

UNIVERSIDADE FEDERAL DE ITAJUBÁ

Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos

**APLICAÇÃO DA REDE NEURAL MAPAS AUTO-ORGANIZÁVEIS E
ALGORITMO GENÉTICO NSGA – II À SETORIZAÇÃO DE REDE DE
DISTRIBUIÇÃO DE ÁGUA**

Lorena Lemos Dias Lara

Itajubá – MG

2025

UNIVERSIDADE FEDERAL DE ITAJUBÁ

Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos

Lorena Lemos Dias Lara

**APLICAÇÃO DA REDE NEURAL MAPAS AUTO-ORGANIZÁVEIS E
ALGORITMO GENÉTICO NSGA – II À SETORIZAÇÃO DE REDE DE
DISTRIBUIÇÃO DE ÁGUA**

Dissertação submetida ao Programa de Mestrado em Meio Ambiente e Recursos Hídricos como parte dos requisitos para obtenção do título de Mestre em Meio Ambiente e Recursos Hídricos pela Universidade Federal de Itajubá.

Área de Concentração: Clima e Gestão do Ambiente

Linha de Pesquisa: Gestão e Conservação da Natureza

Orientador: Prof. Dr. Fernando das Graças Braga da Silva

Itajubá – MG

2025

Dedico este trabalho à minha maior torcida: Mamãe, Papai (*in memoriam*), Zaza e Carol. Todo o meu amor é de vocês.

AGRADECIMENTOS

Aos meus pais, Marilene e Antônio (*in memoriam*), pelo incentivo aos estudos e por me apoiarem em cada decisão e caminho tomado. À minha mãe, em especial, pelo amor incondicional, por todo o zelo do mundo e pelos conselhos que me acolhem e me ajudam a seguir em frente. Ao meu pai, agradeço as boas memórias, as risadas e o ensinamento de que “o saber não ocupa lugar”. Sem vocês, nada disso seria possível.

À minha irmã, Isadora (Zaza), por vibrar comigo em cada passo dado, por ser a melhor irmã e amiga do mundo, meu braço direito, por me fazer dar muitas risadas mesmo nos dias mais turbulentos, sempre me amparando com ternura e compreensão. Obrigada pela sensatez diária e por verdadeiramente acreditar em meu potencial.

À minha companheira de vida, meu amor, Carol, que acompanha de perto e vive comigo cada momento. Agradeço por todo o cuidado, carinho e amor do mundo, pelas longas conversas que ajudaram a esclarecer muitos pontos deste trabalho e por se emocionar a cada desafio vencido. Agradeço, principalmente, por ser meu refúgio e por tornar os dias mais leves.

Ao Professor Dr. Fernando Braga, por toda orientação e suporte dado, sempre muito humano e atencioso. Obrigada pelos ensinamentos, pela dedicação e por ter acreditado em meu trabalho desde o início. Agradeço também pelo incentivo aos novos desafios e pelas conversas descontraídas e que me motivaram nesse processo.

Aos amigos e família de Itabira – MG e Itajubá – MG pelos momentos de descontração e por me ajudarem a recarregar as energias sempre que necessário. Frequentemente interessados nos avanços e nos próximos passos a serem dados nessa pesquisa. Um agradecimento especial ao meu amigo de vida, Lucas Brandão, pela amizade, por compartilhar seus conhecimentos de jornada acadêmica e, acima de tudo, por permanecer ao meu lado por tantos e tanto anos.

Aos colegas do Núcleo de Modelagem e Simulação em Meio Ambiente e Recursos e Sistemas Hídricos – NUMMARH, pelas contribuições feitas ao longo dessa jornada. Em especial, ao Alex Takeo e à Sara Marques pela amizade construída que vai além dos conselhos técnicos sempre muito proveitosos.

Aos colegas que ingressaram comigo na turma do mestrado em 2023.1 do POSMARH pelas trocas acadêmicas e momentos de desconpressão. E ao corpo docente pela competência e pelos conhecimentos lecionados.

À Universidade Federal de Itajubá – UNIFEI por proporcionar a infraestrutura técnica para o desenvolvimento deste trabalho, principalmente, por meio do Laboratório de Hídrica Computacional – LHC. Estendo o agradecimento aos servidores, essenciais para que todo o sistema universitário funcione plenamente.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pela bolsa de pesquisa atribuída ao desenvolvimento deste trabalho, com processo nº 88887.824439/2023-00.

Ao Projeto Redecope Finep – MCT (Ref. 0983/10) - Ministério da Ciência e Tecnologia, intitulado “Desenvolvimento de tecnologias eficientes para a gestão hidro energética em sistemas de abastecimento de água” e ao Programa Pesquisador Mineiro da Fapemig pelo PPM - 00755-16.

E, por fim, agradeço a todos que contribuíram de alguma forma nessa trajetória.

Toda a nossa ciência, comparada com a realidade, é primitiva e infantil - e, no entanto, é a coisa mais preciosa que temos.

Albert Einstein (1879 – 1955)

RESUMO

A água é um recurso essencial à vida, mas grande parte dela é desperdiçada nas redes de distribuição urbana. No Brasil, as perdas atingem cerca de 40%, sendo 60% deste valor atribuídos a vazamentos. O controle dessas perdas é crucial e representa um desafio complexo, que exige soluções inovadoras e ferramentas avançadas. Ainda assim, muito é desenvolvido de maneira heurística. Neste contexto, este trabalho propõe um método para a setorização de redes de distribuição de água, que foi aplicado à rede *benchmark* Balerna. O método foi estruturado em duas fases: agrupamento, com o uso de mapas auto-organizáveis (SOM), e otimização, utilizando o algoritmo genético NSGA – II. Na fase de agrupamento, o SOM identificou os setores ou Distritos de Medição e Controle (DMCs), apresentando erros de quantização e topográfico de 0,0819 e 0,0700, respectivamente, evidenciando um bom ajuste da rede neural. Na fase de otimização, a locação de válvulas de isolamento e dispositivos de medição resultou em uma redução de 4,55% na pressão média original e em 1,21% na estimativa de perdas da rede original. Simulações adicionais a uma pressão mínima de serviço de 10 mca, atingiram redução de 21,60% da pressão média da rede e na estimativa de 46,47% de perdas (menos 6,02 p.p. em relação às perdas médias originais). A abordagem proposta se demonstrou promissora, combinando técnicas computacionais robustas com baixo esforço computacional e oferecendo uma solução viável para o controle de perdas em sistemas de distribuição de água, mesmo tendo sido aplicada a um modelo de rede naturalmente desafiador devido a sua topografia e às suas características de serviço.

Palavras-chave: Perdas de água. Redes de abastecimento de água. Distritos de Medição e Controle. MiniSom. Pymoo.

ABSTRACT

Water is an essential resource for life, yet a significant portion is wasted in urban distribution networks. In Brazil, water losses reach approximately 40%, with 60% of these attributed to physical losses, such as leaks. Controlling these losses is crucial and represents a complex challenge that demands innovative solutions and advanced tools. Nevertheless, many strategies are still developed heuristically. In this context, this study proposes a method for the sectorization of water distribution networks, applied to the benchmark Balerna network. The method is structured in two phases: clustering, using self-organizing maps (SOM), and optimization, leveraging the NSGA – II genetic algorithm. In the clustering phase, the SOM identified the sectors or District Metering Areas (DMAs), achieving quantization and topographic errors of 0.0819 and 0.0700, respectively, which indicate a well-trained neural network. In the optimization phase, the placement of isolation valves and flow measurement devices led to a 4.55% reduction in the original average pressure and a 1.21% decrease in the estimated network losses. Additional simulations, considering a minimum service pressure of 10 meters, achieved a 21.60% reduction in the network's average pressure and an estimated 46.47% reduction in water losses (6.02 percentage points less than the original average losses). The proposed approach proved to be promising, combining robust computational techniques with low computational effort and offering a feasible solution for loss control in water distribution systems. Despite being applied to a naturally challenging network model, due to its topography and service characteristics, the method demonstrated significant potential for improving network performance.

Keywords: Water losses. Water supply networks. District Metered Areas. MiniSom. Pymoo.

LISTA DE FIGURAS

Figura 1- Componentes de um sistema de distribuição de água.....	20
Figura 2 – Esquema da estrutura básica de um neurônio biológico	25
Figura 3 - Rede neural biológica	26
Figura 4 – Esquema da estrutura de um neurônio artificial.....	26
Figura 5 – Exemplo de um hiperplano gerado pelo <i>perceptron</i>	28
Figura 6 - Topologias das RNA. Feed-forward (FNN) e recurrent (RNN)	28
Figura 7 - Tipos de aprendizado de máquina.....	30
Figura 8 - Esquema do treinamento de um mapa auto-organizável	32
Figura 9 - Exemplo de mapa auto-organizável com neurônios hexagonais	33
Figura 10 – Exemplo de mapa auto-organizável com neurônios retangulares.....	35
Figura 11 – Comportamento da função de vizinhança Gaussiana no SOM	37
Figura 12 - Fluxograma de funcionamento do algoritmo do SOM	40
Figura 13 - Ilustração do ótimo global e do ótimo local	43
Figura 14 - Processo genético típico.....	44
Figura 15 - Funcionamento básico de um algoritmo genético	45
Figura 16 - Distância de Aglomeração do NSGA – II.....	47
Figura 17 – Procedimentos do NSGA – II.....	50
Figura 18 - Esquema ilustrativo de Distritos de Medição e Controle	52
Figura 19 - Etapas do particionamento de uma rede de distribuição de água; (a) rede original; (b) fase de agrupamento; (c) fase de setorização	54
Figura 20 - Etapas da metodologia utilizada	59
Figura 21 - Interface do IDE <i>Spyder</i>	60
Figura 22 - Interface do EPANET - rede Balerma.....	61
Figura 23 - Dados de entrada da rede Balerma	62
Figura 24 - Layout do modelo Balerma.....	64
Figura 25 - Vizinhanças (0, 1 e 2) do neurônio central	68
Figura 26 - Interface EPANET x Python.....	74
Figura 27 - Exemplo de formulação de um problema utilizando a biblioteca <i>Pymoo</i> ...	76
Figura 28 - Inicialização do NSGA – II pela biblioteca <i>Pymoo</i>	77
Figura 29 – Ilustração de <i>crossovers</i> para diferentes tipos de variáveis do <i>Pymoo</i>	79
Figura 30 - Modo de importação atualizado dos módulos do <i>Pymoo</i>	80
Figura 31 - Estrutura da função <i>minimize</i> do <i>Pymoo</i>	81

