluxograma 1 apresenta as etapas do modelo proposto.

O modelo é baseado no trabalho de Zhang *et al.* (2019), fundamentado no desenvolvimento de uma abordagem inovadora e adaptada do algoritmo de Dijkstra, baseado na análise do caminho mais curto para o agrupamento de nós combinado com técnicas para otimizar a formação dos distritos. Além disso, tendo em vista a complexidade do problema, um algoritmo *binary particle swarm optimization* (BPSO) foi desenvolvido para buscar a melhor combinação de condição do trecho (aberto ou fechado) enquanto satisfaz as condições de restrição.

Fluxograma 1 – Etapas do modelo híbrido de setorização proposto.



Fonte: A Autora (2021).

O algoritmo BPSO foi adotado porque o problema é caracterizado como discreto e binário, onde a configuração do trecho pode assumir o valor 0 (tubulação fechada) ou 1 (tubulação aberta). Essa abordagem vem se destacando em problemas de otimização, uma vez que é necessário menos indivíduos e iterações para convergir para uma solução ótima, acarretando em menos tempo de processamento. Este foi um dos motivos pelos quais foi adotado o algoritmo BPSO na pesquisa. Vale ressaltar que este método metaheurístico não foi aplicado em nenhum estudo com a esta finalidade.

3.1. Tubulação Principal

Definir a tubulação principal consiste em uma etapa importante para o projeto ótimo, uma vez que este determinará as tubulações derivantes e conseqüentemente o designe ótimo da setorização. O projetista precisa definir o conjunto de tubulações que constituirão a tubulação principal do sistema, e informar o identificador de cada trecho.

No geral, a tubulação principal é composta por tubulações de grandes diâmetros e conseqüentemente transportarem grande quantidade de água, sua origem parte do reservatório, e devem alimentar os DMCs formados posteriormente. Uma vez definida esta tubulação, foram identificados os trechos que serão variáveis de decisão (tubulações derivantes), isto é, trechos que podem receber seccionamento (registros) ou medidores de vazão. Esses trechos estão conectados diretamente com a tubulação principal.

3.2. Agrupamento de Nós

Após a definição da tubulação principal, o modelo transformou a topologia da rede de distribuição de água em estruturas de grafos não dirigidos, onde os vértices representam os nós e as arestas representam os trechos, sem sentido definido. Para essa representação, uma matriz de adjacência foi construída para relacionar as conexões existentes entre os nós, onde:

$$\begin{aligned} \text{Matriz_de_Adjacência } [i, j] &= 1, \text{ se houver trecho entre o nó } i \text{ e nó } j \\ \text{Matriz_de_Adjacência } [i, j] &= 0 \text{ caso contrário.} \end{aligned}$$

Além da matriz de adjacência, foi necessária a elaboração da matriz ponderada para a realização de agrupamento dos nós. A matriz ponderada foi definida como:

Matriz_Ponderada [i, j] = “peso” se houver trechos entre o nó i e nó j
 Matriz_Ponderada [i, j] = “infinito”, caso contrário.

A partir da representação da topologia através de matrizes, o modelo agrupou os demais nós que não estão na tubulação principal, com base no caminho mais curto. Para isso, o algoritmo DSP (DIJKSTRA, 1959), descrito no Algoritmo 1 (Item 3.2.2), deve ser utilizado para encontrar o caminho ótimo da água entre o nó i e o ponto final k (reservatório). Em combinação da Matriz_Ponderada, com valores dos pesos dos trechos, foi obtido o menor caminho a partir da Equação 14:

$$distância_{ki} = \sum w_t t \in \{caminho_{ki}\} \quad (14)$$

Onde: w_t é o peso do trecho t ; $\{caminho_{ki}\}$ é o conjunto de trechos que correspondem ao caminho mais curto entre o nó inicial k (reservatório) e o nó i .

O coeficiente de resistência da tubulação, calculado pela fórmula de Hazen-Williams, foi utilizado como valor para o peso da tubulação, conforme a Equação 15:

$$wt = 10.67 \cdot C_t^{-1.852} \cdot d_t^{-4.871} L_t, \quad t = 1, 2, \dots, T \quad (15)$$

Onde: C_t é o coeficiente de rugosidade de Hazen-Williams da tubulação do trecho t ; d_t é o diâmetro da tubulação do trecho t ; L_t é o comprimento do trecho t , e T é a quantidade de trechos.

Por consequência, os nós são agrupados de modo a compartilharem o mesmo trecho derivante, trechos conectados diretamente na tubulação principal. Este procedimento é descrito brevemente no Algoritmo 3.

Os distritos formados representam o conjunto de caminhos (trechos) que possuem menores resistências. A quantidade de DMCs gerados, representa o número máximo de setores que a rede analisada comportaria, implicando em alto custo de operação e inviabilidade técnica de implementação, logo se torna necessária a utilização de mais uma etapa para mesclar os distritos, obtendo a solução final.

Algoritmo 3: Pseudocódigo do algoritmo para o agrupamento de nós

```

1 Distritos ( ):
2 | Para cada nó faça:
3 | | DSP (nó, k (reservatório))
4 | | Para cada trecho_derivante faça:
5 | | | Se caminho_curto (nó) = trecho_derivante faça:
6 | | | | Distrito (trecho_derivante ) = + nó
7 | | | Fim
8 | | Fim
9 | Fim
10 Fim

```

Fonte: A Autora (2021).

Vale ressaltar também que os trechos derivantes que fazem parte do conjunto do caminho mais curto de um nó qualquer são as variáveis de decisão, e poderão indicar a entrada de um distrito. Enquanto os trechos derivantes que não foram selecionadas em nenhum caminho mais curto deverão permanecer fechados, diminuindo dessa forma, a quantidade de variáveis de decisão.

3.3. Otimização dos Distritos de Medição e Controle

Para solucionar o problema de otimização aqui proposto, optou-se pelo uso da técnica de otimização metaheurística *binary particle swarm optimization* dada sua robustez e velocidade de processamento. No algoritmo BPSO, proposto por Khanesar, Teshnehlab e Shoorehdeli (2007), cada partícula representa sua posição em valores binários 0 ou 1, e a velocidade pode ser interpretada como na versão do PSO clássico, ou seja, representa a taxa de variação de bits de partículas.

Para cada iteração, foi necessário realizar a simulação do sistema de distribuição de água, caracterizado pela nova setorização, através da biblioteca Epanettools, e o novo desempenho é investigado calculando a função objetivo. Logo, a implementação da técnica de setorização dentro da classe BPSO se tornou essencial.

A posição da partícula informa a situação dos trechos de derivação, indicando se a trecho deverá permanecer aberta (1) ou fechada (0). A cada iteração uma nova topologia da rede é formada com as novas conexões, logo, é preciso atualizar a Matriz_de_Adjacência e a Matriz_Ponderada, e calcular os novos caminhos mais curtos com a utilização do algoritmo DSP, formando novos distritos. A partir dos novos distritos criados, foram identificados os

trechos limites, que são trechos que conectam dois DMCs. É imprescindível inserir válvulas de seccionamento nessas tubulações de modo que os setores sejam isolados.

Realizadas as mudanças necessárias na rede, inserção de válvulas de seccionamento nos trechos que devem permanecer fechadas e medidores de vazão nos trechos de entrada dos distritos, fazem-se as simulações e cálculos de restrição e função objetivo para todas as iterações. Este procedimento é descrito brevemente no Algoritmo 4.

Algoritmo 4: Pseudocódigo do algoritmo de extensão do BPSO

```

1 Inicialize o Enxame ( ):
2 Para cada Iteração faça:
3   | Para cada Partícula faça:
4   | | Feche os trechos que receberem o valor 0
5   | | Atualize a matriz_dijkstra com a nova topologia
6   | | Distritos ( )
7   | | Feche os trechos_limites
8   | | Simule o modelo hidráulico
9   | | Calcule a função objetivo
10  | Fim
11  | Iteração ++
12 Fim

```

Fonte: A Autora (2021).

3.3.1. Função Objetivo

A otimização do projeto ótimo de distritos de medição buscou a redução da pressão do sistema, de modo a minimizar as perdas de água reais, sem afetar o atendimento às demandas dos consumidores, além de minimizar os custos de implantação do projeto. Desse modo, o modelo utiliza a função objetivo descrita na Equação 16, considerando os custos dos dispositivos necessários para a implementação do projeto, pressão do sistema e tamanho dos DMCs.

$$FO = CD + Pen \tag{16}$$

Onde: FO é a função objetivo a ser minimizada, CD é o custo dos dispositivos (válvulas de seccionamento e medidores de vazão), e Pen corresponde à função de penalização.

A função de penalização foi baseada nas restrições do problema. Neste caso, é considerada a pressão mínima (P_{min}) dos nós e também o tamanho máximo ($máxSize$) dos distritos. Assim a penalização foi calculada através da Equação 17:

$$Pen = Pen_{pressão} + Pen_{SizeDMA} \quad (17)$$

Minimizando os custos dos dispositivos: O projeto ótimo de DMC tem como objetivo minimizar os custos dos dispositivos necessários para a setorização. A função de custos foi calculada conforme a Equação 18.

$$CD = \sum_{j=1}^{kválvula} C_{válvula}(D_j) + \sum_{m=1}^{kmedidor_vazão} C_{medidor_vazão}(D_m) \quad (18)$$

Onde: CD é a função custo, $C_{válvula}$ é o custo da válvula de seccionamento em função do diâmetro D da tubulação do trecho j , $C_{medidor_vazão}$ é o custo do medidor de vazão, $k_{válvula}$ é o número total de válvulas de seccionamento, $k_{medidor_vazão}$ é o número total de medidores de vazão.

A função objetivo proposta minimizou os custos com dispositivos utilizados para a setorização, reduzindo a sua quantidade e/ou inserindo-as em tubulações de diâmetros menores. Foram considerados os custos dos dispositivos adotados em Zhang *et al.* (2019), convertidos em real, considerando que 1 RMB (Renminbi) equivale a R\$ 0,82, cotação realizada em janeiro de 2021 (Tabela 1).

Tabela 1 – Valores das válvulas de seccionamento e medidores de vazão em R\$.

Diâmetro (mm)	Custo do medidor de vazão (R\$)	Custo da válvula de seccionamento (R\$)
150	13.706,00	3.465,00
200	15.554,00	4.104,00
250	17.479,00	4.581,00
300	19.327,00	5.120,00
400	25.564,00	5.559,00
450	29.337,00	7.777,00
500	32.956,00	10.01,00
600	36.652,00	14.707,00
700	40.810,00	20.944,00
800	44.583,00	24.717,00
1000	49.280,00	30.030,00
1200	54.439,00	35.574,00
1500	71.610,00	41.272,00
1800	86.240,00	46.354,00

Fonte: Zhang *et al.* (2019).

Minimizando a pressão do sistema: Para garantir a confiabilidade do sistema, a pressão em todos os nós deve permanecer acima da pressão mínima estabelecida. Desse modo, a função penalização de pressão $Pen_{pressão}$ foi calculada através da Equação 19:

$$Pen_{pressão} = \sum_{i=1}^N \alpha |P_{mín} - P_n| \quad (19)$$

Onde: N é o número total de nós, α é o fator de penalização, $P_{mín}$ é a pressão estabelecida por norma, e P_n é a pressão no nó i .

Desse modo, a função de penalização de pressão garante que a minimização da pressão não resulte em soluções infactíveis, que não satisfaçam a restrição de pressão mínima, garantindo a confiabilidade do sistema.

Maximizando o tamanho dos distritos: De modo a garantir a restrição do tamanho máximo dos DMCs, a função de penalização foi definida conforme a Equação 20. Essa penalização também permite a homogeneidade do tamanho dos distritos. Foi adicionado uma extensão máxima para os DMCs. O usuário precisa definir tal parâmetro para o modelo alcançar soluções dentro das restrições.

$$Pen_{SizeDMA} = \sum_{j=1}^M (\beta |máxSize - SizeDMC_j|) \quad (20)$$

Onde: M é o número de distritos, β é o fator de penalização, $máxSize$ é a extensão máxima dos distritos, e $SizeDMC$ é a extensão do distrito j .

Os fatores de penalização α e β foram obtidos através de testes de verificação. É importante que esses valores sejam significativos, de modo que o algoritmo de otimização reconheça a solução ótima. Diferentemente de outros algoritmos de otimização, que apresentam um conjunto de soluções factíveis (conjunto de Pareto), o modelo converge para uma única solução factível, isso foi possível através dos valores atribuídos aos fatores de penalização, hierarquizando o critério mais importante considerado pelo projetista.