Figura 32 - Mapas gerados com 110 neurônios: (a) C01; (b) C02; (c) C03 e (d) C04...	85
Figura 33 - Mapas gerados com 400 neurônios: (a) C05; (b) C06; (c) C07 e (d) C08...	86
Figura 34 - Mapas gerados para as configurações adicionais: (a) C0 e (b) C10	86
Figura 35 – Evolução de erros das configurações de 110 neurônios: (a) C01; (b) C02; (c) C03 e (d) C04	87
Figura 36 – Evolução de erros das configurações de 400 neurônios: (a) C05; (b) C06; (c) C07 e (d) C08	88
Figura 37 - Erro de quantização e erro topográfico das configurações adicionais: (a) C09 e (b) C10	88
Figura 38 - Configuração C06: (a) Mapa gerado e (b) Gráfico de evolução dos erros..	91
Figura 39 - Identificação de <i>clusters</i> no SOM para setorização.....	92
Figura 40 - Setores (DMCs) da rede Balerma	93
Figura 41 - Nós conflituantes no processo de setorização.....	94
Figura 42 - Tubulações de fronteira e seus respectivos identificadores	96
Figura 43 - Tubulações de fronteira e tubulações estratégicas	97
Figura 44 - Solução com 8 variáveis de decisão: instalação de 2 VRPs e 6 medidores de fluxo.....	99
Figura 45 - Solução com 11 variáveis de decisão: instalação de 3 VRPs e 8 medidores de fluxo.....	100
Figura 46 - Mapa de pressões da rede Balerma em seu formato original	101
Figura 47 - Mapa de pressões das soluções encontradas: (a) 2 VRPs; (b) 3 VRPs.....	102
Figura 48 - Setorização da rede Balerma pelo estudo de Shekofteh, Yousefi-Khoshqalb e Piratla (2023).....	104
Figura 49 - Setorização da rede Balerma pelo estudo de Wei <i>et al.</i> (2023)	106
Figura 50 - Elevações dos nós da rede Balerma.....	107

LISTA DE TABELAS

Tabela 1 – Pseudocódigo do algoritmo do NSGA – II	50
Tabela 2 - Configuração padrão da biblioteca MiniSom	66
Tabela 3 - Configurações teste dos mapas auto-organizáveis	70
Tabela 4 - Definição de parâmetros do NSGA – II utilizada por estudos da literatura ..	78
Tabela 5 - Resultados dos testes com as configurações do SOM propostas.....	83
Tabela 6 – Resultados dos valores dos erros provenientes do ajuste fino do SOM	90
Tabela 7 - Resultados da execução do NSGA – II.....	98
Tabela 8 - Resultados da execução do NSGA – II com a restrição de pressão mínima de 10 mca	103
Tabela 9 - Resultados da setorização do estudo de Shekofteh, Yousefi-Khoshqalb e Piratla (2023)	105
Tabela 10 - Cálculo do percentual de perdas da rede Balerma.....	108

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
AGs	Algoritmos Genéticos
ANA	Agência Nacional Das Águas E Saneamento Básico
BMU	<i>Best Match Unit</i> ou Neurônio Vencedor
BMUs	<i>Best Match Units</i> ou Neurônios Vencedores
CD	<i>Crowding Distance</i>
CNA	Análise de Redes Complexas
CWS	<i>Centre for Water Systems</i>
DA	Distância de Aglomeração
DCP	<i>Density Peak Clustering</i>
DMC	Distrito de Medição e Controle
DMCs	Distritos de Medição e Controle
EQ	Erro de Quantização
ET	Erro Topográfico
FG	<i>Fast Greedy</i>
FNN	<i>Feed-forward Neural Networks</i>
GN	<i>Girvan-Newman</i>
HUX	<i>Half Uniform Crossover</i>
IA	Inteligência Artificial
IDE	Ambiente de Desenvolvimento Integrado
IWA	<i>International Water Association</i>
KWRI	<i>Kentucky Water Research Institute</i>
NSGA – II	<i>Nondominated Sorting Genetic Algorithm II</i> ou Algoritmo Genético de Ordenação Não-Dominada II

PSO	<i>Particle Swarm Optimization</i> ou Otimização de enxame de partículas
RNA	Rede Neural Artificial
RNN	<i>Recurrent Neural Networks</i>
SNIS	Sistema Nacional de Informações Sobre Saneamento
SOM	<i>Self-Organizing Maps</i> ou Mapas auto-organizáveis
SWR	<i>Short Random Walk</i>
UX	<i>Uniform Crossover</i>
VRP	Válvula Redutora de Pressão
VRPs	Válvulas Redutoras de Pressão

SUMÁRIO

1. INTRODUÇÃO.....	16
2. OBJETIVOS.....	19
3. FUNDAMENTAÇÃO TEÓRICA.....	20
3.1 Redes de Distribuição de Água	20
3.2 Perdas na distribuição de água.....	21
3.3 Modelagem hidráulica e simulação de redes de distribuição.....	23
3.4 Redes Neurais Artificiais	25
3.4.1 Tipos de aprendizado	30
3.5 Mapas auto-organizáveis (<i>Self-organizing maps</i>).....	31
3.5.1 Funcionamento	35
3.5.2 Arquitetura	38
3.5.3 Métricas de avaliação	40
3.6 Algoritmos Genéticos	42
3.6.1 NSGA – II.....	45
3.7 Setorização de redes: Distritos de Medição e Controle.....	51
3.7.1 Técnicas de setorização na literatura	55
3.7.1.1 Setorização de redes utilizando algoritmos	55
3.7.1.2 Setorização de redes utilizando Inteligência Artificial	57
4. METODOLOGIA.....	59
4.1 Etapa 1: Definição das características dos nós a serem consideradas no agrupamento	61
4.2 Etapa 2: Definição da rede neural para agrupamento.....	62
4.3 Etapa 3: Definição do algoritmo genético para otimização.....	63
4.4 Etapa 4: Definição da rede de distribuição de água a ser estudada	64
4.5 Etapa 5: implementação das ferramentas para setorização	65
4.5.1 Implementação dos Mapas Auto-Organizáveis	65
4.5.1.1 Grade de neurônios.....	66
4.5.1.2 Quantidade de atributos	67
4.5.1.3 Taxa de aprendizado	67

4.5.1.4 Raio de vizinhança.....	68
4.5.1.5 Distância de ativação	69
4.5.1.6 Função de vizinhança	69
4.5.1.7 Número de iterações (épocas).....	70
4.5.1.8 Configurações simuladas	70
4.5.2 Implementação do NSGA – II	71
4.5.2.1 Formulação do problema de otimização.....	72
4.5.2.2 Interface EPANET x Python.....	74
4.5.2.3 Criação do modelo do problema.....	75
4.5.2.4 Inicialização do algoritmo, população e operadores genéticos	77
4.5.2.5 Função “minimize”, número de gerações e sementes aleatórias	81
4.6 ETAPA 6: CÁLCULO DE PERDAS E ANÁLISES DE RESULTADOS	82
5. RESULTADOS.....	83
5.1 FASE 1: AGRUPAMENTO DOS NÓS.....	83
5.1.1 Resultados dos testes das configurações iniciais do SOM	83
5.1.2 Ajuste fino dos parâmetros do SOM.....	89
5.1.3 Definição dos setores da rede Balerma	92
5.2 FASE 2: OTIMIZAÇÃO	95
5.2.1 Identificação das tubulações de fronteira	95
5.2.2 Execução do NSGA – II	98
5.2.3 Comparação com estudos de setorização aplicados à rede Balerma	104
5.3 CÁLCULO DE PERDAS NA REDE BALERMA	107
6. CONCLUSÕES E RECOMENDAÇÕES	109
7. REFERÊNCIAS	112
APÊNDICES	127
APÊNDICE A – MAPAS E GRÁFICOS RESULTANTES DO AJUSTE FINO FEITO NAS CONFIGURAÇÕES C06 E C10.....	127

1. INTRODUÇÃO

A água é essencial para a existência humana, desempenhando um papel crucial em diversas atividades, como o uso doméstico, industrial, comercial, agrícola e na criação de animais. Embora seja abundante no planeta, com cerca de 70% da superfície terrestre composta por água, apenas 3% desse recurso é doce, e uma fração ainda menor está diretamente disponível para consumo humano (Singh, 2017).

O aumento populacional e a crescente demanda por água, atrelados às mudanças climáticas, à escassez dos recursos hídricos e à sua distribuição desigual no globo terrestre, impõem desafios significativos ao acesso a esse recurso vital. Esse cenário evidencia a insuficiência no fornecimento hídrico e ressalta a necessidade de intervenções estratégicas, em áreas distintas, para assegurar a sustentabilidade do uso da água.

Um dos principais desafios nesse contexto ocorre na gestão das redes de distribuição, onde as perdas de água, devido ao excesso de pressão e falhas estruturais, são predominantes, especialmente em países em desenvolvimento (Mosetlhe, 2021; Serafeim *et al.*, 2024). As perdas de água são inerentes e estima-se que, em países em desenvolvimento, entre 40% e 50% do volume total de água tratada seja perdido na distribuição. Por outro lado, em países desenvolvidos, as perdas são significativamente menores, variando de 5% a 20%.

Dentre as alternativas que melhor controlam a pressão nas tubulações, a setorização das redes se destaca e emerge como estratégia promissora para reduzir perdas e melhorar a eficiência operacional (Brentan *et al.*, 2022; Wei *et al.*, 2023; Nawik; Chittaladakorn; Pilailar, 2024). A setorização, nada mais é do que a divisão da rede em áreas menores, os chamados Distritos de Medição e Controle (DMCs). Essa abordagem envolve o agrupamento dos nós de demanda da rede, constituindo os grupos – ou setores, e a instalação de medidores de fluxo e de válvulas em pontos estratégicos, de forma a isolar totalmente ou parcialmente os setores.

Os DMCs proporcionam um controle mais eficiente, monitoramento detalhado e melhor gerenciamento do comportamento hidráulico nas tubulações da rede. A setorização também facilita a detecção de vazamentos e identificação de áreas propensas a adversidades, permitindo intervenções mais rápidas e a implementação de manutenções

preventivas. Além disso, os DMCs oferecem uma fonte valiosa de dados, como consumo, fluxo, demanda e variações de pressão ao longo do dia (Bui; Marlim; Kang, 2020).

Atualmente, os setores das redes são definidos de forma heurística e existe grande preocupação no desenvolvimento de métodos com abordagens mais avançadas e automatizadas para a criação dos DMCs. Há uma concordância na concepção de métodos de setorização a partir de duas fases: agrupamento e otimização. E, para tal, pesquisas da área seguem uma tendência crescente na utilização de modelos computacionais, baseados em diversos tipos de algoritmos, redes neurais e técnicas de *cluster* e otimização.

A combinação entre as ferramentas computacionais que podem ser aplicadas na setorização de redes é vastamente diversificada. Portanto, é interessante a escolha de técnicas que gerem menor esforço computacional além da minimização das perdas, o que garante com que os recursos sejam utilizados de maneira eficiente e com que o melhor desempenho da rede seja alcançado.

No que diz respeito à fase de agrupamento, o maior desafio envolve a definição das características dos nós de demanda a serem levadas em consideração para que os setores sejam formados. Por se tratar de um problema complexo, e com inúmeras variáveis e atributos, faz-se interessante a utilização de ferramentas de aprendizado de máquina, principalmente daquelas em que o aprendizado ocorre por meio do reconhecimento de padrões de maneira não-supervisionada, mimetizando o funcionamento cerebral.