3.3.2. Variáveis de Decisão

O problema do projeto ótimo de distritos é um problema de combinação das condições dos trechos, abertas (1) ou fechadas (0). Para garantir que os setores sejam isolados, algumas tubulações deverão permanecer fechadas. Ao definir a delimitação dos DMCs, foram identificados os trechos limites, que são trechos cujos nós inicial e final estão localizados em diferentes distritos. Tais trechos limites foram fechados, conforme a Equação 21:

$$\forall \text{ tubulação}_j \in \{\text{tubulações limites}\}, x(j) \in (0) \quad (21)$$

Enquanto isso, os trechos que partem da tubulação principal e conectam os possíveis distritos (tubulação derivantes) são as variáveis de decisão do problema. Através de combinações, as melhores soluções foram identificadas. Nesse conjunto, os trechos que permanecerem abertos receberam medidores de vazão, e os demais receberam válvulas de seccionamento. Tais trechos são expressos por meio da Equação 22:

$$\forall \text{ tubulação}_j \in \{\text{tubulação derivantes}\}, x(j) \in (0,1) \quad (22)$$

3.3.3. Restrições

Para tornar o modelo e os resultados satisfatórios, as seguintes restrições foram impostas ao modelo híbrido:

I. Distritos isolados: Tendo em vista a criação de distritos independentes e eficientes, não deve haver interseções de nós entre dois DMCs. A Equação 23 demonstra a restrição matematicamente.

$$\forall I, J \in \{1, \dots, M\}, \text{nós}_I \cap \text{nós}_J = \emptyset \quad (23)$$

Onde: nós_I e nós_J pertencem a distritos diferentes; M é o número de distritos.

II. Requisitos hidráulicos: A conservação da massa e a conservação da energia devem ser garantidas, como mostrado nas Equações 24 e 25, respectivamente. O modelo garante os requisitos hidráulicos através dos cálculos realizados pela biblioteca Epanettools, integrada no ambiente PyCharm.

$$\sum Q_{entra} - \sum Q_{sai} - Q_n = 0 \quad (24)$$

$$H_{Fj} - H_{Tj} = h_j \quad (25)$$

Onde: Q_{entra} e Q_{sai} representam o fluxo de entrada e saída do nó n , respectivamente; Q_n representa a demanda do nó n ; H_{Fj} e H_{Tj} representam a energia do nó final e inicial do trecho j , respectivamente; e h_j representa a perda de carga na tubulação do trecho j .

III. Pressão mínima: A pressão em todos os nós deve ser maior que a pressão mínima requerida, conforme a Equação 26. A NBR 12218 (ABNT, 2017) estabelece a pressão mínima de 10 mca, valor adotado nesse trabalho. O modelo garantiu a pressão mínima através da função de penalização (Equação 26) acoplada à função objetivo.

$$P_n \geq P_{min} \quad (26)$$

IV. Tamanho do DMC: As dimensões mínimas foram consideradas na análise da viabilidade técnica e econômica da função objetivo, conforme a Equação 27. Assim como a restrição da pressão mínima, a restrição do tamanho dos distritos é garantida através da função de penalização. O projetista precisa informar, como dado de entrada, o valor do *máxSize*, tamanho máximo dos distritos.

$$máxSize \leq SizeDMA \quad (27)$$

Diferentemente de problemas contínuos solucionados pelo PSO clássico, em problemas discretos não é necessário definir limite do espaço de busca. Além disso, deve-se ter atenção na definição do número de partículas e número de iterações, uma vez que a biblioteca Epanettools permite somente realizar 160 simulações hidráulicas. Logo, para o modelo convergir a bons resultados de modo mais rápido, foi necessário inicializar as partículas numa posição relativamente favorável. A posição inicial está relacionada com as extensões do agrupamento dos nós descrita no item 3.2 (agrupamento de nós), de modo que os trechos (variáveis de decisão) que alimentam os grupos de maiores extensões devem inicializar na posição 1 (aberto), enquanto os trechos que alimentam os grupos de menores extensão devem inicializar na posição 0 (fechado).

Por fim, foram estimados os volumes de perdas e água antes e depois da setorização, através do método *Fixed and Variable Area Discharges* (FAVAD), expressado através da Equação 28, sugerida por May 1994.

$$\frac{Q_{v1}}{Q_{v2}} = \left(\frac{P_1}{P_2} \right)^{N_1} \quad (28)$$

Onde: Q_{v1} e Q_{v2} representam vazões de vazamento e P_1 e P_2 representam as pressões no sistema nos respectivos momentos; e N_1 é o expoente que depende do tipo de material da tubulação (0,5 para tubos de materiais metálicos; 1,0 para casos de desconhecimento do sistema; 1,5 para orifícios com perdas de águas indetectáveis e que são sensíveis a variação de pressão, independentemente do material dos tubos; E entre 1,5 e 2,5 para orifícios com grandes perdas de água e em tubulações plásticas).

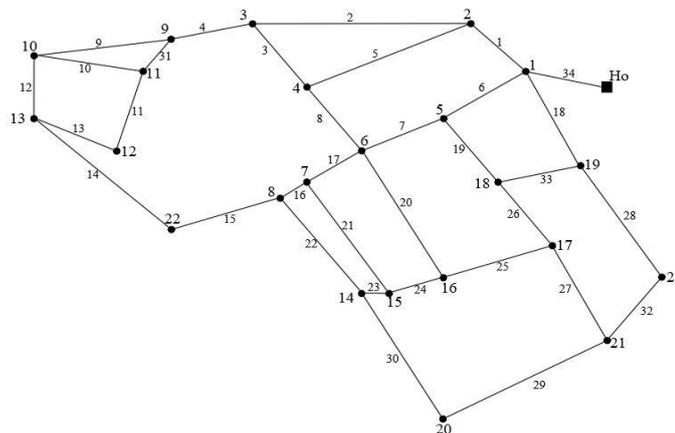
4 RESULTADOS E DISCUSSÕES

No capítulo anterior foi apresentada a abordagem proposta para o projeto de distritos de medição e controle. Contudo, é importante demonstrar a sua aplicação para verificar as consequências do projeto em redes de distribuição de água diversas. Assim, neste capítulo apresenta e discute os resultados da aplicação da metodologia na Rede Apulian e em três sistemas de distribuição de água, reais e complexos, localizados na cidade de João Pessoa-PB. Os resultados obtidos foram comparados com a setorização realizada pela Hidrainfo, empresa especializada contratada pela Companhia de Água e Esgotos da Paraíba (CAGEPA).

4.1. Rede Apulian

Com o intuito de avaliar e validar o modelo híbrido proposto utilizou-se a rede fictícia Apulian (GIUSTOLISI; SAVIC; KAPELAN, 2008), ao qual possui um reservatório que fornece água por gravidade para 23 nós através de 34 trechos (Figura 5). Adicionalmente, foi adotado que todos os trechos possuem uma parcela de vazamento com índice de 30% de perdas de água.

Figura 5 – Rede Apulian.



Fonte: Giustolisi, Savic e Kapelan (2008).

Visto que a configuração original da Rede Apulian resulta em pressões baixas, inclusive abaixo da mínima estabelecida pela NBR 12218 (ABNT, 2017), de 10 mca, foi adotada a cota do nível de água do reservatório de 100 m. Dessa forma, foi possível aplicar a abordagem de setorização proposta nessa pesquisa.

A definição da tubulação principal foi definida como o conjunto dos trechos 6, 7, 16, 17, 22 e 30 e 34, visto que os mesmos possuem as maiores vazões e iniciam a partir do reservatório. Em seguida, foram definidos os parâmetros do BPSO e as configurações do projeto de setorização, os valores de c_1 e c_2 (constantes relacionadas aos fatores cognitivo e social, respectivamente), e ω (peso de inércia) foram os mesmos valores adotados por Khanesar, Teshnehlab e Shoorehdeli (2007).

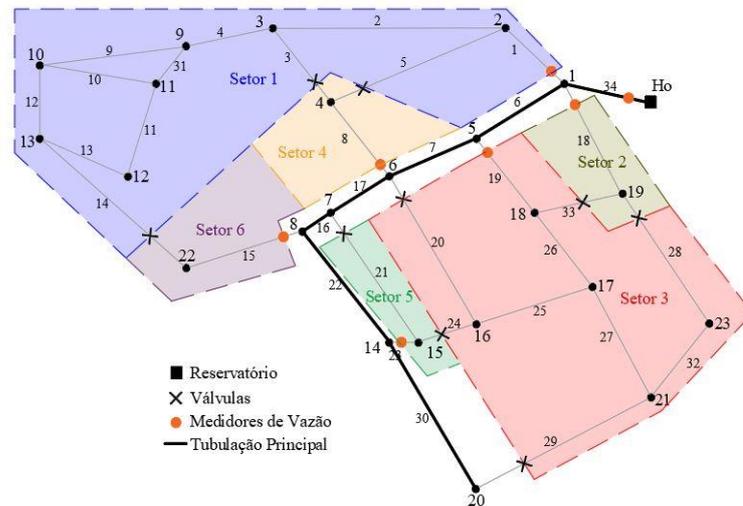
- $c_1 = 1$
- $c_2 = 1$
- $\omega = 0,5$
- Número de partículas = 4
- Número de iterações = 20
- $P_{min} = 10$ mca
- $N_1 = 2$

Após a leitura de entrada do arquivo (.INP), foram criadas as matrizes para representação da topologia em grafo e, em seguida, definidos seis DMCs através do agrupamento de nós descrito na Seção 3.2 (Figura 6). Logo, para este projeto de setorização, seriam necessários seis medidores de vazão, localizados nos trechos 1, 8, 15, 18, 19 e 23, e nove válvulas de seccionamento para o fechamento dos trechos 3, 5, 14, 20, 21, 24, 28, 29 e 33, de modo que os distritos se mantenham isolados e abastecidos através de uma única tubulação de entrada.

Esta configuração representa uma solução não otimizada, com alto custo e presença de muitos distritos pequenos. No entanto, esses distritos precisam ser mesclados para que seus tamanhos sejam equilibrados. Logo, os DMCs formados representarão a posição inicial da partícula do enxame, sendo variáveis de decisão os trechos 1, 8, 15, 18, 19 e 23. Estas iniciarão na posição 1, aberta. Os trechos 20, 21 e 29 não fazem parte do conjunto de trajetória mínima de nenhum nó da rede, desse modo, estas devem permanecer fechadas, diminuindo a quantidade de variáveis de decisão.

Neste estudo de caso, por se tratar de uma rede de pequeno porte, não foi aplicada a função de penalização de tamanho dos distritos, apenas a penalização da pressão foi aplicada. O valor de α foi adotado igual a 10, garantindo a convergência para ótima solução dentro da restrição imposta. Em relação aos custos dos dispositivos foi considerado os valores adotados em Zhang *et al.* (2019), conforme a Tabela 1.

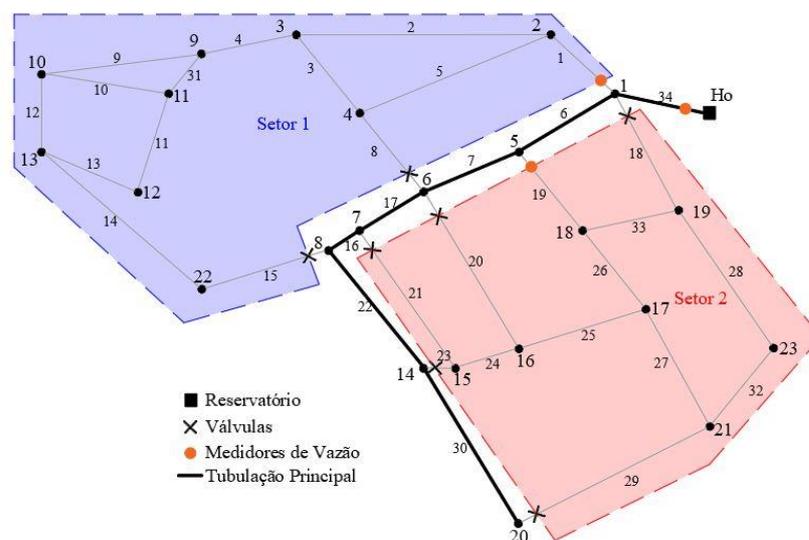
Figura 6 – Setorização da Rede Apulian através do algoritmo DSP.



Fonte: A Autora (2021).

Os algoritmos de otimização BPSO padrão (KENNEDY; EBERHART, 1997) e BPSO modificado (KHANESAR; TESHNEHLAB; SHOOREHDELI, 2007) foram aplicados para otimizar o processo de setorização da rede. Ambos os algoritmos convergiram para a mesma solução, apresentando dois DMCs. Os trechos 1 e 19 foram selecionados para alimentar os distritos, ambos trechos devem receber a instalação de medidores de vazão. As válvulas de seccionamento deverão ser instaladas nos trechos 8, 15, 18, 20, 21, 23 e 29, isolando os DMCs. A solução é ilustrada na Figura 7.

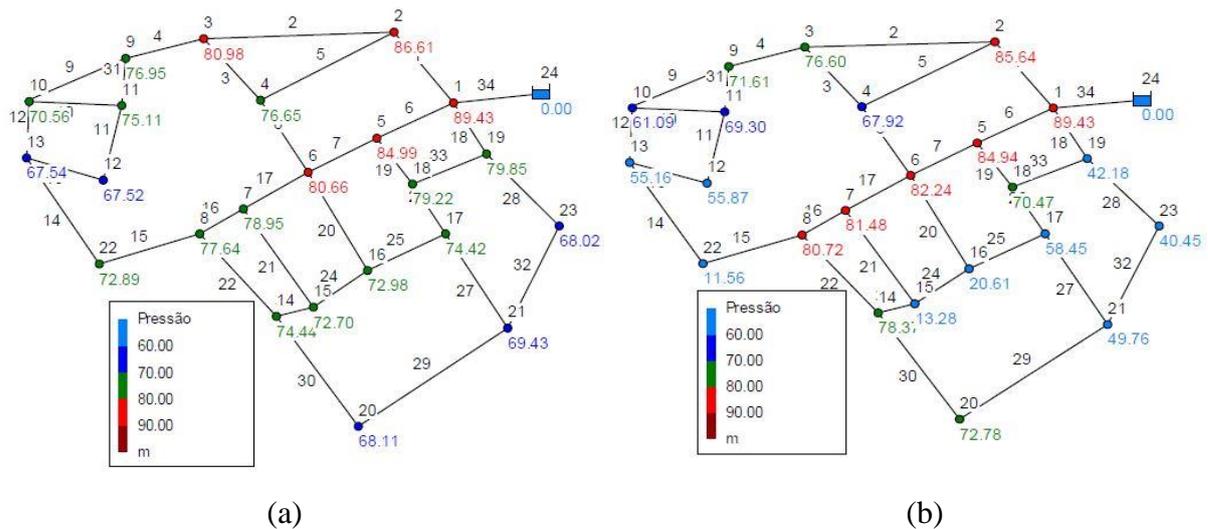
Figura 7 – Solução otimizada da setorização da Rede Apulian.



Fonte: A Autora (2021).

O custo total referente aos valores dos dispositivos foi de R\$ 68.919,57, sendo R\$ 25.661,05 os custos das válvulas de seccionamento e R\$ 43.258,52 os dos medidores de vazão. Essa reestruturação implicou na redução de pressão do sistema. O Mapa 1 apresenta as pressões da rede Apulian antes e depois da setorização.

Mapa 1 – Mapa de pressão da Rede Apulian: (a) antes e (b) depois da setorização.



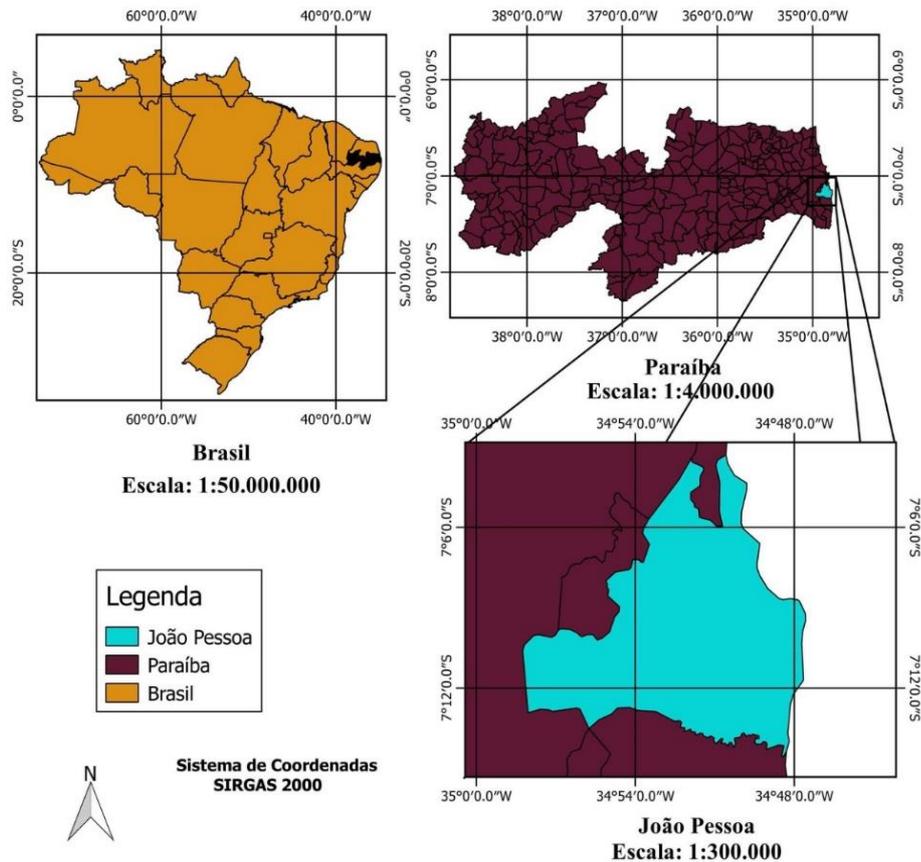
Fonte: A Autora (2021).

A pressão média da rede reduziu 17,7% após o processo de setorização, esse efeito ocorre devido à diminuição do número de caminhos que a água pode percorrer. A pressão do nó crítico (nó 22) ficou acima da pressão mínima preestabelecida, 10 mca, portanto não é necessária a aplicação de técnicas de reabilitação da rede. A partir da Equação 28, método FAVAD, foi estimado a redução de perdas de água. A setorização implicou na redução do índice de perda de 30% para 20,3%.

4.2. Estudo de Caso Real

Após a validação do modelo proposto, foi realizada a sua aplicação em sistemas de distribuição de água reais localizados na cidade de João Pessoa-PB. O município de João Pessoa fica situado na microrregião do Litoral Paraibano e ocupa uma área de 211.475 km², correspondendo a um percentual de 0,33% da área total do Estado. As delimitações territoriais do município estão representadas no Mapa 2. João Pessoa distribui seus quase 730 mil habitantes (contagem IBGE, 2010); em 65 unidades territoriais, com uma densidade demográfica de 1.815,57 hab/km².

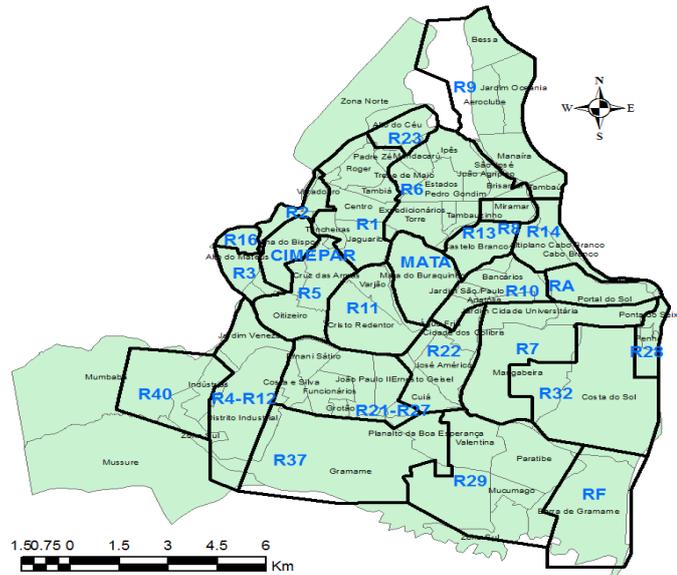
Mapa 2 – Mapa territorial da cidade de João Pessoa – PB.



Fonte: A Autora (2021).

O sistema de abastecimento de água da cidade de João Pessoa é operado pela CAGEPA - Companhia de Água e Esgotos da Paraíba, e foi dividido em 30 zonas de pressão (ZP). O Mapa 3 mostra o posicionamento e as áreas de atendimento das zonas. Neste trabalho, o modelo híbrido foi aplicado na setorização dos sistemas de distribuição de água das Zonas de Pressão R37, R5 e R1-R23 e, posteriormente, comparado com o projeto de setorização realizado pela Hidrainfo, empresa especializada contratada pela Companhia de Água e Esgotos da Paraíba (CAGEPA). É importante ressaltar que este estudo utilizou versões reabilitadas dos sistemas. Além disso, foi utilizado o cenário de demanda máxima horária, para o dia de maior consumo, considerando as perdas futuras de água (esperadas) na rede de abastecimento, para os dados de vazões médias mensais estimadas para o ano de 2034 (final do plano).

Mapa 3 – Bairros por área de influência dos reservatórios da cidade de João Pessoa.

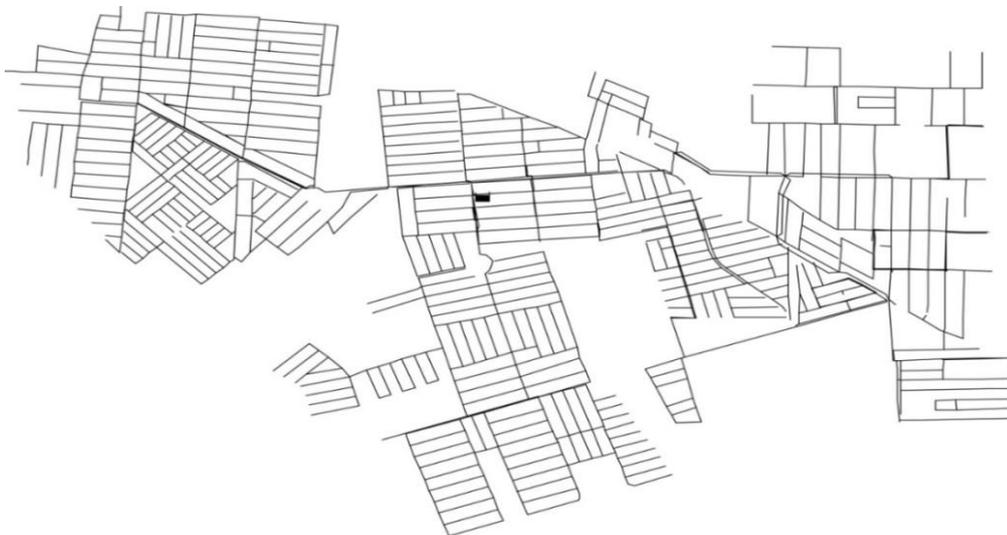


Fonte: Hidrainfo (2015).

4.2.1. Zona de Pressão R37

O sistema de distribuição de água da ZP 37 é composto por 1.045 nós, 1.251 trechos, e um reservatório com cota piezométrica de 70 mca (Figura 8). A rede é constituída por tubulações de PVC, com índice de perda na distribuição de 31,2% (SNIS, 2018). A maior pressão nodal do sistema corresponde a 63,82 mca, e a menor pressão nodal é de 10,26 mca. O volume diário de abastecimento de água é de aproximadamente 14.786 m³.

Figura 8 – Sistema de distribuição de água da ZP R37.



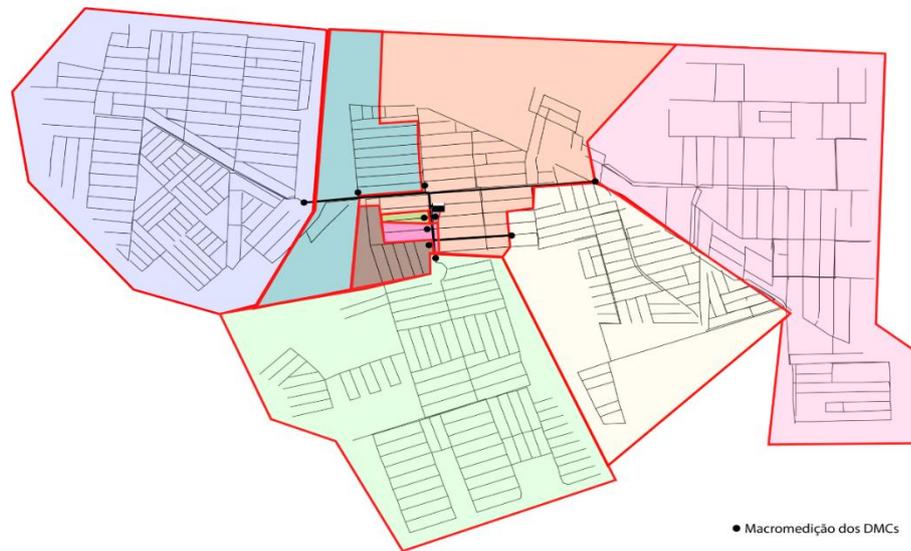
Fonte: Hidrainfo (2015).

A tubulação principal foi definida como o conjunto de trechos 10000, T1160, T1161, 2, T1155, T1156, T1157, T457, T1158, 17, T456, T455, T959, 4, T960, T961, T962, T963; caracterizado por possuir grandes diâmetros e conseqüentemente suportarem grandes vazões. Logo, as variáveis de decisão do problema, trechos derivantes da tubulação principal, são os trechos 1, T47, T48, T448, T949, T958*, 3, 5, T249, T964. Em seguida, foram definidos os parâmetros do BPSO e as configurações para o projeto:

- $c_1 = 1$
- $c_2 = 1$
- $\omega = 0,5$
- Número de partículas = 4
- Número de iterações = 20
- $P_{min} = 10$ mca
- $máxSize = 30$ km
- $N_1 = 2$

Após a leitura de entrada do arquivo (.INP), foram criadas as matrizes para representação da topologia em grafo e, em seguida, definidos dez DMCs através do agrupamento de nós descrito na Seção 3.2 (Figura 9). Logo, para este projeto de setorização, seriam necessários dez medidores de vazão, localizados nos trechos 1, T47, T48, T448, T949, T958*, 3, 5, T249, T964, representando as variáveis de decisão do problema, e dezesseis válvulas de seccionamento para o fechamento dos trechos T10004, T216, T450, T453, T495, T496, T500, T506, T434, T436, T1205, T252, T257, T261, T269, T663, de modo que os distritos se mantenham isolados e abastecidos através de uma única tubulação de entrada.