Uma das técnicas de aprendizado de máquina utilizadas para esse fim na setorização, é a rede neural criada por Kohonen (1982): os mapas auto-organizáveis, ou *self-organizing maps* (SOM). Essa rede neural é utilizada para *clustering* e reduz a dimensionalidade dos dados de entrada, entregando, ao final de sua execução, um mapa que expõe a similaridade entre os dados e a formação dos grupos.

A versatilidade dessa rede neural pode ser exemplificada por sua utilização em uma proposta de Aksela, Aksela e Vahala (2009) de um método para detecção de vazamentos em redes de distribuição. Os autores treinaram o modelo para que o SOM incorporasse, como dados de entrada, o conhecimento sobre vazamentos de uma rede da Finlândia e dessa forma, foi possível indicar o nível de probabilidade de cada vetor-modelo representar onde ocorrem vazamentos.

O SOM, quando aplicado em estudos de setorização, é associado a outros algoritmos de agrupamento, sendo o *k-means* o mais utilizado (Brentan *et al.*, 2018a; Novarini *et al.*, 2019). Essa abordagem é justificada pela alegação de que, isoladamente, o SOM tende a gerar um número excessivo de grupos ou setores, resultando em elevados custos para as companhias de abastecimento de água devido à necessidade de maior número de dispositivos ou intervenções na rede.

A associação do SOM a outros algoritmos, exige que o número de DMCs desejado seja previamente especificado, para que a ferramenta computacional possa identificar os nós que irão compor cada setor. Isso impõe uma limitação ao espaço de busca, restringindo a capacidade do SOM de reconhecer padrões e *outliers* da rede de distribuição. Consequentemente, observa-se uma lacuna na literatura científica quanto a aplicação do SOM em seu estado puro, sem associação com outros algoritmos ou ferramentas, durante a fase de agrupamento da setorização.

Diante do contexto apresentado, este trabalho propõe um novo método de setorização de redes de distribuição de água empregando o SOM, em sua forma pura, na fase de agrupamento e o algoritmo genético NSGA – II (Deb *et al.*, 2002) na fase de otimização. Essa abordagem visa preencher lacunas existentes na literatura e foi aplicada ao modelo da rede Balerma, proposto por Reca e Martínez (2006), demonstrando sua viabilidade para o controle eficiente de perdas e otimização da operação de redes de abastecimento.

2. OBJETIVOS

O objetivo principal deste trabalho é desenvolver um método de setorização de redes de distribuição de água combinando uma rede neural de aprendizado não-supervisionado (mapas auto-organizáveis) e um algoritmo genético de ordenação não-dominada (NSGA – II) para a alocação de dispositivos hidráulicos, visando a redução de perdas de água.

Tem-se como objetivos específicos:

- a) Implementar os mapas auto-organizáveis, em seu estado puro, na fase de agrupamento da setorização de uma rede de *benchmark* da literatura científica e identificar a configuração de parâmetros ideal da rede neural para o problema em questão.
- b) Aplicar o algoritmo genético NSGA – II na fase de otimização da setorização da rede de distribuição de água e identificar os melhores pontos da rede para instalação de dispositivos hidráulicos.
- c) Avaliar de maneira comparativa o percentual de perdas inerentes da rede original e da rede setorizada.

3. FUNDAMENTAÇÃO TEÓRICA


Nesta seção são abordados conceitos teóricos e estudos da literatura científica essenciais para o desenvolvimento dessa pesquisa.

3.1 REDES DE DISTRIBUIÇÃO DE ÁGUA

Os sistemas de distribuição de água são um conjunto de obras, equipamentos, acessórios, tubulações, reservatórios, bombas e serviços destinados ao abastecimento de água potável a uma comunidade dentro de condições sanitárias, de vazão e pressão adequadas, para fins de consumo doméstico, serviços públicos, consumo industrial e outros usos (Azevedo Netto *et. al*, 1998; Porto, 2006).

O sistema de abastecimento público de água engloba diversos elementos e práticas: manancial, captação, adução (água bruta e água tratada), tratamento, reservatórios, distribuição (redes distribuidoras) e estações elevatórias ou de recalque – quando necessárias (Azevedo Netto *et. al*, 1998). A Figura 1 ilustra os componentes de um sistema de distribuição de água.

Figura 1- Componentes de um sistema de distribuição de água



Fonte: Notas de aula do Prof. Hugo Alexandre Soares Guedes - UFPEL¹

O foco desta pesquisa está na rede de distribuição que é a unidade do sistema responsável por conduzir a água aos pontos de consumo. Segundo Tsutiya (2006) este é o componente mais custoso do sistema de abastecimento de água, envolvendo em torno de 50% a 75% do custo de todas as obras de abastecimento.

¹ Disponível em: <<https://wp.ufpel.edu.br/hugoguedes/files/2018/08/Aula-1-Abastecimento-e-concep%C3%A7%C3%A3o.pdf>>. Acesso em: 24 jan. 2024.

As redes são constituídas por condutos classificados como principais (ou troncos) e secundários. Sendo os principais aqueles de maior diâmetro e que têm por finalidade abastecer os condutos secundários (Porto, 2006). Os secundários possuem menor diâmetro e abastecem diretamente os pontos de consumo (Tsutiya, 2006). As redes podem ser classificadas como “ramificadas”, “malhadas” ou “mistas”, de acordo com a disposição das tubulações e o sentido de escoamento (Porto, 2006; Tsutiya, 2006).

De acordo com Porto (2006), a concepção geométrica da rede de distribuição está atrelada ao porte da cidade, bem como às características viárias e topográficas. Além disso, a junção de outros fatores como dinâmicas de consumo e uniformidades da rede acabam tornando o sistema de abastecimento bastante complexo tanto em questões de dimensionamento, quanto à operação e manutenção (Brentan *et al.*, 2022; Porto, 2006).

3.2 PERDAS NA DISTRIBUIÇÃO DE ÁGUA

Pearson (2019) em publicação da *International Water Association* (IWA), define perdas como a diferença entre o volume de água que entrou no sistema e o volume de consumo autorizado, ou seja, medido nos hidrômetros. As perdas são classificadas, quanto à sua natureza, como reais ou aparentes

As perdas reais representam a água que não chega ao consumo devido a vazamentos em reservatórios, redes, ramais, adutoras, conexões e em outros elementos da rede, neste caso, a água entra no sistema, mas não chega a passar pelo hidrômetro do usuário; já as perdas aparentes (não-físicas) são provenientes de submedição, fraudes e ligações clandestinas, ou seja, a água é distribuída para o usuário, mas não é registrada pela entidade operadora do sistema (Agência Nacional Das Águas e Saneamento Básico – ANA, 2021).

As perdas são inerentes nos sistemas de abastecimento e estão presentes mesmo com infraestruturas bem desenvolvidas e boas práticas operacionais (Brasil, 2020; Fritz; Gimenes; Pina Filho, 2020). Dificilmente as perdas serão completamente eliminadas, já que os sistemas de abastecimento são extremamente complexos, envolvendo inúmeras variáveis tanto de infraestrutura quanto gestão, sendo um desafio para os gestores e engenheiros de recursos hídricos desenvolverem ferramentas para mitigar o problema e garantir a sustentabilidade do sistema.

Em conjunto com as perdas, o que vem ocorrendo globalmente é o crescimento da demanda de água e a diminuição da oferta (Fritz; Gimenes; Pina Filho, 2020). Essa escassez dos recursos hídricos está atrelada ao rápido crescimento populacional e à urbanização e se tornou um desafio a ser enfrentado por países em todo o planeta (Rahman; Muhammad; Mohtar, 2018).

As perdas reais (vazamentos) são causadas por inúmeros fatores, entre eles, o mais significativo é o excesso da pressão de serviço que deve estar dentro do intervalo de 10 a 40 mca determinado pela NBR 12218 (ABNT, 2017), por isso é tão essencial o monitoramento e o controle dessa variável em especial (Muhammetoglu *et al.*, 2017; Zhang *et al.*, 2017; Brasil, 2020; Bui; Marlim; Kang, 2020; Mahardini; Tangahu, 2023). O excesso de pressão atrelado ao envelhecimento das tubulações está diretamente ligado às causas de rupturas (Giustolisi *et al.*, 2023).

Os vazamentos também são associados à qualidade da infraestrutura, dos materiais utilizados na rede de distribuição, da idade das tubulações, além da qualidade da manutenção, da mão de obra, das condições de assentamento dos condutos, do tráfego e também à ausência de programas de monitoramento de perdas (Tardelli Filho, 2016; Brasil, 2020).

A operação de redes de distribuição de água é afetada em diversos aspectos pelas perdas reais, desde a qualidade do serviço prestado, à piora no consumo energético e de insumos para tratamento, além de perdas econômicas e até mesmo riscos sanitários (Giustolisi *et al.*, 2023). Portanto, o controle de perdas de água não visa exclusivamente a sustentabilidade hídrica, mas envolve concomitantemente o âmbito econômico, energético, ambiental, sanitário e a eficiência do sistema como um todo.

Para lidar com as perdas de água, a medição distrital tem sido comumente utilizada para melhorar a gestão dos sistemas de distribuição de água. Os DMCs facilitam a estimativa de localização dos vazamentos, permitem o monitoramento da performance da rede, a gestão e a redução das perdas aparentes, além de possibilitarem o controle ativo dos vazamentos e de políticas apropriadas de gestão e controle de pressões (Nawik; Chittaladakorn; Pilailar, 2024).

3.3 MODELAGEM HIDRÁULICA E SIMULAÇÃO DE REDES DE DISTRIBUIÇÃO

Modelagem é o processo de produzir um modelo, ou seja, uma representação da construção e funcionamento de algum sistema. Um dos propósitos de um modelo é possibilitar a predição de efeitos de mudanças em determinado sistema, para isso, deve ser o mais próximo possível da situação real, incorporando ao máximo as características proeminentes possíveis. Um bom modelo deve encontrar um equilíbrio entre realidade e simplicidade. Modelos muito complexos podem acabar impossibilitando o entendimento e a análise do experimento em si (Maria, 1997).

Simulação é a operação do modelo de um sistema. O modelo pode ser reconfigurado de forma a simular cenários que seriam, normalmente, impossíveis, muito caros ou impraticáveis de se testar no sistema real. A simulação é uma ferramenta para avaliar o desempenho de um sistema existente ou proposto, permitindo o estudo da operação do modelo sob diversas perspectivas e/ou configurações e, portanto, propriedades do comportamento do sistema real podem ser inferidas. Além disso, as simulações reduzem as chances de falhas, eliminam gargalos, superutilização de recursos e otimização do sistema como um todo (Maria, 1997).

Com o advento da tecnologia, há a possibilidade de representar sistemas dinâmicos e complexos (como redes de distribuição de água) em computadores. O que afasta a necessidade de construção e teste real dos sistemas. A aplicabilidade da modelagem e simulação é válida para qualquer situação que possa ser formalizada e tornada computável, e isso foi ampliado pelo fato de os computadores poderem processar com rapidez e precisão qualquer formulação matemática ou lógica. A vista disso, a modelagem e simulação desempenham um papel muito importante em entendimento científico, criação de tecnologias, operação de sistemas e planejamento de desenvolvimento (Bossel, 2018).