Figura 9 – Setorização da Zona de Pressão R37 através do algoritmo DSP.

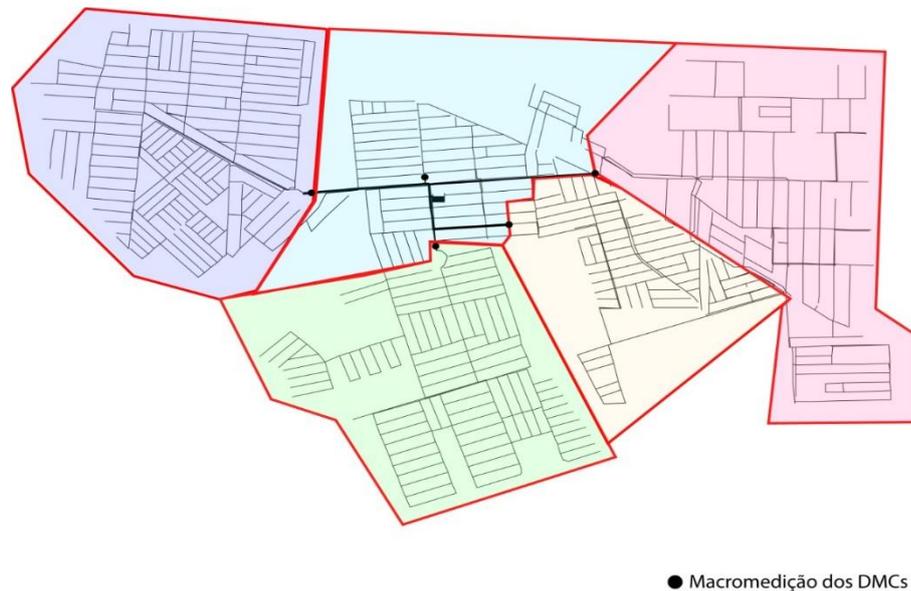


Fonte: A Autora (2021).

Este agrupamento de nós não representa a solução otimizada, fazendo-se necessária a aplicação da abordagem descrita na Seção 3.3. Logo, os distritos formados foram mesclados de modo a encontrar uma solução viável economicamente e tecnicamente. Os trechos que alimentam os distritos maiores (T448, T949, 3, 5, T249, T964) iniciaram na posição 1 (aberto), enquanto os trechos que alimentam os distritos menores (1, T47, T48, T958*) iniciaram-se na posição 0 (fechado).

Os valores de penalização α e β foram calibrados através de testes de verificação, de modo que o algoritmo de otimização reconhecesse a solução ótima. Logo, as penalizações α e β assumiram os valores 10 e 5 respectivamente. Em seguida, para solucionar o problema de otimização aqui proposto e formação dos distritos de medição e controle, utilizou-se técnicas de otimização metaheurística *binary particle swarm optimization* com a função objetivo e restrições conforme formulação apresentada no capítulo anterior. Assim, o modelo convergiu para a solução ótima indicada na Figura 10. Esta solução é caracterizada por possuir cinco DMCs, sendo os trechos 1, T949, 3, 5 e T964 selecionados para permanecerem abertos, ou seja, são alimentadores dos distritos e devem receber medidores de vazão, e possuem extensões de 24,89 km, 17,56 km, 25,08 km, 16,45 km e 29,97 km respectivamente. Enquanto que os demais trechos avaliados (T47, T48, T448, T249 e T958*) foram selecionados para permanecerem fechados, devendo receber válvulas de seccionamento.

Figura 10 – Solução otimizada do projeto de setorização da Zona de Pressão R37.

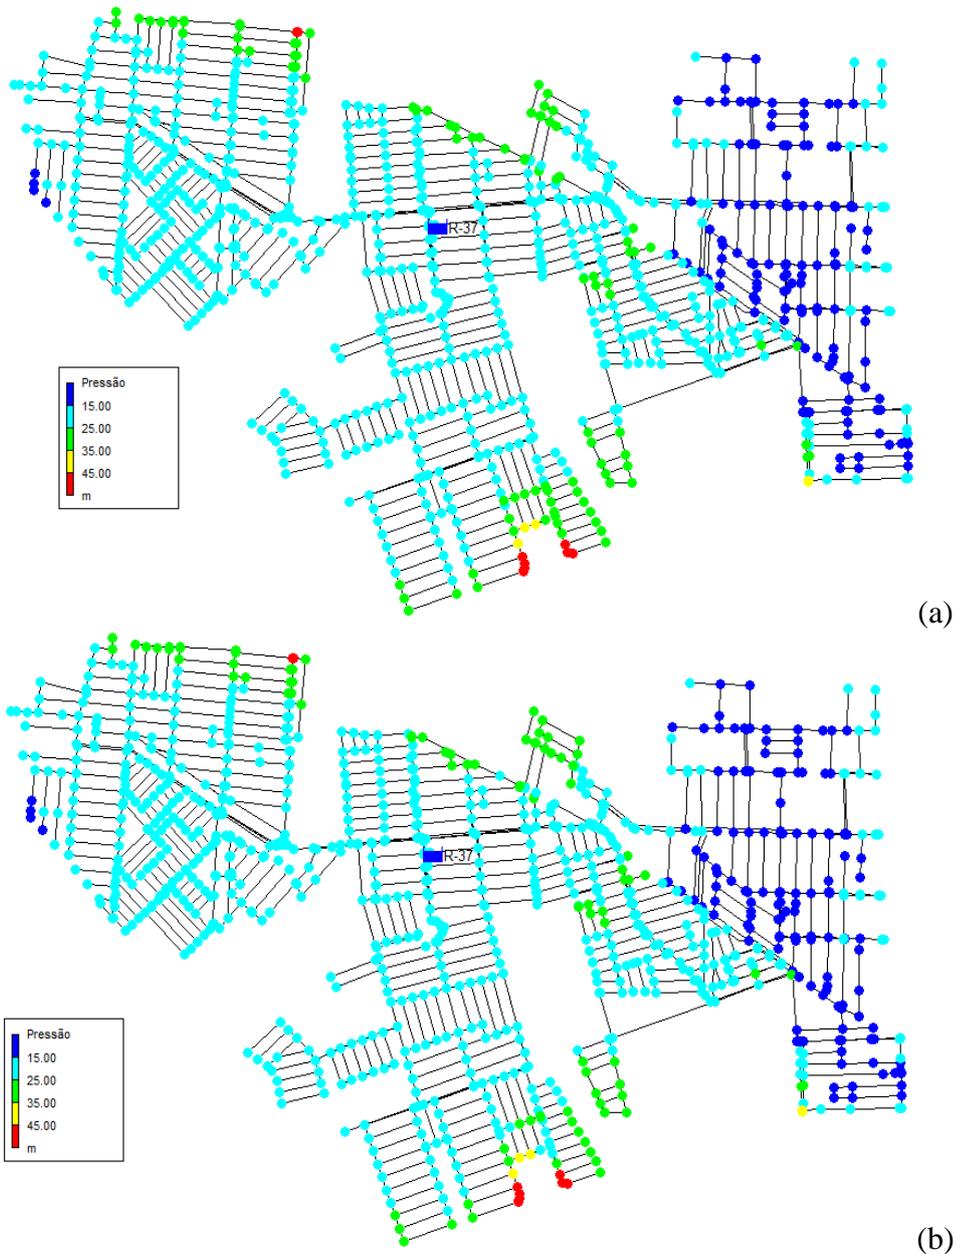


Fonte: A Autora (2021).

Uma vez definido os distritos, o modelo identificou os trechos cujos nós inicial e final estão localizados em diferentes setores, denominados de trechos limites. O conjunto de trechos limites são T495, T496, T500, T506, T1205, T663, aos quais devem receber válvulas de seccionamento para permanecerem fechados, obedecendo à restrição de distritos isolados. Por conseguinte, o custo total referente aos valores dos dispositivos foi de R\$ 147.934,99, sendo R\$ 38.923,90 referente aos custos das válvulas de seccionamento e R\$ 109.011,09 os dos medidores de vazão, considerando 1 RMB (Renminbi) igual a R\$ 0,82.

Em relação à redução de pressão, o Mapa 4 apresenta as pressões da Zona de Pressão R37 antes e depois da setorização. Desse modo, a setorização traria redução no índice de perdas de água, de 31,2% para 29,5%, equivalente à economia de 246.580 L/dia.

Mapa 4 – Mapa de pressão da Zona de Pressão R37 (a) antes e (b) depois da setorização.



Fonte: A Autora (2021).

4.2.2. Zona de Pressão R5

O sistema de distribuição de água da ZP R5 (Figura 11) é composto por 1.154 nós, 1.417 trechos, e um reservatório com cota piezométrica de 82,94 mca. A maior parte das tubulações da rede é constituída de PVC, com índice de perda na distribuição de 31,2% (SNIS, 2018). O volume diário de abastecimento de água é de aproximadamente 14.831 m³. A maior pressão nodal do sistema corresponde a 62,82 mca, e a menor pressão nodal é de 12,90 mca.

Figura 11 – Sistema de distribuição de água da ZP R5.



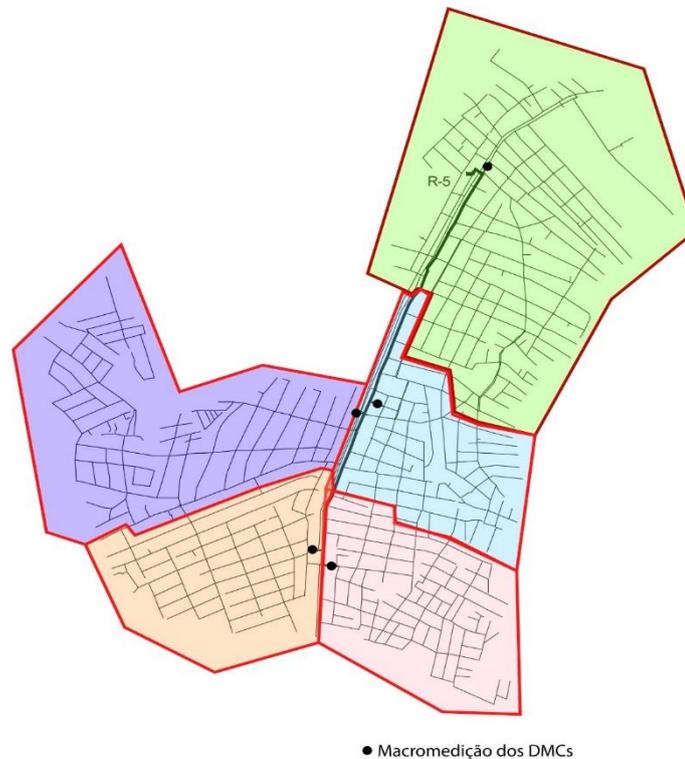
Fonte: Hidrainfo (2015).

A tubulação principal foi definida como o conjunto de trechos: 1, T683, T682, T1131, T1130, T1129, T1128, T1127, T1126, T1125, T1124, T1123, T1122, T1121, T1120, T1119, T1118, T1117, T1116, T1135, T1134, T1133, T1132, T1144, T1143, T1142, T1141, T1140, T1139, T1138, T1137, T1136 e T1406; tendo em vista que estes possuem grandes diâmetros e partem do reservatório. Por conseguinte, as variáveis de decisão do problema, trechos derivantes da tubulação principal, são os trechos 3, T990, T850, T1360, T210, T1058, T1041, T1026, T196, T1016, T1008, T1335, T614, 2, T1180, T466, T1315, T568, T559, T556, 23, T1145 e T1407. Em seguida, foram definidos os parâmetros do BPSO e as configurações para o projeto:

- $c_1 = 1$
- $c_2 = 1$
- $\omega = 0,5$
- Número de partículas = 4
- Número de iterações = 20
- $P_{min} = 10$ mca
- $máxSize = 30$ km
- $N_1 = 2$

β assumiram os valores 10 e 5 respectivamente. Em seguida, a aplicação da técnica de otimização metaheurística *binary particle swarm optimization* resultou em cinco distritos, sendo os trechos 3, 2, T1180, T1145 e T1407 selecionados para permanecerem abertos, ou seja, são alimentadores dos distritos e devem receber medidores de vazão, com extensões de 29,19 km, 12,49 km, 18,74 km, 14,69 km, 11,73 km, respectivamente, apresentado na Figura 13. Enquanto que os demais trechos selecionados como variáveis de decisão (T990, T850, T1360, T210, T1058, T1041, T1026, T196, T1016, T1008, T1315, T1335, T614, T466, T568, T559, T556 e 23) foram fechados.

Figura 13 – Solução otimizada do projeto de setorização da Zona de Pressão R5.

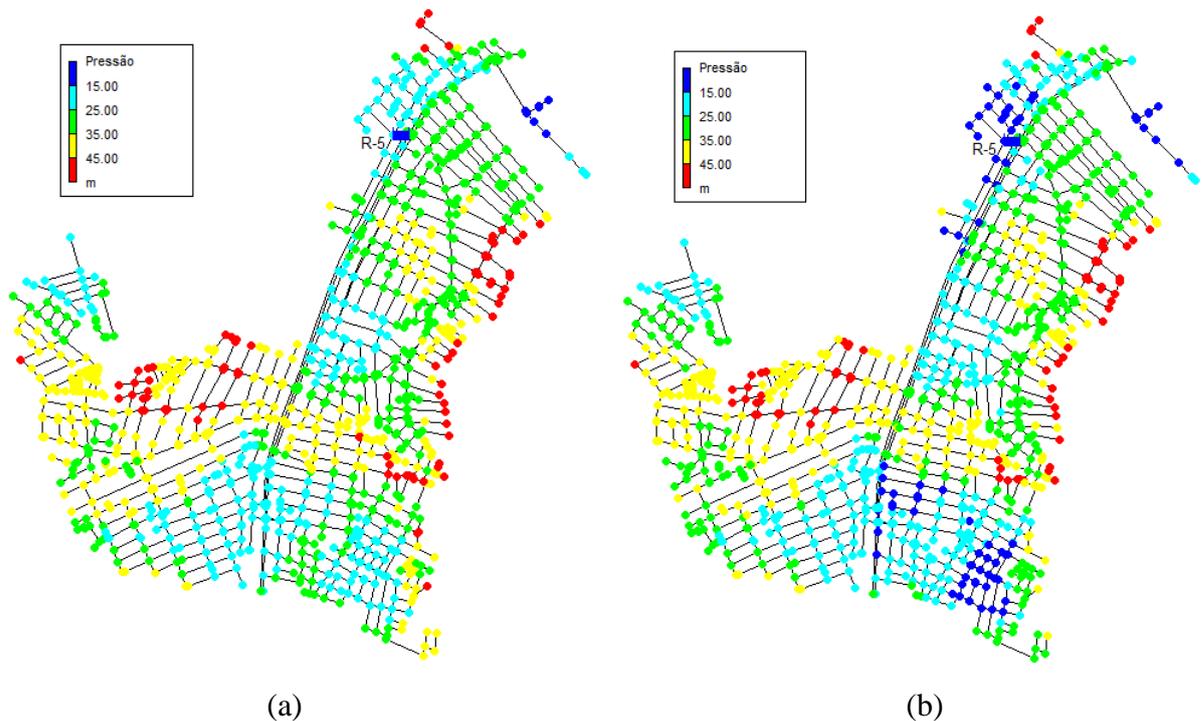


Fonte: A Autora (2021).

Uma vez definidos os distritos, os trechos limites foram identificados. O conjunto de trechos limites são: T492, T898, T903, T906, T1327, T376, T443, T438, T379, T1249, T565, T1257, T1100, T819, T818, T1367, T1280, T1299, T1392, T216, T385, T452 e T812; aos quais devem receber válvulas de seccionamento para que os distritos permaneçam isolados. Desse modo, o custo total referente aos valores dos dispositivos foi de R\$ 289.480,76, sendo R\$ 132.503,89 correspondendo aos custos das válvulas de seccionamento e R\$ 156.876,86 os dos medidores de vazão.

Como já era o esperado, a reestruturação do sistema implicou na redução de pressão do sistema. O Mapa 5 apresenta as pressões da Zona de Pressão R5 antes e depois da setorização. Desse modo, a setorização traria redução no índice de perdas de água, de 31,2% para 26,8%, equivalente à economia de 650.752 L/dia.

Mapa 5 – Mapa de pressão da Zona de Pressão R5 (a) antes e (b) depois da setorização.



Fonte: A Autora (2021).

4.2.3. Zona de Pressão R1-R23

Por fim, o sistema de distribuição de água ZP R1-R23 também foi adotado como estudo de caso (Figura 14). A rede é composta por 2.029 nós, 2.380 trechos, e um reservatório com cota piezométrica de 71 mca. A maior parte das tubulações da rede são constituídas de PVC com índice de perda na distribuição de 31,2% (SNIS, 2018). A maior pressão nodal do sistema corresponde a 68,68 mca, enquanto a menor pressão nodal é de 11,48 mca. O volume diário de abastecimento de água é de aproximadamente 28.826 m³.

Figura 14 – Sistema de distribuição de água da ZP R1-R23.



Fonte: Hidrainfo (2015).

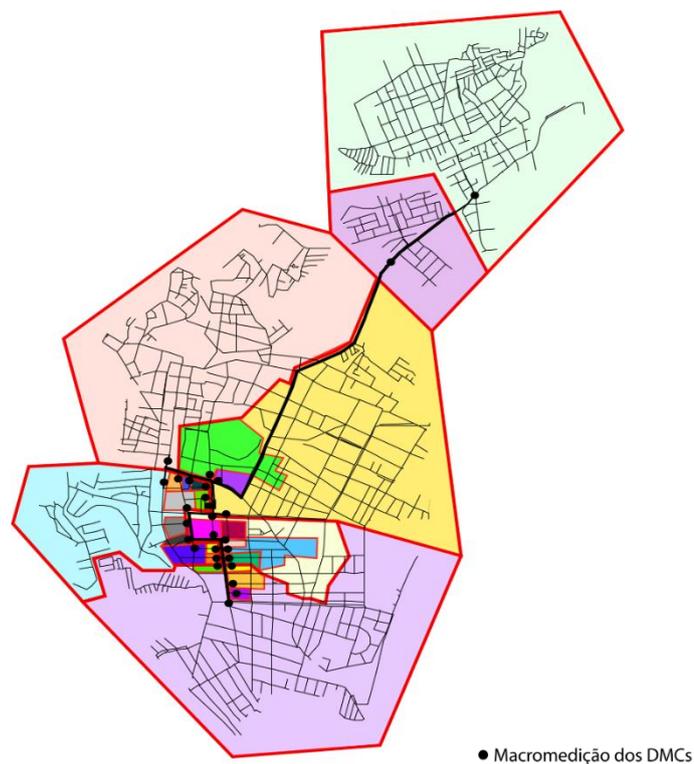
A tubulação principal foi definida como o conjunto de trechos: 1, T2102, T2103, 19, 17, 18, 15, T1748, T1749, T1750, T1751, T1752, T1753, T1754, T1755, T1756, T1757, T1758, T1759, T1760, T1761, T1381, T1619, T1616, T1783, T2117, T2116, T2115, T2114, T2113, T2112, T2304, T2303, T2302, 16, T1383, T1384, T1385, T1386, T1387 e T1388. Por conseguinte, as variáveis de decisão do problema, trechos derivantes da tubulação principal, são os trechos 27, T1762, 23, T1616*, T1617, T1783*, T1782*, T1900, T2308, T2213, T1901, T2208, T2200, T2201, T2195, T2196, T2210, T2211, T2184, T2301, T2173, T2100, T1494, T1817, T1863, T1210, T1897, T1888, T1889, T1389 e T1800. Em seguida, foram definidos os parâmetros BPSO e as configurações para o projeto:

- $c_1 = 1$
- $c_2 = 1$
- $\omega = 0,5$
- Número de partículas = 4
- Número de iterações = 20

- $P_{min} = 10$ mca
- $máxSize = 30$ km
- $N_1 = 2$

Após a leitura de entrada do arquivo (.INP), foram criadas as matrizes para representação da topologia em grafo e, em seguida, definidos vinte e sete DMCs através do agrupamento de nós descrito na Seção 3.2 (Figura 15). Sendo assim, para essa setorização, seriam necessários vinte e sete medidores de vazão, localizados nos trechos 27, T1762, 23, T1616*, T1617, T1900, T2308, T2213, T1901, T2208, T2200, T2201, T2195, T2196, T2210, T2211, T2184, T2301, T2173, T2100, T1494, T1817, T1863, T1897, T1888, T1389 e T1800; compondo as variáveis de decisão, e cinquenta e nove trechos precisam ser fechados.

Figura 15 – Setorização da Zona de Pressão R1-R23 através do algoritmo DSP.



Fonte: A Autora (2021).

Esses DMCs formados foram mesclados de modo a encontrar uma solução viável economicamente e tecnicamente. Cabe observar que os trechos T1783*, T1782*, T1210 e T1889 não fazem parte do conjunto de trajetória mínima de nenhum nó da rede, desse modo,

estes permaneceram fechados, diminuindo a quantidade de variáveis de decisão. Assim, o problema teve vinte e sete variáveis de decisão, resultando em um espaço de busca com $2^{27} = 134.217.728$ combinações possíveis. De modo a garantir que o modelo convergisse para a solução ótima, inicializou-se as partículas em posições pré-selecionadas. Os trechos que alimentam os distritos maiores inicializaram-se na posição 1 (trechos 27, T1762, 23, T1616*, T2308, T2201, T2301, T1817, T1389 e T1800); enquanto os trechos que alimentam os distritos menores iniciaram-se na posição 0 (trechos T1617, T1900, T2213, T1901, T2208, T2200, T2195, T2196, T2210, T2211, T2184, T2173, T2100, T1494, T1863, T1897 e T1888).

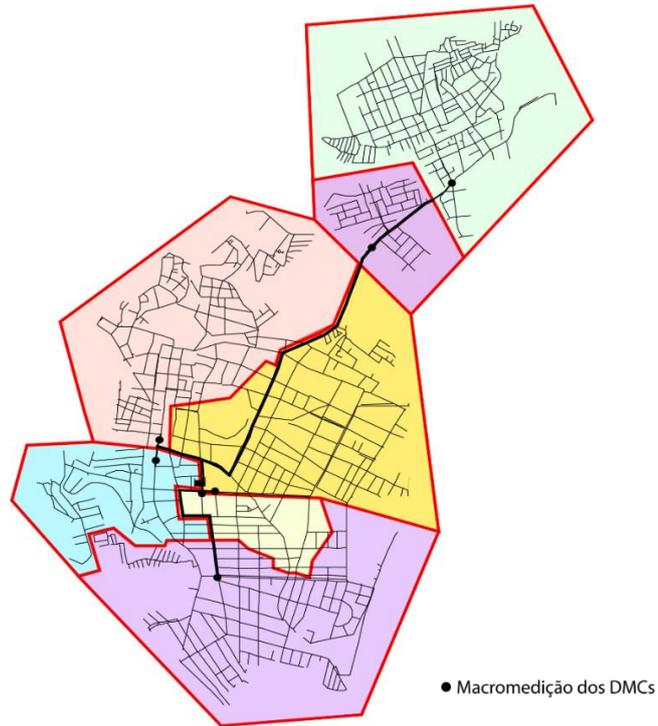
Os valores de penalização α e β foram calibrados através de testes de verificação, de modo que o algoritmo de otimização reconhecesse a solução ótima. Logo, as penalizações α e β assumiram os valores 10 e 5 respectivamente.

Em seguida, a aplicação da técnica de otimização metaheurística *binary particle swarm optimization* resultou em sete distritos (Figura 16), sendo os trechos 27, T1762, 23, T1616*, T2301, T1389 e T1800 selecionados para permanecerem abertos, com extensões de 7,68 km, 30,47 km, 26,30 km, 5,97 km, 28,32 km, 26,02 km, 11,05 km, respectivamente. Enquanto que os demais trechos que são variáveis de decisão (T1617, T1900, T2308, T2213, T1901, T2208, T2200, T2201, T2195, T2196, T2210, T2211, T2184, T2173, T2100, T1494, T1817, T1863, T1897 e T1888) foram selecionados para permanecerem fechados, devendo receber válvulas de seccionamento.

Uma vez definidos os distritos, os seguintes trechos limites foram determinados: T1355, T1560, T1694, T1839, T2016, T780, T842, T25, T27, T1237, T1244, T2176, T2293, T2181, T1940, T2142, T2314, T2189, T2306 e T1355; aos quais devem receber válvulas de seccionamento para permanecerem fechados, obedecendo à restrição de distritos isolados. Desse modo, o custo total referente aos valores dos dispositivos foi de R\$ 311.854,13 sendo R\$ 184.786 referentes aos custos das válvulas de seccionamento e R\$ 160.160,52 os dos medidores de vazão. Como já era o esperado, a reestruturação do sistema da Zona de Pressão R1-R23 implicou na redução de pressão do sistema.