Os modelos hidráulicos de redes de distribuição são ferramentas eficientes para cálculos e previsão do comportamento de fluxos, velocidades, pressões, níveis de reservatórios e custos operacionais, por exemplo. Nas últimas décadas, as simulações hidráulicas têm sido constantemente melhoradas em termos matemáticos e computacionais e se tornaram

uma poderosa ferramenta de tomada de decisão para engenheiros e cientistas que trabalham com a operação das redes (Arsene; Al-Dabass; Hartley, 2012).

Os simuladores hidráulicos vêm integrados com um sistema de informação geográfica, fornecem ferramentas de gerenciamento de dados, possuem apresentações gráficas e capacidades de diagnósticos satisfatórias, analisam e executam estados estacionários e simulações de tempo estendido para sistemas de distribuição de água muito grandes, sendo bem completos e eficientes (Arsene; Al-Dabass; Hartley, 2012).

Dentre os *softwares* hidráulicos mais utilizados na área, segundo Costa e Frota (2018), está o EPANET (*Environmental Protection Agency's Network*), desenvolvido pela *USA Environmental Protection Agency* (Agência de Proteção Ambiental dos Estados Unidos). Os atrativos do programa vão além da facilidade de uso e fornecimento gratuito: o EPANET permite a modelagem hidráulica e execução de simulações estáticas e dinâmicas do comportamento e da qualidade de água em redes de distribuição (Costa; Frota, 2018). O *software* se tornou uma ferramenta popular para analisar tanto redes simples, quanto complexas, sendo um aparato para melhorar o entendimento do comportamento da água em redes de distribuição (Veer *et al.*, 2022).

Uma das maiores vantagens do EPANET é a possibilidade de desenvolver programas, por meio de linguagens de programação, como Python, R, C/C++, MATLAB, dentre outros (Kyriakou *et al.*, 2023). Para tal, o *EPANET Programmer's Toolkit*, um conjunto de funções de cálculos hidráulicos, permite que programadores interajam diretamente com o EPANET de acordo com suas necessidades específicas, como por exemplo: otimização de diâmetros, calibração de redes, otimização de estratégia de bombas, dentre inúmeras aplicações (Costa; Frota, 2018).


Os avanços nos estudos têm incorporado estratégias mais sofisticadas, destacando-se a crescente utilização da modelagem hidráulica e simulação de cenários no EPANET, apoiada pela poderosa ferramenta *Toolkit*. Podendo ser destacados os trabalhos de Silva (2019), Silva *et al.* (2020), Marques (2023), Marques *et al.* (2023a), Marques *et al.* (2023b), Silva (2023) e Lara *et al.* (2024a). Visando contemplar necessidades específicas, esta pesquisa emprega o EPANET em conjunto com a *Toolkit*, proporcionando uma abordagem mais robusta e aproveitando a versatilidade e funcionalidades oferecidas por essa combinação de ferramentas.

3.4 REDES NEURAIS ARTIFICIAIS

Os estudos das Redes Neurais Artificiais (RNAs), tiveram início com um modelo matemático do neurônio biológico desenvolvido por Warren McCulloch e Walter Pitts (1943). As RNAs são modelos matemáticos que tentam simular o funcionamento e estrutura de um cérebro humano, capazes de adquirir, manter e generalizar conhecimentos e possuem como estrutura básica o neurônio artificial (Amaral, 2020; Krogh, 2008; Krenker; Bester; Kos, 2011).

Na Figura 2 é possível visualizar uma ilustração de como é a estrutura básica de um neurônio biológico.

Figura 2 – Esquema da estrutura básica de um neurônio biológico




Fonte: Adaptado de Abraham (2005)

A configuração de um neurônio biológico compreende a “soma”, uma região onde se localiza o núcleo, também chamada de corpo celular ou pericário; além dos dendritos e axônios, finos tubos (neuritos) que se irradiam do corpo celular, sendo o axônio a estrutura responsável pelos processos de transferência de informações de um neurônio para o outro através da sinapse (transmissão sináptica) e os dendritos responsáveis por receber as sinapses (as informações). O núcleo é a estrutura na qual o processamento das informações é feito (Bear *et al*, 2017).

A Figura 3 ilustra uma rede neural humana, na qual pode-se observar os numerosos neurônios e suas conexões.


Figura 3 - Rede neural biológica



Fonte: Hubel (1988) apud Bear *et al.* (2017)

O neurônio artificial é análogo ao neurônio biológico em vários aspectos. Assim como os dendritos recebem sinais de entrada no neurônio biológico, o neurônio artificial também possui um número n de entradas para receber os estímulos externos. Da mesma forma que o núcleo desempenha um papel importante na regulação e processamento das informações no neurônio biológico, no neurônio artificial, os estímulos recebidos na entrada são ponderados pelos pesos sinápticos, combinados linearmente e submetidos à ação de uma função de ativação. Por fim, o sinal resultante da atuação do núcleo vai para a estrutura de saída, semelhante com a função do axônio (Amaral, 2020). A Figura 4 ilustra de forma didática a estrutura de um neurônio artificial.

Figura 4 – Esquema da estrutura de um neurônio artificial



Fonte: Adaptado de Krogh, 2008

O modelo matemático, criado em 1943 por McCulloch e Pitts, foi desenvolvido como um “interruptor” que recebe a informação e pode ser ativado, ou não, dependendo da entrada total ponderada. O peso pelo qual o dado de entrada é multiplicado representa a força da sinapse, podendo ser positivo (excitatório) ou negativo – inibitório (Krogh, 2008). Na Figura 4 as entradas, representadas em x_1, x_2, x_3 e x_n , são associadas aos pesos

$(w_1, w_2, w_3$ e $w_n)$ tornando então a entrada total do neurônio que é a soma ponderada sobre todas as entradas, representada pela Equação (1):

$$\sum_{i=1}^n w_i x_i = w_1 x_1 + w_2 x_2 + \dots + w_n x_n \quad (1)$$

O valor resultante dessa soma ponderada passa por uma função de ativação que controla o nível de ativação do neurônio. A função de ativação, também chamada de função de transferência (*transfer function*) pode ser qualquer função matemática e é escolhida com base no problema a ser resolvido. Algumas das mais comumente usadas são a *Step function*, *Linear function* e *Non-linear (sigmoid) function* (Krenker; Bester; Kos, 2011).

A *step function* (função degrau), por exemplo, é uma função binária, possuindo apenas duas possibilidades de valores. O que significa que se a entrada atingir um limite específico, a saída resultará em um valor e se o limite não for atendido, isso resultará em um valor de saída diferente (Krenker; Bester; Kos, 2011). A Equação (2) define a função degrau.

$$f(x) = \begin{cases} c_1, & \text{se } x < a \\ c_2, & \text{se } x \geq a \end{cases} \quad (2)$$


Quando uma função de ativação desse tipo é empregada em uma rede neural, o neurônio artificial é denominado *perceptron*. O *perceptron* é reconhecido como um classificador binário, de camada única, utilizado amplamente para resolver problemas simples de classificação de padrões. Foi criado e desenvolvido por Frank Rosenblatt (1958) (Abraham, 2005; Krenker; Bester; Kos, 2011).

O *perceptron* tem como limitação a sua capacidade de aprendizado. Isso porque este pode solucionar somente problemas linearmente separáveis. O que significa que é possível resolver problemas se as duas classes – por isso a função degrau – puderem ser separadas por um hiperplano (Abraham, 2005; Krogh, 2008). A Figura 5 ilustra um exemplo de hiperplano gerado pelo *perceptron* classificando os dados relativos a +1 com representação gráfica de cruz e os dados relativos a -1 com representação gráfica de “x”.

Normalmente, os problemas reais são mais complexos, não sendo linearmente separáveis. Para lidar com problemas não lineares podem ser introduzidos mais hiperplanos, formando, portanto, uma rede contendo mais do que uma camada (Krogh, 2008). Esse

tipo de rede neural é chamado de multicamada, em outras palavras, da mesma maneira que a rede neural humana, formada pela interconexão de neurônios, no conceito computacional, as redes neurais são compostas pela associação de neurônios que formam as redes multicamadas.


Figura 5 – Exemplo de um hiperplano gerado pelo *perceptron*



Fonte: Adaptado de Marim, Oliveira e Villela (2019)

A maneira como os neurônios artificiais estão interconectados na rede neural, é comumente chamada de topologia ou arquitetura e, como essa interconexão pode ser feita de inúmeras maneiras, as topologias são divididas em duas grandes classes básicas, representadas na Figura 6 (Krenker; Bester; Kos, 2011).

Figura 6 - Topologias das RNA. Feed-forward (FNN) e recurrent (RNN)



Fonte: Krenker, Bester e Kos (2011)

A primeira classe é a *feed-forward neural networks* (FNN), na qual a informação chega pela camada de entrada, passa pelas camadas escondidas e chega à camada de saída,

seguindo somente uma direção de fluxo. Já na classe recorrente (*recurrent neural networks* – RNN) a informação não segue somente uma direção de fluxo, mas pode seguir a direção oposta contendo conexões de *feedback*. Ao determinar a classe e arquitetura de uma rede neural a ser utilizada, finaliza-se apenas metade do processo de resolução do problema desejado (Abraham, 2005; Krenker; Bester; Kos, 2011).

Não há uma arquitetura ideal, cada uma delas possui seus pontos fortes e fracos, o que se busca é sempre encontrar a melhor solução possível para determinado problema. Um ponto de extrema relevância é a definição da quantidade de neurônios, camadas, pesos sinápticos e de demais parâmetros relacionados à classe e à arquitetura da RNA que está sendo utilizada. Fleck *et al.* (2016) ressaltam que a estimação de parâmetros, é conhecida como treinamento, um processo iterativo, no qual os parâmetros iniciais são utilizados até a convergência.

Normalmente, a definição da configuração da rede neural por meio de seus parâmetros é feita de maneira empírica. Na literatura existem alguns métodos para obter a melhor configuração da rede, porém esses métodos possuem limitações, podendo não alcançar o resultado esperado tendo em vista o problema em questão (Amaral, 2020). Silva (2023) também destaca que nem sempre uma RNA muito complexa implicará em melhor desempenho, podendo até exceder a necessidade do projeto e envolver um custo computacional desnecessário. Além disso, de acordo com Fleck *et al.* (2016), nas RNAs assim como ocorre no cérebro, o comportamento das variáveis não é rigorosamente conhecido.

À vista disso, é possível fazer uso de algoritmos e funções necessárias e específicas ao problema a ser resolvido. Por possibilitarem o processamento de muitos dados e variáveis, as RNAs visam a resolução de problemas multifacetados, sendo capazes de aprender a tomar decisões baseadas em seu próprio aprendizado (Fleck *et al.*, 2016). A capacidade de aprendizado de uma rede neural é alcançada ajustando os pesos na etapa de treinamento de acordo com o algoritmo de aprendizagem escolhido (Abraham, 2005).

Vale ressaltar que um sistema neural humano é muito mais complexo do que as redes neurais artificiais. A ciência ainda tem muito o que estudar e entender sobre os detalhes mais específicos do cérebro. As RNAs são inspiradas no funcionamento das redes neurais


biológicas, realizando o processo de aprendizagem e a troca de informações de maneira semelhante ao que acontece no cérebro humano.