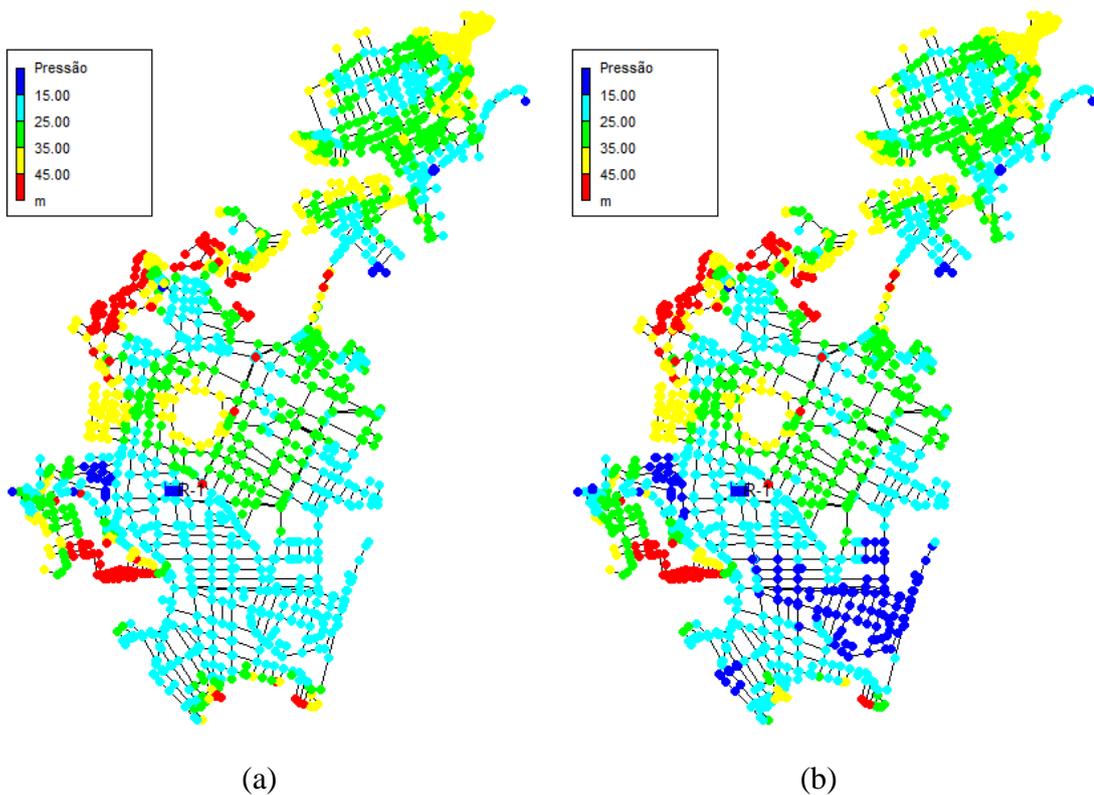
O Mapa 6 apresenta as pressões sistema analisado antes e depois da setorização. A setorização resultaria uma redução no índice de perdas de água de 31,2% para 28,7%, equivalente à economia de 707.429 L/dia.

Figura 16 – Solução otimizada do projeto de setorização da Zona de Pressão R1-R23.



Fonte: A Autora (2021).

Mapa 6 – Mapa de pressão da Zona de Pressão R1-R23 (a) antes e (b) depois da setorização.



Fonte: A Autora (2021).

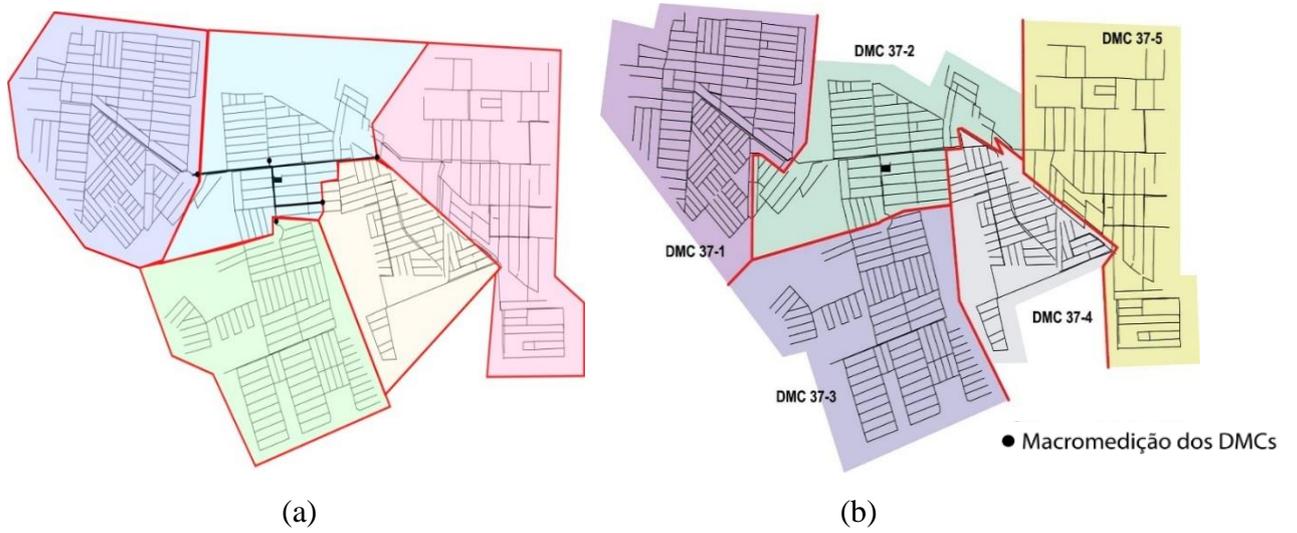
4.3. Análise e Discussão dos Resultados

Exemplos de aplicação do modelo híbrido proposto para o projeto de distritos de medição e controle foram apresentados. Com isto, foi verificada a eficácia da abordagem ao analisar possíveis soluções e convergir para soluções ótimas. Como já era o esperado, verificou-se que o número de possíveis soluções é elevado em redes reais, justificando a utilização do algoritmo metaheurístico *binary particle swarm optimization*. Além do mais, não foi utilizada a função de tolerância como critério de parada, pois o modelo sujeitava-se a ficar “preso” em mínimo locais. Isso ocorreu porque as simulações possuem poucas soluções viáveis quando comparadas ao número total de soluções possíveis.

A análise apontou que o projetista desempenha um papel determinante no projeto de setorização ao definir a tubulação principal, uma vez que as variáveis de decisão são dependentes desta definição. Apesar disso, a abordagem proposta traz a vantagem de indicar apenas uma única solução ótima, que atende às restrições impostas e maximiza os benefícios indicados nas funções objetivas. Dessa forma, não há necessidade de avaliar todas as soluções ótimas do conjunto de Pareto, como alguns modelos existentes na literatura. Por outro lado, a pré-seleção das partículas foi utilizada no intuito do BPSO chegar à solução ótima mais rapidamente, mostrando ser uma estratégia eficiente.

É importante observar que a solução ótima encontrada pelo modelo é muito semelhante à setorização projetada pelos especialistas, conforme pode ser observado nas Figuras 17, 18 e 19, das Zonas de Pressão R37, R5 e R1-23 respectivamente. As principais diferenças estão nos trechos limites, mudando um pouco o tamanho e formato dos setores.

Figura 17 – Projeto de setorização da Zona de Pressão R37 (a) modelo proposto e (b) Hidrainfo.



Fonte: A Autora (2021).

Fonte: Hidrainfo (2015).

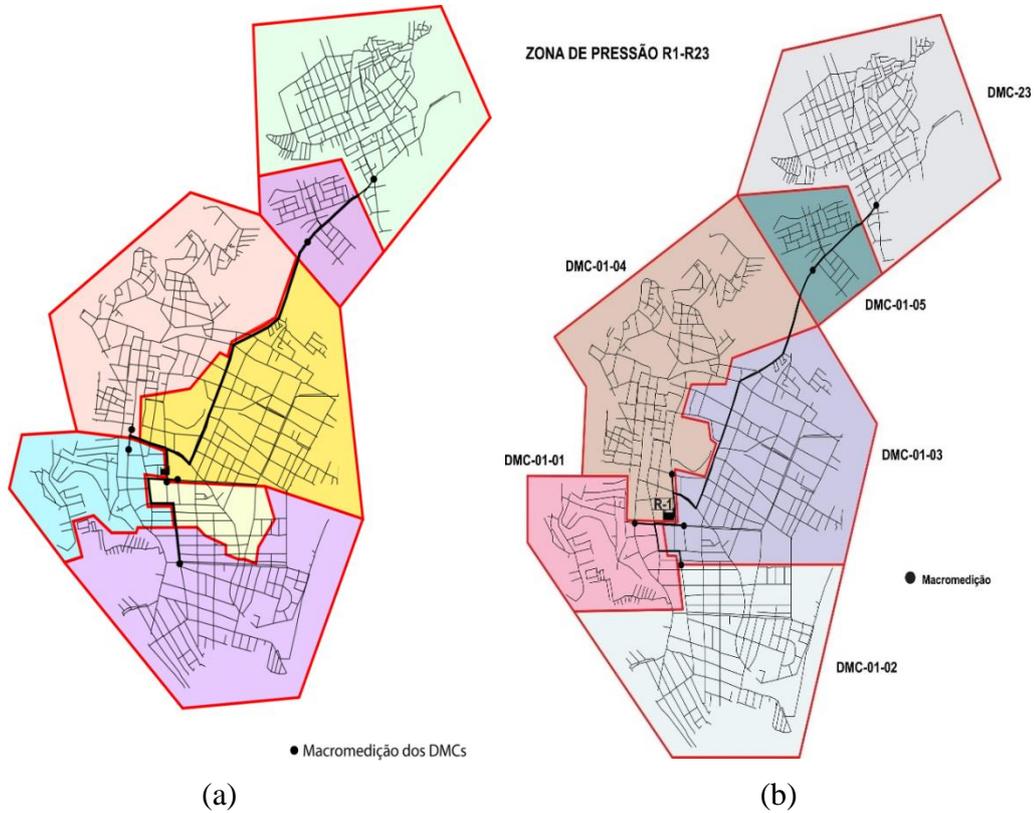
Figura 18 – Projeto de setorização da Zona de Pressão R5 (a) modelo proposto e (b) Hidrainfo.



Fonte: A Autora (2021).

Fonte: Hidrainfo (2015).

Figura 19 – Projeto de setorização da Zona de Pressão R1-R23 (a) modelo proposto e (b) Hidrainfo.



Fonte: A Autora (2021).

Fonte: Hidrainfo (2015).

A avaliação dos impactos da setorização em relação à redução de perdas de água se deu através da Equação de May (1994) que relaciona a redução de pressão com a redução de perdas de água. A setorização traria uma economia de 1.604.761 L/dia para a cidade de João Pessoa. O resumo das informações a respeito dos resultados de setorização dos três sistemas reais analisados nesse estudo encontra-se na Tabela 2.

Tabela 2 – Resumo dos principais resultados referentes a setorização.

	SDA da ZP R37	SDA da ZP R5.	SDA da ZP R1-R23.
Tubulação principal	10000, T1160, T1161, 2, T1155, T1156, T1157, T457, T1158, 17, T456, T455, T959, 4, T960, T961, T962 e T963	1, T683, T682, T1131, T1130, T1129, T1128, T1127, T1126, T1125, T1124, T1123, T1122, T1121, T1120, T1119, T1118, T1117, T1116, T1135, T1134, T1133, T1132, T1144, T1143, T1142, T1141, T1140, T1139, T1138, T1137, T1136 e T1406	1, T2102, T2103, 19, 17, 18, 15, T1748, T1749, T1750, T1751, T1752, T1753, T1754, T1755, T1756, T1757, T1758, T1759, T1760, T1761, T1381, T1619, T1616, T1783, T2117, T2116, T2115, T2114, T2113, T2112, T2304, T2303, T2302, 16, T1383, T1384, T1385, T1386, T1387 e T1388
Trechos com medidores de vazão	1, T949, 3, 5 e T964	3, 2, T1180, T1145 e T1407	27, T1762, 23, T1616*, T2301, T1389 e T1800
Trechos com válvulas de seccionamento	T47, T48, T448, T249, T958*, T495, T496, T500, T506, T1205 e T663	T990, T850, T1360, T210, T1058, T1041, T1026, T196, T1016, T1008, T1315, T1335, T614, T466, T568, T559, T556, 23, T492, T898, T903, T906, T1327, T376, T443, T438, T379, T1249, T565, T1257, T1100, T819, T818, T1367, T1280, T1299, T1392, T216, T385, T452 e T812	T1355, T1783*, T1782*, T1210, T1889, T1617, T1900, T2308, T2213, T1901, T2208, T2200, T2201, T2195, T2196, T2210, T2211, T2184, T2173, T2100, T1494, T1817, T1863, T1897, T1888, T1355, T1560, T1694, T1839, T2016, T780, T842, T25, T27, T1237, T1244, T2176, T2293, T2181, T1940, T2142, T2314, T2189 e T2306
Custo dos dispositivos	R\$ 147.934,99	R\$ 289.480,76	R\$ 311.854,13
Índice de perdas antes da setorização	31,2%	31,2%	31,2%
Índice de perdas após a setorização	29,5%	26,8%	28,7%
Economia de água	246.580 L/dia	650.751,70 L/dia	707.429 L/dia

Fonte: A Autora (2021).

Por fim, vale destacar que a metodologia desenvolvida neste trabalho visa auxiliar empresas de saneamento na realização de projetos de setorização de sistemas de distribuição de água, sendo necessário, em alguns casos, aplicar o projeto de reabilitação. Nos estudos de casos apresentados, os sistemas já se encontravam reabilitados, portanto, não houve a necessidade de propor intervenções na infraestrutura das redes.

5 CONSIDERAÇÕES FINAIS

Neste capítulo serão apresentadas as conclusões e contribuições desta pesquisa, bem como sugestões para trabalhos futuros.