RNAs são embasadas, portanto, em neurociência, matemática, física, estatística, ciência da computação e engenharia, podendo ser aplicadas em inúmeros campos como, por exemplo, em modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle de processos. A possibilidade de aplicação das redes neurais em diversas áreas é caracterizada pela habilidade de aprendizado a partir dos dados de entrada, seja por um aprendizado supervisionado, não-supervisionado ou por reforço (Abraham, 2005; Fleck, *et al.*, 2016).

3.4.1 Tipos de aprendizado

O aprendizado de máquina (*machine learning*) é basicamente a técnica utilizada para ensinar máquinas a lidar e trabalhar com determinado tipo de dado de maneira mais eficiente (Mahesh, 2020). As técnicas de aprendizado de máquina são orientadas a dados, ou seja, aprendem automaticamente a partir dos dados de entrada (Ludermir, 2021). Os tipos de aprendizado podem ser classificados em supervisionado, não-supervisionado e por reforço, como mostra a Figura 7.

Figura 7 - Tipos de aprendizado de máquina



Fonte: A autora

No aprendizado supervisionado os dados de entrada são apresentados com um *set* de saídas desejadas (uma para cada entrada), ou seja, são dados pré-categorizados (ou rotulados). Ao final do treinamento, o objetivo é que o classificador consiga determinar corretamente a classe de novos exemplos ainda não rotulados. Portanto, para o

aprendizado supervisionado, é necessário prover um professor externo à rede neural (Abraham, 2005; Ludermir, 2021).

Ao contrário do aprendizado supervisionado, o não-supervisionado não possui um professor externo. Os algoritmos trabalham por si só para descobrir e aprender sobre as similaridades (padrões) das características dos dados. Então, quando uma nova classe de dados é introduzida, as características aprendidas anteriormente são utilizadas para reconhecer a classe de dados. Em geral, é necessária uma análise para determinar o significado de cada grupo no contexto do problema a ser resolvido. Esse tipo de aprendizado é utilizado para agrupamento (*cluster*), redução de dimensionalidade e associação (Mahesh, 2020; Ludermir, 2021).

O aprendizado por reforço é bastante utilizado em jogos e robótica. O algoritmo faz uma hipótese e determina se essa hipótese foi boa ou não, a partir de um sinal de reforço de recompensa ou punição (Ludermir, 2021). Esse tipo de aprendizado não está relacionado a dados, mas sim a um ambiente virtual ou real para interação.

3.5 MAPAS AUTO-ORGANIZÁVEIS (*SELF-ORGANIZING MAPS*)

Os mapas auto-organizáveis, ou *self-organizing maps* (SOM), são um algoritmo de aprendizado de máquina não supervisionado proposto por Kohonen (1982). Esse tipo de rede neural artificial não possui camadas ocultas e produz um mapeamento direto entre o conjunto de treinamento e a rede de saída (Kind; Brunner, 2013). A inspiração da criação dessa rede neural surgiu do modo pelo qual informações sensoriais são mapeadas no cérebro, especialmente no hipocampo e no córtex cerebral, sobre estimulação visual e de memória (Kohonen, 1982; Costa, 1999; Brentan *et al.*, 2018a).

Devido ao seu método automático de análise de dados, os também chamados mapas de Kohonen são amplamente utilizados em uma variedade de contextos, incluindo indústria, finanças, medicina, engenharia, ciências naturais e linguística. A rede neural é empregada em uma gama diversificada de problemas relacionados à exploração e agrupamento de dados, destacando sua versatilidade e aplicabilidade em diferentes domínios (Kohonen, 2013).


Kohonen *et al.* (2000) explica que a aplicabilidade da ferramenta em múltiplas e distintas áreas de estudos, se dá devido a habilidade do SOM em aprender a partir de dados com

inúmeras dimensões, resultando em uma camada de saída bidimensional (ou tridimensional, dependendo da aplicação), ou seja, acontece a redução dimensional dos dados e o agrupamento de padrões ou características semelhantes.

O resultado do SOM consiste em um mapa (gráfico) que representa a relação de similaridade entre os dados de entrada. A Figura 8, mostra uma representação esquemática de como um mapa auto-organizável é treinado. Na imagem está representada a camada de entrada correspondente ao vetor de dados de entrada; a matriz de pesos com os quais os dados de entrada são associados e, por fim, a camada de saída, composta pela grade de neurônios 2D.

A partir da Figura 8, percebe-se que todas as entradas estão conectadas a todos os neurônios de saída. Cada neurônio possui uma quantidade de pesos igual ao número de atributos (ou características) dos dados de entrada. Ou seja, se cada dado possui n características, cada neurônio possuirá n pesos.

Figura 8 - Esquema do treinamento de um mapa auto-organizável




Fonte: Adaptado de Kind e Brunner (2013)

O SOM é uma ferramenta muito útil para visualização de dados. Costa (1999) destaca que, geralmente, como as situações reais são multidimensionais (possuem mais do que dois atributos – características – ou variáveis) a visibilidade da relação entre os dados é prejudicada. A organização espacial no mapa facilita uma visualização conveniente e a rápida inspeção da similaridade dos dados de entrada, bem como sua tendência de

agrupamento. Com uma calibração do modelo mais adequada, os grupos dos dados se tornam mais explícitos (Kohonen, 2013).

Na Figura 9 é possível verificar um exemplo de como os dados podem ser visualizados em um mapa auto-organizável utilizando a grade de neurônios em forma hexagonal, um dos formatos mais comuns de serem empregados.

Figura 9 - Exemplo de mapa auto-organizável com neurônios hexagonais



Fonte: Melo *et al.* (2019)

A Figura 9 é resultado do trabalho de Melo *et al.* (2019), cujo objetivo foi verificar a eficácia do SOM como uma ferramenta de investigação de processos biogeoquímicos, de forma a entender a influência dos padrões de uso do solo na qualidade da água de reservatórios. O primeiro mapa (a), é um mapa das amostras do estudo, as quais foram divididas em 17 grupos. Na segunda parte da figura (b), estão ilustrados os mapas de variáveis, que indicam a intensidade, ou influência, de cada variável (atributo). As amostras de Melo *et al.* (2019), continham 31 atributos, ou seja, 31 dimensões, e foram reduzidas a uma visualização 2D de forma clara e com o agrupamento facilmente identificável.


Comumente, a grade de neurônios também pode assumir forma retangular por questões de simplicidade ou mesmo opção do usuário. No entanto, Kohonen (2013) sugere que a grade hexagonal é mais adequada, pois além de ser mais visualmente representativa, também oferece maior precisão. Essa precisão está relacionada com a quantidade de vizinhos conectados em um neurônio. Em grades retangulares pode-se ter uma vizinhança tipo 4-conectados e em grades hexagonais, 6-conectados (Costa, 1999).

Essa estrutura de vizinhança influencia em como os neurônios se organizam em grupos. Quanto mais vizinhos conectados o neurônio tiver, maior a área de influência dos vizinhos durante o treinamento, o que permite que dados com características semelhantes permaneçam próximos entre si, conservando a topologia do espaço original. Outra questão é a suavização da atualização dos pesos (como será visto mais a frente): a quantidade de vizinhos afeta a rapidez com que o SOM converge para uma configuração estável. Uma vizinhança mais ampla pode suavizar a atualização e levar a uma convergência mais suave e estável do treinamento.

A Figura 10 mostra a sua esquerda um diagrama ilustrativo, retirado do trabalho de Ebbels (2007), do SOM enfatizando os vizinhos de um neurônio destacado em preto. Percebe-se o grau de influência dos neurônios vizinhos pelos tons de cinza que vão do escuro (mais próximos do neurônio destacado) ao mais claro (distantes do neurônio destacado).

Ainda na Figura 10, à direita, observa-se mapas gerados nos estudos de Beckonert *et al.* (2003) sob a grade de neurônios retangulares. O trabalho tem por objetivo visualizar mudanças metabólicas em tecidos com câncer de mama. O mapa superior esquerdo mostra as áreas dos diferentes graus de tumor. Os demais mapas correspondem à influência que cada atributo analisado possui nos diferentes graus de tumor. De acordo Beckonert *et al.* (2003), o SOM no estudo permitiu a identificação de informações bioquímicas relevantes para caracterizar grupos de tumor maligno fornecendo suas diferenças metabólicas.

Figura 10 – Exemplo de mapa auto-organizável com neurônios retangulares



Fonte: Ebbels (2007) e Beckonert *et al.* (2003)

Kohonen (1990) destaca que a propriedade especial dos mapas auto-organizáveis é a criação efetiva e espacialmente organizada de representações internas para várias características dos dados de entrada e suas abstrações. Assim, o SOM é capaz de transformar relações estatísticas complexas e não lineares entre dados de alta dimensão em relações geométricas simples em uma exibição de baixa dimensão, preservando a topologia dos dados.

3.5.1 Funcionamento

O treinamento do SOM, possui três estágios de aprendizado: competição, colaboração e adaptação sináptica, e segue um conjunto de etapas, que serão detalhadas posteriormente. Antes do início do treinamento, os dados a serem analisados são importados para dentro da rede neural e passam pelo processo de normalização, para então os pesos dos neurônios (ou conexões sinápticas) serem inicializados, no caso deste estudo, de forma aleatória.

O aprendizado competitivo do SOM envolve a seleção do neurônio cujos pesos são mais semelhantes às coordenadas do dado de entrada. Isso é feito calculando a distância entre os pesos de cada neurônio e as coordenadas do dado de entrada, isso faz com que os neurônios compitam entre si para ter a menor distância. Uma vez encontrado o neurônio

mais próximo, ou seja, que tem maior nível de ativação, o dado é associado a esse neurônio, chamado de *Best Match Unit* (BMU) ou neurônio vencedor.

A fase de competição é responsável por indicar no mapa a região (vizinhança) mais ativada por certo dado de entrada, o que significa que os neurônios se especializam em estímulos apresentados de forma não supervisionada (Costa, 1999; Brentan *et al.*, 2018a). O cálculo das distâncias normalmente é feito utilizando a função de distância Euclidiana.


Na segunda fase do treinamento, conhecida como fase cooperativa, o neurônio vencedor passa por uma leve alteração em seus pesos, buscando torná-los ainda mais semelhantes às coordenadas do dado de entrada. Além disso, os neurônios adjacentes também sofrem ajustes leves, enquanto aqueles mais distantes do BMU são modificados em menor grau. Portanto, todos os neurônios são atualizados nessa etapa. É durante essa fase que se define a extensão da influência do neurônio vencedor sobre sua vizinhança.

Em resumo, o neurônio vencedor determina a localização espacial central de uma vizinhança topológica de neurônios excitados, fornecendo assim a base para a cooperação entre esses neurônios vizinhos. Esse processo cooperativo é baseado na evidência neurobiológica de interação lateral entre neurônios excitados no cérebro humano. A função que normalmente é utilizada e representa satisfatoriamente esse fenômeno é a função Gaussiana, ou função de Gauss (Haykin, p. 431, 2009).

Quando compartilhado o “entusiasmo” ou “recompensa” do BMU com sua vizinhança, há uma adaptação, assim, mesmo que os neurônios da camada de saída não estejam conectados diretamente, eles tendem a compartilhar características comuns, devido a este parâmetro de vizinhança (Larose; Larose, 2014).

A Figura 11 faz destaque ao neurônio vencedor e à função de vizinhança da rede e basicamente representa as duas primeiras etapas de treinamento do SOM. O BMU destacado em vermelho calculado na fase de competição, e a função de vizinhança representada pela curva em vermelho, que demarca a localização espacial dos neurônios excitados e ordena topologicamente o mapa para que os padrões estejam próximos na grade de neurônios (fase de cooperação).

Figura 11 – Comportamento da função de vizinhança Gaussiana no SOM



Fonte: Adaptado de Spiegel (2007) *apud* Larose (2004)

Na terceira fase, adaptação sináptica, o neurônio vencedor ajusta seus pesos de forma a aumentar sua sensibilidade aos dados de entrada que são semelhantes aos que ativaram esse neurônio anteriormente. Em suma, quando um dado de entrada semelhante é apresentado à rede, o BMU será mais propenso a ser ativado novamente pois os pesos foram ajustados para responder fortemente a esse tipo específico de entrada aumentando, portanto, as suas chances de “vencer” novamente (Larose; Larose, 2014).

A adaptação sináptica é a fase de aprendizado da rede neural, que também pode ser chamada de aprendizado de Kohonen. Esse processo é feito pelo ajuste dos pesos dos neurônios vizinhos ao vencedor usando uma combinação linear do vetor de entrada e do vetor atual de pesos. Os pesos do BMU são somados ao resultado da multiplicação da taxa de aprendizado pela função de vizinhança e pela diferença entre o vetor de entrada e os pesos atuais (Larose; Larose, 2014).

Todo esse processo está mais claro, com todas as equações e variáveis, na próxima subseção referente à arquitetura do SOM. Importante ressaltar que não existe um critério de convergência ou minimização, o algoritmo trabalha com o número definido, pelo usuário, de iterações (ou épocas) durante a fase de aprendizado e adaptação dos pesos (Costa, 1999; Kitani, 2013).

3.5.2 Arquitetura

A arquitetura do SOM, caracterizada como uma rede *feedforward*, é composta por duas camadas de neurônios: a camada de entrada, I , e a camada de saída (ou camada de Kohonen), U . A entrada da rede corresponde a um vetor, $\mathbf{x} = [x_1, x_2, \dots, x_i]$, onde $i = 1, 2, \dots, N$, onde N é o número de dados. Os dados de entrada podem ser denotados como $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{ip}]^T$, onde $p = 1, 2, \dots, P$, sendo P o número total de características dos dados de entrada. O vetor de pesos sinápticos de cada neurônio j é denotado por: $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jp}]^T$, com $j = 1, 2, \dots, l$, sendo l o número total de neurônios do mapa. (Costa, 1999; Haykin, 2009; Gonçalves; Andrade Netto; Costa, 2007; Kitani, 2013).

Pode-se descrever o processo de treinamento do SOM nos seguintes passos (Deboeck; Kohonen, 1998; Costa, 1999; Kitani, 2013):

1. Preparação da rede:
 - a. Definição do formato da grade de neurônios (unidimensional, bidimensional, tridimensional).
 - b. Definição da grade de vizinhança entre os neurônios (comumente retangular ou hexagonal).
 - c. Definição do número de neurônios (l).
 - d. Definição do número de iterações T tal de $T > N$, sendo N o número de amostras (quantidade de dados).
2. Apresentação do dado de entrada, $\mathbf{x}_i$, à rede, onde o dado $\mathbf{x}_i$ é a i -ésima entrada no tempo t .
3. Calcular a distância Euclidiana – Equação (3) – entre as características do dado de entrada $\mathbf{x}_i$ com os pesos de cada neurônio, ou seja, calcular o estado de cada neurônio em relação aos dados de entrada:

$$d(\mathbf{w}_j, \mathbf{x}_i) = \|\mathbf{w}_j - \mathbf{x}_i\| = \sqrt{\sum_{p=1}^P |w_{jp} - x_{ip}|^2} \quad (3)$$

4. Definir o neurônio vencedor, c , também conhecido como *Best Match Unit* (BMU) – Equação (4), que produziu a menor distância Euclidiana, ou seja, maior similaridade:

$$\|\mathbf{x}_i - \mathbf{w}_j\| = \min \|\mathbf{x}_i - \mathbf{w}_j\| \quad (4)$$

5. Atualizar o peso do neurônio vencedor, c , e de seus vizinhos, cujo tamanho da vizinhança é definido por $\sigma_c(t)$. Sendo os novos pesos corrigidos por:

$$w_j(t+1) = w_j(t) + \alpha(t)h_{c_j}(t)||x_i(t) - w_j(t)|| \quad (5)$$

Onde a taxa de aprendizado $\alpha(t)$ é diminuída constantemente, por uma função de decaimento. A escolha da função depende do usuário e, normalmente, são utilizadas funções lineares – Equação (6), inversas do tempo – Equação (7) ou séries de potências, Equação (8) – (Stefanovic e Kurasova, 2011; Natita, Wiboonsak e Dusadee, 2016). Além dessas, a função de decaimento exponencial – Equação (9) – também é muito utilizada (Kohonen, 2001):

$$\alpha(t) = \frac{1}{t} \quad (6)$$

$$\alpha(t, T) = \left(1 - \frac{t}{T}\right) \quad (7)$$

$$\alpha(t, T) = (0,005)^{\frac{t}{T}} \quad (8)$$

$$\alpha(t, T) = \alpha_o \times e^{-\frac{t}{T}} \quad (9)$$

Onde o tamanho da influência $h_{c_j}(t)$ – ou função de vizinhança – que o neurônio m_c tem na taxa de aprendizado dos seus vizinhos pode ser definido utilizando a função Gaussiana (função de Gauss) – Equação (10):

$$h_{c_j}(t) = e^{\left(-\frac{||r_j - r_c||^2}{2\sigma_c^2(t)}\right)} \quad (10)$$


Sendo r_j a localização do neurônio j excitado e r_c a localização do neurônio vencedor. Se $||r_j - r_c||$ aumenta, $h_{c_j}(t)$ diminui. O raio de influência da vizinhança $\sigma_c(t)$ BMU também decresce continuamente no tempo e pode ser calculado como mostra a Equação (11):

$$\sigma_c(t) = \sigma_0 \times e^{\left(-\frac{T}{t}\right)} \quad (11)$$

6. Retornar ao passo 2 até que $t = T$.

A Figura 12 mostra um fluxograma contendo os processos básicos do algoritmo dos mapas auto-organizáveis.

Figura 12 - Fluxograma de funcionamento do algoritmo do SOM



Fonte: Adaptado de Rhamatbakhsh, Gagarinova e Babu (2021)

Após a convergência ser alcançada, o arranjo de neurônios refletirá características importantes dos dados de entrada (Gonçalves; Andrade Netto; Costa, 2007).

3.5.3 Métricas de avaliação

Para avaliar a qualidade dos mapas gerados pelo algoritmo do SOM, as métricas mais populares são: o erro de quantização (EQ), método tradicional proposto por Kohonen (1982) que é calculado pela soma das distâncias entre os pesos dos neurônios vencedores e os dados de entrada; e o erro topográfico (ET), sugerido por Kiviluoto (1996), que verifica a preservação da topologia dos dados no espaço de saída do SOM (Costa, 2022).

O erro de quantização quantifica a resolução do mapa gerado e é definido como a distância média entre o vetor de entrada e o vetor BMU de pesos (Kiviluoto, 1996). Um baixo valor para o erro de quantização indica uma boa representação dos dados de entrada pelo mapa e é frequentemente utilizado para averiguar a qualidade do agrupamento sendo calculado pela Equação (12) (Costa *et al.*, 2024).

$$EQ = \frac{1}{n} \sum_{i=1}^n \sqrt{(x_i - w_{i,j})^2} \quad (12)$$

Onde n é a quantidade de dados de entrada, $\mathbf{x}$ é o vetor de entrada e $\mathbf{w}_{i,j}$ o vetor de pesos do neurônio vencedor para o dado de entrada $\mathbf{x}_i$. O erro de quantização é simplesmente a distância média entre o vetor de entrada da rede e o vetor de pesos do neurônio ao qual essa entrada foi designada. Quanto menor esse valor, melhor é o ajuste do mapa ao conjunto de dados (Costa, 2022).

O erro topográfico foi uma métrica de avaliação de continuidade do mapa proposta por Kiviluoto (1996). De acordo com o autor, em alguns casos, a preservação da topologia do mapeamento é mais importante do que a boa resolução. O erro topográfico mede as adjacências do primeiro e segundo neurônios vencedores de um vetor de entrada e se os dois BMUs são adjacentes comparados ao vetor, significa que o mapeamento é contínuo (Kitani, 2013).

Em outras palavras, o erro topográfico quantifica a frequência com que o segundo BMU para um vetor de dados é ou não vizinho do neurônio vencedor. Ou seja, dado um padrão $\mathbf{x} \in \mathbf{X}$, sejam $\mathbf{w}_i$ e $\mathbf{w}_j$ o primeiro e o segundo vetores de pesos mais próximos de $\mathbf{x}$, respectivamente. Se os neurônios correspondentes $\mathbf{z}_i$ e $\mathbf{z}_j$ são adjacentes, o mapeamento mantém, localmente, a topologia (Costa e Andrade Netto, 2007).

O erro topográfico para o mapa é obtido somando o número de erros topográficos locais para todos dos dados de entrada, como na Equação (13) (Kiviluoto, 1996).

$$\xi_t = \frac{1}{n} \sum_{k=1}^n u(x_k) \quad (13)$$

Onde $u(x_k)$ é igual a 1 caso o primeiro e o segundo neurônios vencedores não sejam adjacentes e igual a 0 caso contrário. E n é o número total de dados de entrada. Logo, ξ_t

corresponde a uma proporção de padrões que foram mapeados incorretamente. Dessa forma, o erro topográfico é capaz de medir a preservação da topologia do SOM (Costa *et al.*, 2024).

3.6 ALGORITMOS GENÉTICOS


Os algoritmos genéticos (AGs) são uma técnica de otimização desenvolvida por John Holland em 1975 na Universidade de Michigan. Inspirada em conceitos da teoria da evolução proposta pelo naturalista Charles Darwin, a técnica visa resolver problemas de otimização e busca que requerem eficiência e efetividade (Goldberg, 1989).

Os AGs, em outras palavras, são uma aplicação computacional dos princípios evolutivos propostos por Darwin de forma que os indivíduos mais adaptados ao ambiente possuem maior probabilidade de sobreviver e se reproduzir, passando suas características para as futuras gerações, como ocorre na seleção natural. O algoritmo inicia com uma população aleatória de cromossomos e escolhe pais dos quais serão gerados descendentes usando operações análogas aos processos biológicos – operadores genéticos – geralmente *crossover* (cruzamento ou recombinação) e mutação (Lin; Lee; Hong, 2003).