5.1 Conclusões

Com as instalações obsoletas e a escassez hídrica, a gestão eficiente dos sistemas de distribuição de água tornou-se um desafio para as empresas de saneamento. Uma vez que a técnica de setorização representa um dos procedimentos mais eficaz para melhorar o gerenciamento de tais sistemas, este trabalho propôs um modelo híbrido de otimização para o projeto de distritos de medição e controle em sistemas de distribuição de água. A minimização dos custos dos dispositivos, a redução da pressão do sistema e o tamanho dos setores foram selecionados como objetivos do modelo, que foi baseado na combinação dos algoritmos de Dijkstra (DSP) e *binary particle swarm optimization*. De fato, a teoria dos grafos representou uma ferramenta útil para modelar os sistemas, reduzindo significativamente a complexidade do problema.

A revisão de literatura acerca dos modelos disponíveis para a setorização dos sistemas apontou uma lacuna existente no que diz respeito a aplicação de algoritmos de otimização nos projetos de DMCs. Nesse sentido, comparado com outros modelos, a metodologia desenvolvida neste trabalho foi aprimorada em vários aspectos: objetivos múltiplos, processo de otimização e convergência para uma solução única viável.

Os resultados da aplicação do modelo híbrido proposto nos estudos de casos foram bons, com a formação dos distritos resultando em soluções aplicáveis e coerentes. As soluções apresentaram redução de pressão em relação à configuração original (antes da setorização), o que evidencia que a setorização proposta implicaria na redução de perdas de água. Cabe destacar que a redução de perdas de água não se limita apenas à conservação do recurso hídrico, mas também tem influência na redução do consumo de energia elétrica, utilizado pelas estações elevatórias e conseqüentemente na redução das emissões de Gases de Efeito Estufa (GEE), que contribuem para o aquecimento regional e global, benefícios esses não quantificados nesse trabalho.

Com isso, verifica-se que a metodologia desenvolvida cumpriu os objetivos deste estudo, na busca do desenvolvimento de uma ferramenta computacional para o projeto ótimo de distritos de medição e controle de sistemas de distribuição de água, que vise à minimização dos vazamentos nas tubulações, justificando os investimentos necessários para sua

implementação. Ademais, além de ser de fácil aplicação, a abordagem multiobjetiva desenvolvida neste trabalho não apresenta limitações, desde que o sistema possua capacidade de transporte compatível com a setorização, podendo ser aplicado em sistemas reais.

Possivelmente, o grande desafio do Século XXI, é a busca da sustentabilidade. Em um planeta capitalista e globalizado, a preservação e a otimização dos recursos naturais têm importância não apenas teórica ou acadêmica, mas podem influir no sistema político, econômico e social de uma nação.

5.2 Contribuições

A abordagem proposta traz as seguintes contribuições para a literatura:

- Desenvolvimento de uma abordagem inovadora e adaptada do algoritmo de Dijkstra, baseado na teoria dos grafos, para o projeto de setorização;
- Utilização da programação metaheurística que permitiu a análise de diversos cenários de setorização;
- Aplicação e adaptação do algoritmo *binary particle swarm optimization* no processo de otimização dos setores, não aplicado em nenhum estudo com a mesma finalidade;
- Desenvolvimento de um algoritmo computacional genérico que pode ser adotado para o projeto de setorização de sistemas reais;
- Realização de estudos de casos em redes reais localizadas na cidade de João Pessoa-PB, a fim de se conhecer as particularidades e eficácia da abordagem proposta.

5.3 Limitações e Recomendações para Trabalhos Futuros

A metodologia proposta possui algumas limitações. O modelo não considera a compatibilidade dos distritos com os setores comerciais. Sendo necessária a formulação de mais estratégias para a realização da compatibilização. Outro fator importante de ser considerado é a respeito da definição da tubulação principal. Neste trabalho, o projetista precisa definir o conjunto de trechos que corresponde à tubulação principal. Como recomendações para trabalhos futuros, sugere-se a seleção automática das tubulações principais em combinação com os limites naturais e comerciais.

Por fim, propõe-se avançar na abordagem proposta por meio da inclusão do projeto de reabilitação na metodologia. Neste caso, o modelo híbrido definiria, além dos distritos de medição e controle, quais ações de reabilitação seriam necessárias para viabilizar tecnicamente a setorização. Estas ações podem ser limpeza de tubulações, substituição de

tubulações, duplicação de trechos, entre outras. Dessa forma, a função objetivo precisará ser reformulada para considerar os custos da reabilitação do sistema.

REFERÊNCIAS

- ABBASS, H.A. Marriage in honey-bee optimization (MBO): A haplometrosis polygynous swarming approach. **Proceedings of the 2001 Congress on Evolutionary Computation**, p. 207-214, 2001.
- ABNT – Associação Brasileira de Normas Técnicas. NBR 12218:2017. **Projeto de rede de distribuição de água para abastecimento público** – Procedimento. 2017.
- ALVISI, S.; FRANCHINI, M. A heuristic procedure for the automatic creation of district metered areas in water distribution systems. **Urban Water Journal**, v. 11, n. 2, p. 137-159, 2013.
- BABIC, B.; DUKIC, A.; STANIC, M. Managing water pressure for water savings in developing countries. **Water SA**, v. 40, n. 2, p. 221-232, 2014.
- BANSAL, J. C.; SHARMA, H.; JADON, S. S.; CLERC, M. Spider monkey optimization algorithm for numerical optimization. **Memet Comput**, v. 6, n. 1, p. 31-47, 2014.
- BERARDI, L.; LAUCELLI, D.; SIMONE, A.; PERRONE, G. C.; GIUSTOLISI, O. Integrated pressure control strategies for sustainable management of water distribution networks. **E3S Web of Conferences**, v. 85, 2019.
- BEZERRA, S. T. M.; GOMES, H. P. Controle de Perdas de Água. In: GOMES, H. P. (Org.). **Abastecimento de Água**. 1ed. João Pessoa: Editora UFPB, 2019, v. único, p. 347-402.
- BISWAS, A.; DASGUPTA1, S.; DAS, S.; ABRAHAM, A. Synergy of PSO and Bacterial Foraging Optimization – A comparative study on numerical benchmarks. **Innovations in Hybrid Intelligent Systems**, p. 255-263, 2007.
- BOZORG HADDAD O.; AFSHAR A.; MARIÑO M.A. HoneyBees Mating Optimization (HBMO) Algorithm: A new heuristic approach for water resources optimization. **Water Resources Management**, v. 20, p. 661-680, 2006.
- BOZORGI, S. M.; YAZDANI, S. IWOA: An Improved whale optimization algorithm for optimization problems. **Journal of Computational Design and Engineering**, v. 6, p. 243-259, 2019.
- CAMPBELL, E.; IZQUIERDO, J.; MONTALVO, I.; ILAYA-AYZA, A.; PÉREZ-GARCÍA, R.; TAVERA, M. A flexible methodology to sectorize water supply networks based on social network theory concepts and multi-objective optimization. **Journal of Hydroinformatics**, v. 18, n. 1, 62-76, 2015.
- CAMPBELL, E.; IZQUIERDO, J.; MONTALVO, I.; PÉREZ-GARCÍA, R. A novel water supply network sectorization methodology based on a complete economic analysis, including uncertainties. **Water**, v. 8, n. 5, 2016.
- CIAPONI, C.; MURARI, E.; TODESCHINI, S. Modularity-based procedure for partitioning water distribution systems into independent Districts. **Water Resources Management**, v. 30, n. 6, p. 2021–2036, 2016.

CLERC, M. The swarm and the queen: towards a deterministic and adaptive particle swarm optimization. **Proceedings of the 1999 Congress Evolutionary Computation**, IEEE Press, p. 1951-1957, 1999.

DI NARDO, A.; DI NATALE, M. A heuristic design support methodology based on graph theory for district metering of water supply networks. **Engineering Optimization**, v. 43, n. 2, p. 193-211. 2011.

DI NARDO, A.; DI NATALE, M.; GARGANO, R.; GIUDICIANNI, C.; GRECO, R.; SANTONASTASO, G. F. Performance of partitioned water distribution networks under spatial-temporal variability of water demand. **Environmental Modelling & Software**, v. 101, p. 128-136. 2018.

DI NARDO, A.; DI NATALE, M.; MUSMARRA, D.; SANTONASTASO, G. F.; TZATCHKOV, V.; ALCOCER-YAMANAKA, V. H. Dual-use value of network partitioning for water system management and protection from malicious contamination. **Journal of Hydroinformatics**, v. 17, n. 3, p. 361-376, 2015.

DI NARDO, A.; DI NATALE, M.; SANTONASTASO, G. F.; TZATCHKOV, V. G.; ALCOCER-YAMANAKA, V. H. Water network sectorization based on a genetic algorithm and minimum dissipated power paths. **Water Science Technology Water Supply**, v. 13, p. 951-957, 2013.

DIAO, K.; FU, G.; FARMANI, R.; GUIDOLIN, M.; BUTLER, D. Twin-hierarchy decomposition for optimal design of water distribution systems. **Journal of Water Resources Planning and Management**, v. 142, 2016.

DIAO, K.; GUIDOLIN, M.; FU, G.; FARMANI, R., BUTLER, D. Hierarchical decomposition of water distribution systems for background leakage assessment. **16th Water Distribution System Analysis Conference**, pp. 53–58, 2014.

DIAO, K.; ZHOU, Y.; RAUCH, W., Automated creation of district metered area boundaries in water distribution systems. **Journal of Water Resources Planning and Management**, v. 139, p. 184–190, 2013.

DIJKSTRA, E. W. A note on two problems in connexion with graphs. **Numerische Mathematik**, v. 1, n. 1, p. 269-271, 1959.

DORIGO, M.; MANIEZZO, V.; COLORNI, A. Positive feedback as a search strategy. Dipartimento di Elettronica, Politecnico di Milano, Technical Report TR 91- 016, 1991.

DRIAS, H.; SADEG, S.; YAHY, S. Cooperative bees swarm for solving the maximum weighted satisfiability problem, computational intelligence and bioinspired Systems. **Proceedings of the 8th International Workshop on Artificial Neural Networks**, 2005.

EBERHART, R. C.; SHI, Y. Comparing inertia weights and constriction factors in particle swarm optimization. **Proceedings of the 2000 Congress on Evolutionary Computation**, 2000. v. 1, p. 84-88, 2000.

ENAYATTABAR, M.; EBRAHIMNEJAD, A.; MOTAMENI, H. Dijkstra algorithm for shortest path problem under interval-valued Pythagorean fuzzy environment. **Complex & Intelligent Systems**, 2018.

EULER, L. Solutio problematis ad geometriam situs pertinentis. **Commentarii Academiae Petropolitanae**, v. 8, p. 128, 1741.

EUSUFF, M.; LANSEY, K. Optimizing of water distribution network design using the shuffled frog-leaping algorithm. **Journal of Water Resources Planning and Management**, v. 129, n. 3, p. 210-225, 2003.

EUSUFF, M.; LANSEY, K.; PASHA, F. Shuffled frogleaping algorithm: a memetic meta-heuristic for discrete optimization. **Engineering Optimization**, v. 38, n. 2, p. 129-154, 2006.

FARLEY, MALCOLM. **Leakage management and control: a best practice training manual**. Water Supply and Sanitation Collaborative Council, World Health Organization Geneva, Switzerland, 2001.

FERRARI, G., SAVIC, D. Economic performance of DMCs in water distribution systems. **Procedia Engineering**, v. 119, p. 189-195, 2015.

FERRARI, G.; SAVIC, D.; BECCIU, G. Graph-theoretic approach and sound engineering principles for design of district metered areas. **Journal of Water Resources Planning and Management**, v. 140, n. 12, p. 04014036(1-13), 2014.

GANDOMI, A. H.; ALAVI, A. H. Krill herd: A new bio-inspired optimization algorithm. **Communications in Nonlinear Science and Numerical Simulation**, v. 17, n. 12, p. 4831-4845, 2012.

GIUSTOLISI, O.; RIDOLFI, L. New modularity-based approach to segmentation of water distribution networks. **Journal of Hydraulic Engineering**, v. 140, n. 10, p. 04014049(1-14), 2014.

GIUSTOLISI, O.; SAVIC, D.; KAPELAN, Z. Pressure-driven demand and leakage simulation for water distribution networks. **Journal of Hydraulic Engineering**, v. 134, n. 5, p. 626-635, 2008.

GOLDBERG, D.E. *The Design of Innovation: Lessons from and for Competent Genetic Algorithms*, Kluwer Academic Publishers, Norwell, 2002.

GOMES, R.; SOUSA, J.; MARQUES, A. S. Influence of future water demand patterns on the district metered areas design and benefits yielded by pressure management. **Procedia Engineering**, v. 70, p. 744 – 752, 2014.

GOMEZ, P.; CUBILLO, F.; MARTÍN, F. J. Comprehensive and efficient sectorization of distribution networks. **Procedia Engineering**, v. 70, p. 753-762, 2014.

HERRERA, M.; CANU, S.; KARATZOGLOU, A.; PEREZ-GARCIA, R.; IZQUIERDO, J. An approach to water supply clusters by semi-supervised learning. **International Environmental Modelling and Software Society**, 2010.

HIDRAINFO - Hidrainfo Consultoria e Serviços Ltda. Elaboração de projetos de setorização da rede de distribuição dos sistemas de abastecimento de água das cidades de Cabedelo e João Pessoa/PB. Relatório Técnico. 2015, João Pessoa.