Os AGs são vistos como técnicas baseadas em processos evolucionários que são usadas com o objetivo de chegar, e garantir, a melhor solução global de um problema de otimização. As “melhores” soluções são selecionadas e as “piores” eliminadas. Então as melhores soluções são submetidas à recombinação com a ação de taxas de *crossover* e mutação. Essa característica os diferencia dos algoritmos aleatórios, já que possuem a habilidade de direcionar a busca para as regiões prospectivas no escopo de busca, ou seja, atenuam o risco de se obter uma solução ótima local e garantem a solução ótima global (Srinivas; Patnaik, 1994).

A Figura 13, ilustra o comportamento de busca para encontrar o ótimo global, ou seja, melhor solução possível para o problema, que passa por ótimos locais, soluções “próximas” ao melhor possível.

Figura 13 - Ilustração do ótimo global e do ótimo local




Fonte: Fernandes (2019)

O operador genético *crossover* causa uma mudança estruturada (ainda que randomizada) do material genético entre soluções, com a probabilidade de as “melhores” soluções poderem gerar soluções “ainda melhores” (Goldberg, 1989; Srinivas; Patnaik, 1994). Ou seja, a estratégia é construir novos indivíduos a partir dos indivíduos de alto-desempenho existentes. Sempre que um indivíduo é selecionado da população atual para se reproduzir, um companheiro também é selecionado. Os descendentes são produzidos pela concatenação de segmentos, definidos aleatoriamente, desses dois indivíduos (Jong, 1980).

Já o operador genético de mutação envolve a modificação do valor de um ou mais genes de um indivíduo existente e é considerado um operador secundário que aumenta a variabilidade genética da população (Jong, 1980; Grefenstette, 1986; Srinivas; Patnaik, 1994). Segundo Jong (1980) a mutação não é um operador primário porque os modelos artificiais se espelham na natureza e a probabilidade de um gene sofrer mutação é menor do que 0,01%.

A Figura 14 retrata os processos de recombinação e mutação do material genético de uma população, refletindo um típico mecanismo genético.

Figura 14 - Processo genético típico



Fonte: Adaptado de Lin, Lee e Hong (2003)


A taxa de *crossover* determina o quanto as soluções estão submetidas à recombinação. Ou seja, controla a frequência com a qual o operador genético é aplicado. Quanto maior essa taxa, mais rápida é a convergência, porém, pode levar a uma perda prematura de diversidade genética. As taxas mais lentas favorecem uma exploração mais ampla do espaço de busca, mas a convergência pode ser mais lenta e deve-se ter o cuidado com estagnação (Grefenstette, 1986; Srinivas; Patnaik, 1994). Os valores típicos para a taxa de *crossover* estão entre 50 e 100% (Lin; Lee; Hong, 2003).

Segundo Lin, Lee e Hong (2003), a taxa de mutação controla a velocidade com a qual o AG irá explorar uma nova área e, tipicamente, é escolhida em um intervalo de 0,01 a 5%. Altas taxas de mutação podem transformar o AG em um puro algoritmo de busca aleatória (Srinivas; Patnaik, 1994). Jong (1980) destaca que a mutação pode ser vista como uma imposição para expandir o escopo de busca e o *crossover*, em conjunto com as probabilidades de seleção, pode ser visto como uma imposição para convergir para soluções de alto-desempenho.

A escolha do valor das taxas de *crossover* e mutação afeta criticamente a performance do AG (Srinivas; Patnaik, 1994; Lin; Lee; Hong, 2003). A literatura científica tem buscado identificar as configurações ótimas para os parâmetros dos AGs, mas essas configurações

dependem de cada problema a ser tratado. O fluxograma da Figura 15, ilustra o funcionamento básico de um AG.

Figura 15 - Funcionamento básico de um algoritmo genético



Fonte: Adaptado de Chagas, Rodrigues e Tavares (2009)

A partir de uma população gerada randomicamente, é feita a avaliação dos indivíduos por uma função de aptidão (*fitness function*) para definir quais deles participarão da geração da prole ou próxima geração. A intenção é selecionar os indivíduos mais aptos a serem representados na base de acasalamento para, posteriormente, passarem pelos processos de recombinação e mutação (Bardanachvili, 2006).

3.6.1 NSGA – II

O *Nondominated Sorting Genetic Algorithm II*, ou Algoritmo Genético de Ordenação Não-Dominada II (NSGA – II), proposto por Deb *et al.* (2002), foi desenvolvido com base nos princípios e estrutura básica do NSGA, algoritmo introduzido por Srinivas e Deb (1994), para solucionar problemas multiobjetivos.

A maioria dos problemas do mundo real são multiobjetivos, o que quer dizer que apresentam, em sua formulação, mais de uma função objetivo, além de um conjunto de restrições que frequentemente são conflitantes entre si. Não é incomum que a melhoria de um ou mais objetivos cause, conseqüentemente, a deterioração de outro (s). Isso faz com que esses problemas apresentem um conjunto de soluções ótimas (Zini, 2009).

Soluções que superam as outras são chamadas de “não-dominadas” e soluções que são superadas por, pelo menos, uma outra solução são chamadas de “dominadas”. Técnicas

que visam o conjunto de soluções não-dominadas são interessantes para que se encontre aquela que melhor atenda às necessidades do problema (Zini, 2009). Srinivas e Deb (1994) destacam que a ideia por trás da não-dominância é a seleção que enfatiza os pontos positivos visando manter as subpopulações de pontos positivos estáveis, um dos princípios do NSGA.

O NSGA – II segue o funcionamento básico dos AG, mas se difere na fase de seleção. A fase de seleção da nova população emprega dois procedimentos: o *Fast Nondominated Sorting* (Ordenação Não-dominada) e um operador de promoção de diversidade da população chamado *Crowding Distance* (CD) ou distância de aglomeração (Vargas, 2018).

3.6.1.1 *Fast Nondominated Sorting*

Antes de ocorrer a seleção, os indivíduos são alocados em *fronts* de acordo com sua não-dominância. Aqueles não-dominados formam o primeiro *front* (primeira fronteira ou fronteira de Pareto), que é um subconjunto da população que agrupa indivíduos de mesmo nível de não-dominância. A primeira fronteira não é dominada por nenhuma outra, a segunda fronteira é dominada pela primeira e domina as demais soluções e assim por diante (Almeida, 2016).

Nessa abordagem, o algoritmo calcula para cada solução p um contador de dominação η_p que representa o número de soluções que dominam a solução p , e um conjunto de soluções S_p que lista todas as soluções que p domina. Para cada solução p com $\eta_p = 0$ (*front 1*) visita-se cada membro q do conjunto de soluções S_p e diminui-se o valor do contador de dominação por 1. Se o novo η_p de q for zero, q é colocado em uma nova lista Q , que formará *front 2*. O processo é repetido com Q , para determinar o *front 3* e continua sendo realizado até que todos os indivíduos tenham seus *fronts* (Deb et al., 2002; Almeida, 2016).

Em outras palavras, a Ordenação Não-dominada visa classificar uma população P em S subconjuntos de forma que $S_1 = \{\text{indivíduos não-dominados de } P \text{ e que não são dominados por nenhum outro de } P\}$ (*front 1*), $S_2 = \{\text{indivíduos não-dominados de } P \setminus S_1 \text{ e que não são dominados por nenhum outro de } P \setminus S_1\}$ (*front 2*), $S_3 = \{\text{indivíduos não-dominados de } P \setminus \{S_1 \cup S_2\} \text{ e que não são dominados por nenhum outro de } P \setminus \{S_1 \cup S_2\}\}$ (*front 3*), ..., $S_d = \{\text{indivíduos não-dominados de } P \setminus \{S_1 \cup S_2 \cup \dots \cup S_{d-1}\} \text{ e que não são dominados por nenhum outro de } P \setminus \{S_1 \cup S_2 \cup \dots \cup S_{d-1}\}\}$.

dominados por nenhum outro de $P \setminus \{S_1 \cup S_2 \cup \dots \cup S_{d-1}\}$ (*front d*), onde $P = S_1 \cup S_2 \cup \dots \cup S_d$ (Vargas, 2018).


Esse processo é o que caracteriza o elitismo em um algoritmo evolutivo. O intuito do método é preservar e utilizar as melhores soluções encontradas na geração atual para as próximas gerações. Dessa forma, além de garantir os melhores indivíduos, estes serão priorizados durante a fase de seleção para posterior criação de novos indivíduos (Zini, 2009; Almeida, 2016).

3.6.1.2 Crowding Distance

Um dos propósitos dos algoritmos multiobjetivos é encontrar o maior número de soluções que pertençam à frente de Pareto, sendo necessário, portanto, que a população se mantenha o mais diversa possível. No NSGA – II, o *Crowding Distance*, ou distância de aglomeração (DA) é utilizado para manter a diversidade entre soluções em uma população e evitar a convergência prematura, garantindo que um bom número de soluções seja selecionado na frente de Pareto. O que é um dos propósitos dos algoritmos multiobjetivos (Deb *et al.*, 2002; Mahala *et al.*, 2024; Zini, 2009).

A DA permite quantificar o espaço ao redor de uma solução i . A distância de aglomeração é a distância média de dois pontos ao lado de uma solução para cada objetivo. Ela é usada para estimar o perímetro do cuboide formado usando os vizinhos mais próximos como vértices. Essa métrica mede a diversidade das soluções em um espaço de busca e mostra o quão perto uma solução i está das demais soluções mais próximas a ela, ou seja, é uma maneira de identificar similaridades entre soluções. A Figura 16 permite uma visualização ilustrativa do funcionamento da DA (Zini, 2009; Almeida, 2016).

Figura 16 - Distância de Aglomeração do NSGA – II



Fonte: Deb *et al.* (2002)

Na Figura 16, os pontos em preto são as soluções que fazem parte da melhor frente e os círculos vazios são as soluções que fazem parte de uma frente inferior (Zini, 2009). Almeida (2016) expressa o cálculo da distância de aglomeração pela Equação (14) e ressalta que é necessário ordenar a população em ordem ascendente para cada uma das funções objetivo. As soluções das extremidades (de menor e maior valor) são as soluções de fronteira e têm suas distâncias definidas como infinitas.

$$I[i]_{distância} = I[i]_{distância} + \frac{I[i + 1].m - I[i - 1].m}{f_m^{max} - f_m^{min}} \quad (14)$$

Onde:

- $I[i]_{distância}$ é o valor da DA para a solução na posição i .
- $I[i + 1]$ e $I[i - 1]$ são os valores de DA dos vizinhos de $I[i]$ para o objetivo m .
- f_m^{max} e f_m^{min} são os valores de fronteira para o objetivo m .

A DA é calculada para todos os m objetivos e a DA total de cada solução é a soma de cada um dos valores de distância para cada função objetivo. Uma distância de aglomeração pequena indica que a solução está em uma densa área de soluções similares e o contrário, evidencia uma solução que introduz maior nível de diversidade (Almeida, 2016; Zini, 2009).