- HOLLAND, J.H. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor, Michigan, 1975.
- ILAYA-AYZA, A. E.; CAMPBELL, E.; PÉREZ-GARCÍA, R.; IZQUIERDO, J. Implementation of DMCs in Intermittent water supply networks based on equity criteria. **Water**, v. 9, n. 11, 2017.
- JIA, DL.; ZHENG, GX.; BOYANG, QU; KHAN, M. K. A hybrid particle swarm optimization algorithm for high-dimensional problems. **Computers & Industrial Engineering**, v. 61, n. 4, p. 1117-1122, 2011.
- JITONG, T.; JOTHITYANGKOON, C. Reducing water loss in a water supply system using a district metering area (DMC): A case study of the Provincial Waterworks Authority (PWA), Lop Buri Branch. **Engineering and Applied Science Research**, v. 44, n. 3, p. 154-160, 2017.
- JONG, K. A. **Evolutionary Computation: A Unified Approach**. MIT Press, New York, 2006.
- KARA A. Imitation of Bee Reproduction as a crossover operator in Genetic Algorithms. **Artificial Intelligence**, v. 3157, p. 1015-1016, 2004.
- KARABOGA, D.; BASTURK, B. A powerful and efficient algorithm for numerical function optimization: Artificial Bee Colony (ABC) algorithm. **Journal of Global Optimization**, v. 39, n. 3, p. 459-471, 2007.
- KENNEDY, J.; EBERHART, R. C. A discrete binary version of the particle swarm algorithm. **1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation**. IEEE, v. 5, p. 4104-4108, 1997.
- KENNEDY, J.; EBERHART, R. C. Particle Swam Optimization. *Proceedings IEEE International Conference on Neural Networks*, p. 1942-1948, 1995.
- KENNEDY, J.; EBERHART, R. C.; SHI., Y. **Swarm Intelligence**. San Francisco: Morgan Kaufmann/ Academic Press, 2001.
- KHANESAR, M. A.; TESHNEHLAB, M.; SHOOREHDELI, M. A. A novel binary particle swarm optimization. **2007 Mediterranean Conference on Control & Automation**. IEEE. p. 1-6, 2007.
- KORANI, W. Bacterial Foraging Oriented by particle swarm optimization Strategy for PID Tuning. *Proceedings of GECCO 2008: Genetic and Evolutionary Computation Conference*, p. 1823- 1826, 2008.
- KOZA, J. R.; KEANE, M. A.; STREETER, M. J.; MYDLOWEC, W. **Genetic Programming IV: Routine Human Competitive Machine Intelligence**, Springer, New York, 2003.
- LAUCELLI, D. B.; SIMONE, A.; BERARDI, L.; GIUSTOLISI, O. Optimal design of district metering areas for the reduction of leakages. **Journal of Water Resources Planning and Management**, v. 143, n. 6, p. 04017017(1-12), 2017.

- LI, W.; LING, W.; LIU, S.; ZHAO, J.; LIU, R.; CHEN, Q.; QIANG, Z.; QU, J. Development of systems for detection, early warning, and control of pipeline leakage in drinking water distribution: A case study. **Journal of Environmental Sciences**, v. 23, n. 11, p. 1816-1822, 2011.
- LIU, J.; HAN, R. Spectral clustering and multicriteria decision for design of district metered areas. **Journal of Water Resources Planning and Management**, v. 144, n. 5, p. 04018013(1-11), 2018.
- LU, X.; ZHOU, Y. A novel global convergence algorithm: Bee collecting pollen algorithm. **Artificial Intelligence**, v. 5227, p. 518-525, 2008.
- LUCIC, P.; TEODOROVIC, D. Bee System: Modeling combinatorial optimization transportation engineering problems by swarm intelligence. **Preprints of the TRISTAN IV Triennial Symposium on Transportation Analysis**, p. 441-445, 2001.
- MACDONALD, G.; YATES, C. D. DMC Design and Implementation, a North American Context. **Leakage 2005 – Conference Proceedings**, p. 1-8, 2005.
- MANJARRES, D.; LANDA-TORRES, I.; GIL-LOPEZ, S.; DEL SER, J.; BILBAO, M. N.; SALCEDO-SANZ, S.; GEEM, Z. W. A survey on applications of the harmony search algorithm. **Engineering Applications of Artificial Intelligence**, v. 26, n. 8, p. 1818-1831, 2013.
- MAY, J., **Pressure Dependent Leakage**. World Water and Environmental Engineering, Out. 1994.
- MENHAS, M. I.; WANG, L.; FEI, M. R.; MA, C. X. Coordinated controller tuning of a boiler turbine unit with new binary particle swarm optimization algorithm. **International Journal of Automation and Computing**, v. 8, n. 2, p. 185-192, 2011.
- MIRJALILI, S. Dragonfly algorithm: A new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems. **Neural Computing and Applications**, v. 27, n. 4, p. 1053-1073, 2016.
- MIRJALILI, S. The ant lion optimizer. **Advances in Engineering Software**, v. 83, p. 80-98, 2015a.
- MIRJALILI, S. Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm. **Knowledge-Based Systems**, v. 89, p. 228-249, 2015b.
- MIRJALILI, S.; LEWIS, A. The whale optimization algorithm. **Advances in Engineering Software**, v. 95, p. 51-67, 2016.
- MIRJALILI, S.; MIRJALILI, S. M.; LEWIS, A. Grey wolf optimizer. **Advances in Engineering Software**, v. 69, p. 46-61, 2014.
- MOORE, J.; CHAPMAN, R. **Application of particle swarm to multiobjective optimization**. Department of Computer Science and Software Engineering, Auburn University, 1999.

- MORAES, M. B. DA C.; NAGANO, M. S. Cash balance management: A comparison between genetic algorithms and particle swarm optimization. **Acta Scientiarum. Technology**, v. 34, n. 4, p. 373-379, 2012.
- MULLER, S.D.; MARCHETTO, J.; AIRAGHI, S.; KOUMOUTSAKOS, P. (2002). Optimization based on bacterial chemotaxis. **Transactions on Evolutionary Computation**, v. 6, n. 1, p. 16-29, 2002.
- NEZAMABADI-POUR, H.; SHAHRBABAKI, M. R.; FARSANGI, M. M. Binary particle swarm optimization: Challenges and new solutions. **The Journal of Computer Society of Iran (CSI) On Computer Science and Engineering (JCSE)**, v. 6, n. 1, p. 21-32, 2008.
- NGUYEN, B. H.; XUE, B.; ANDREAE, P. A Novel binary particle swarm optimization algorithm and its applications on knapsack and feature selection problems. **Intelligent and Evolutionary Systems**, p. 319-332, 2016.
- PASSINO, K. M. Biomimicry of bacterial foraging for distributed optimization and control. **IEEE Control Systems Magazine**, v. 22, n. 3, p. 52-67, 2002.
- PERELMAN, L. S.; ALLEN, M.; PREIS, A.; IQBAL, M., WHITTLE, A. J. Flexible reconfiguration of existing urban water infrastructure systems. **Environmental Science & Technology**, v. 49, n. 22, p. 13378-13384, 2015.
- PELIKAN, M.; SASTRY, K.; CANTÚ-PAZ, E. Scalable optimization via probabilistic modeling. **Studies in Computational Intelligence**, v. 33, 2006.
- PHAM, D.T.; KOG, E.; GHANBARZADEH, A.; OTRI, S.; RAHIM, S.; ZAIDI, M. The bees algorithm – A novel tool for complex optimisation problems. Proceedings of 2nd International Virtual Conference on Intelligent Production Machines and Systems (IPROMS 2006), Oxford, Elsevier, 2006.
- PONS, P.; LATAPY, M. Computing communities in large networks using random walks. **Journal Graph Algorithms Appl.**, v. 10, n. 2, p. 191-218, 2006.
- PRESCILLA, K.; SELVAKUMAR, A. I. Comparative study of task assignment on consistent and inconsistent heterogeneous multiprocessor system. IEEE 2013 International Conference on Advanced Computing & Communication Systems (ICACCS) - Coimbatore, India, p. 1–6, 2013a.
- PRESCILLA, K.; SELVAKUMAR, A. I. Modified Binary Particle Swarm optimization algorithm application to real-time task assignment in heterogeneous multiprocessor. **Microprocessors and Microsystems**, v. 37, n. 6, p. 583–589, 2013b.
- RAHMAN, A.; WU, Z. Y. Multistep simulation-optimization modeling approach for partitioning water distribution system into district meter areas. **Journal of Water Resources Planning and Management**, v. 144, n. 5, p. 04018018(1-14), 2018.
- Report 26 – **Leakage Control Policy & Practice**. UK Water Authorities Association, 1980.
- SCHEEL, J.; DIB, R.; WESTERMANN, D.; WIRTZ, F. Maximization of the feed-in of renewable energy into high-voltage grids by optimal switching. IEEE Eindhoven PowerTech - Eindhoven, Netherlands, p. 1–5, 2015.

SERAPIÃO, A. B. S. Fundamentos de otimização por inteligência de enxames: uma visão geral. **Revista Controle & Automação**, v. 20, n. 3, p. 271-304, 2009.

SHI, Y.; EBERHART, R. A modified particle swarm optimizer. **IEEE World Congress on Computational Intelligence**. p 69-73, 1998.

SHI, Y.; EBERHART, R. C. Empirical study of particle swarm optimization. **Proceedings of the 1999 Congress on Evolutionary Computation**, v. 3, p 1945-1950, 1999.

SNIS. **Sistema Nacional de Informações sobre Saneamento. Diagnóstico dos Serviços de Água e Esgoto – 2018**. Ministério do Desenvolvimento Regional. Secretaria Nacional de Saneamento. Brasília, 2019.

SOARES, A. S.; KUSTERKO, S. K.; HENRIQUE, R.; SANTOS, J. A. C. Desafios na setorização do sistema de abastecimento de água costa norte em Florianópolis/SC para controle e redução de perdas. **Congresso Abes Fenasan**, 2017.

SUNG H. J. Queen-Bee Evolution for Genetic Algorithms. **Electronic Letters**, v. 39, n. 6, p. 575-576, 2003.

TANG, W. J.; WU, Q. H.; SAUNDERS, J. R. A Bacterial Swarming Algorithm for Global Optimization. *Proceedings of the 2007 IEEE Congress on Evolutionary Computation*, p. 1207-1212, 2007.

TEODOROVIC, D.; DELL'ORCO, M. Bee colony optimization – a cooperative learning approach to complex transportation problems. *Proceedings of the 10th EWGT Meeting and 16th Mini-EURO Conference*, 2005.

TZATCHKOV, V. G.; ALCO CER-YAMANAKA, V. H.; ORTÍZ, V. B. Graph theory based algorithms for water distribution network sectorization projects. *8th Annual Water Distribution Systems Analysis Symposium*, Cincinnati, Ohio, 2006.

VO, A. T; MAI, L. H.; NGUYEN, H. T. N. Automation with renewable energy to optimize the exploitation of water supply networks in Ninh Thuan province. **MATEC Web of Conferences**, v. 193, n. 98, p. 1-11, 2018.

WAHYUNINGSIH, D.; SYAHREZA, E. Shortest path search futsal field location with Dijkstra algorithm. **Indonesian Journal of Computing and Cybernetics Systems**, v. 12, n. 2, p. 161-170, 2018.

WANG, F.; ZHANG, H.; LI, K.; LIN, Z.; YANG, J.; SHEN, X. A Hybrid Particle Swarm optimization algorithm using adaptive learning strategy. **Information Sciences**, v. 436, p. 162-177, 2018.

WEDDE H. F.; FAROOQ M.; ZHANG Y. BeeHive: An Efficient Fault-Tolerant Routing Algorithm Inspired by Honey Bee Behavior, Ant Colony, Optimization and Swarm Intelligence. **Computer Science**, v. 3172, p. 83-94, 2004.

WU, T. F.; TSAI, P. S.; HU, N. T.; CHEN, J. Y. Combining turning point detection and Dijkstra's algorithm to search the shortest path. **Advances in Mechanical Engineering**, v. 9, n. 2, p. 1-12, 2017.

XU, Q.; CHEN, Q.; MA, J.; BLANCKAERT, K.; WAN, Z. Water Saving and Energy Reduction through Pressure Management in Urban Water Distribution Networks. **Water Resources Management**, v. 28, n. 11, p. 3715-3726, 2014.

YANG X. S. Engineering optimizations via nature inspired virtual bee algorithms. **Computer Science**, v. 3562, p. 317-323, 2005.

ZHANG, K.; YAN, H.; ZENG, H.; XIN, K.; TAO, T. A practical multi-objective optimization sectorization method for water distribution network. **Science of The Total Environment**, v. 656, p. 1401-1412, 2019.

ZHANG, W.; LAN, Z.; MA, Z.; TAN, C.; QUE, J.; WANG, F.; CAO, C. Determination of statistical discontinuity persistence for a rock mass characterized by non-persistent fractures. **International Journal of Rock Mechanics and Mining Sciences**, v. 126, p. 1-16, 2020.

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**, v. 21, n. 5, p. 773-791, 2017.