A partir do cálculo da distância de aglomeração, o operador *crowded-comparison* ($<_n$), ou em português: comparação de aglomeração, guia o processo de seleção em vários estágios do algoritmo em direção a uma frente de Pareto ótima uniformemente espalhada. Cada indivíduo i da população possui dois atributos: 1) o *rank* de não dominação (i_{rank}) e 2) a distância de aglomeração ($i_{distância}$). Portanto, as soluções são comparadas a partir desses, da seguinte forma (Deb *et al.*, 2002):

$$i <_n j \text{ se } (i_{rank} < j_{rank})$$

$$OU ((i_{rank} = j_{rank}) E (i_{distância} > j_{distância}))$$

Em outras palavras, de acordo com Deb *et al.* (2002), entre duas soluções com classificações de não dominação diferentes, prefere-se a solução com a classificação mais baixa (melhor). Caso contrário, se ambas as soluções pertencerem à mesma frente de Pareto, então é selecionada a solução que está localizada em uma região mais espaçada. Almeida (2016) ressalta que dessa forma o elitismo é respeitado e uma solução de *rank*

inferior não é escolhida enquanto melhores *fronts* ainda não estiverem esgotados e assim soluções diferentes são priorizadas.


3.6.1.3 Laço principal

Inicialmente, uma população de pais P_t é criada de forma randomizada. A população é organizada com base em sua não-dominância. Em seguida, os operadores genéticos de recombinação e mutação são utilizados para criar a população descendentes Q_t de tamanho N. O laço principal do algoritmo executa as etapas do NSGA – II em cada iteração, guiando o processo de otimização e segue a seguinte sequência (Deb *et al.*, 2002; Almeida, 2016):

1. A população combinada $R_t = P_t \cup Q_t$ de tamanho $2N$ é formada, R_t é a população resultante;
2. A população R_t é ordenada de acordo com a não-dominância das soluções;
3. As soluções do primeiro *front* F_1 são as melhores soluções da população combinada e devem ser enfatizadas mais do que quaisquer outras soluções da combinação. Se a quantidade de soluções em F_1 for menor que N, todas elas formarão uma nova população P_{t+1} .
4. As soluções remanescentes de P_{t+1} são selecionadas dos *fronts* subsequentes em ordem de não-dominância do *rank* até completar N soluções. Logo, soluções do *front* F_2 são selecionadas em sequência, seguidas das do *front* F_3 e assim por diante. O processo segue até que não existam mais *sets* a serem contemplados.
5. Caso existam mais soluções nos *fronts* do que vagas em P_{t+1} o operador *crowding-comparison* ($<_n$) define os indivíduos do *front* que completarão as vagas remanescentes da população.
6. A nova população P_{t+1} de tamanho N é então estabelecida.
7. Agora a nova população P_{t+1} é usada para seleção, *crossover* e mutação para criar a nova população Q_{t+1} de tamanho N.
8. Esse laço se repete até que o número de gerações predeterminado seja atingido.

Os procedimentos do laço principal do NSGA – II são ilustrados pela Figura 17.

Figura 17 – Procedimentos do NSGA – II

Fonte: Adaptado de Deb *et al.* (2002)

Em sequência, na Tabela 1, pode ser verificado o algoritmo base do NSGA – II.

Tabela 1 – Pseudocódigo do algoritmo do NSGA – II

Algoritmo NSGA – II	
Entrada: Número de gerações	
Saída: P_{final}	
1 início	
2 P_0 = cria a população inicial ()	
3 Q_0 = expande a população (P_0)	
4 $t = 1$	
5 $P_t = P_0$	
6 $Q_t = Q_0$	
7 para $t \leq$ Número de gerações faça	
8 $R_t = P_t \cup Q_t$	*combinar população
9 $F = \text{fast-non-dominated-sort}(R_t)$	*fronts não-dominadas de R_t
10 $P_{t+1} = \emptyset$ e $i = 1$	
11 Para $ P_{t+1} + f_i \leq N$ faça	*até que a população esteja completa
12 $\text{crowding-distance-assignment}(f_i)$	*calcular o CD em f_i
13 $P_{t+1} = P_{t+1} \cup f_i$	*incluir a i-ésima front não-dominada na pop.
14 $i = i + 1$	*checar o próximo front para inclusão
15 fim	
16 Ordenar ($f_i \prec_n$)	*classificar em ordem decrescente usando $\prec_n$
17 $P_{t+1} = P_{t+1} \cup f_i[1 : (N - P_{t+1})]$	*escolher os 1 ^{os} elementos de f_i
18 Q_{t+1} = expande a população (P_{t+1})	*usar seleção, crossover e mutação
19 $P_t = P_{t+1}$	
20 $Q_t = Q_{t+1}$	
21 $t = t + 1$	*incrementar o contador de geração
22 fim	
23 $P_{final} = P_{t+1}$	
24 fim	
25 retorna P_{final}	

Fonte: Adaptado de Almeida (2016) e Deb *et al.* (2002)

Deb *et al.* (2002) ressaltam que a diversidade entre as soluções não-dominadas é assegurada pelo procedimento do *Crowding Distance*, aplicado tanto na seleção quanto na fase de redução da população. As soluções competem com base na sua distância de aglomeração eliminando a necessidade de parâmetros adicionais.

3.7 SETORIZAÇÃO DE REDES: DISTRITOS DE MEDIÇÃO E CONTROLE


O conceito de Distrito de Medição e Controle (DMC) foi proposto em 1980, no Reino Unido, pela *UK Water Authorities Association* como uma área de um sistema de distribuição definida pelo fechamento de válvulas e pela medição do volume de água que entrava e saía dessa área. O objetivo principal dos DMCs é a detecção rápida e a gestão de vazamentos de água (Ridley, 1980; Bui; Marlim; Kang, 2020; Kowalska; Suchorab; Kowalski, 2022).

Farley (2001) elucida DMC como uma área definida pela instalação estratégica de medidores de vazão ao longo de uma rede de distribuição de água estabelecendo uma fronteira permanente. O design dos DMCs visa a divisão da rede em setores menores (setorização) com o objetivo de detectar vazamentos, normalmente pelo cálculo de balanço hídrico, e gerenciar pressões.

Na Figura 18 é possível visualizar um esquema ilustrativo de como são formados os DMCs. A rede possui um reservatório no qual é conectada a tubulação tronco que se ramificará para os nós da rede. Os nós, representados por vértices, identificam os pontos de demanda ou conexões das tubulações que, por sua vez, são representadas pelas arestas. Na entrada de cada DMC é posicionado um medidor de fluxo e entre DMCs são posicionadas as válvulas para fechamento de fronteira (em certos casos, também podem ser posicionados medidores de fluxo).

A norma brasileira NBR 12218 de maio de 2017, estabelece os requisitos de elaboração de projetos de rede de distribuição de água para abastecimento público e define Distrito de Medição e Controle como: “área delimitada e isolável, que possibilita a gestão do sistema por meio do monitoramento, medição e controle de vazões e/ou pressões, permitindo definir indicadores operacionais, avaliar e controlar perdas”. Para a incorporação dos DMCs na rede de distribuição deve-se considerar condições topológicas e operacionais, além de critérios da operadora de água do município.

Figura 18 - Esquema ilustrativo de Distritos de Medição e Controle



Fonte: Adaptado de Bui, Marlim e Kang, 2020

A setorização das redes de distribuição permite a definição de áreas parcialmente isoladas o que leva à melhora no monitoramento de vazamentos, na eficiência hidráulica e energética e na segurança hídrica (Brentan *et al.*, 2018a). Esta estratégia tem sido utilizada amplamente como forma de gerir as perdas nos sistemas de abastecimento (Novarini *et al.*, 2019). Existem vários estudos envolvendo os DMCs que vão desde a análise do funcionamento de um DMC já existente na rede, a até propostas de implantação destas delimitações de área.

Definir as fronteiras é a base do *design* dos DMCs. A setorização das redes, na prática, ainda é feita de maneira empírica e manual e, por ser uma tarefa desafiadora devido à complexidade das redes de distribuição, esforços estão sendo feitos na ciência em busca de métodos para criação automatizada e otimizada dos DMCs (Diao; Zhou; Rauch, 2012; Bui; Marlim; Kang, 2020). Essa complexidade está pautada nas seguintes razões: frequentemente se tratam de redes muito extensas com dezenas de milhares de nós e tubulações; são estruturas construídas no subsolo, logo não possuem fácil acesso de monitoramento e manutenção; o traçado é em *loop*; a modelagem envolve equações não-lineares requerendo métodos de resolução sofisticados e frequentemente apresentam perdas de água severas (Di Nardo *et al.*, 2017).

Para estabelecer uma configuração adequada de DMCs, vários aspectos devem ser considerados simultaneamente: topologia, elevação, tamanho, configuração de *loop*, custos e resiliência, o que implica que abordagens manuais ou empíricas se tornam inviáveis (Brentan *et al.*, 2018a).

O particionamento das redes de distribuição atualmente é um processo heurístico, mesmo sendo reconhecida como a abordagem mais eficaz para lidar com as perdas de água. Em vista deste fato, pesquisadores têm explorado e estudado a fim de desenvolver métodos científicos e mais efetivos para realizar o particionamento das redes. Métodos estes de envolvem basicamente duas fases: agrupamento (*clustering*) e otimização (Di Nardo *et al.*, 2017; Bui; Marlim; Kang, 2020; Brentan *et al.*, 2022; Fu *et al.*, 2022; Wei *et al.*, 2023).


A fase de agrupamento é uma pré-formação dos DMCs, baseada na conectividade e topologia da rede. Esta fase pode ser implementada por diversos algoritmos baseados em teoria dos grafos, detecção de comunidade, modularidade, teorias evolucionárias, modelos de inteligência artificial e algoritmos espectrais com a finalidade de minimizar o número de conexões entre DMCs (Bui; Marlim; Kang, 2020). Em alguns casos, há também a combinação de múltiplas abordagens. Assim dizendo, busca-se identificar e associar características semelhantes entre os nós da rede e agrupá-los formando o *design* dos DMCs (ou seja, formando os setores da rede).

Na segunda fase, conhecida como otimização, o foco está na alocação de dispositivos de medição de fluxo (válvulas de controle) e válvulas de fechamento de fronteira (válvulas de isolamento) isolando e definindo os limites dos setores da rede. Mantendo a alta performance da rede e minimizando os custos de implantação e manutenção (Bui; Marlim; Kang, 2020).

O problema de otimização é formulado, geralmente como um problema multiobjetivo, considerando aspectos como uniformidade de pressão, redução de perdas e eficiência operacional. Algoritmos de otimização, como algoritmos genéticos, são então aplicados para explorar diferentes configurações da rede e buscar soluções eficientes. Nessa fase, o objetivo primordial é alcançar o menor custo possível na instalação de dispositivos, ou seja, quanto menos dispositivos de medição e de fechamento de fronteira forem necessários, melhor.

A Figura 19 ilustra o procedimento de setorização em duas fases de uma rede real da cidade de Pareto, ao sul da Itália. Nesse caso, foram gerados 4 DMCs que podem ser identificados e diferenciados pelas cores descritas na legenda. Na primeira parte da imagem observa-se a rede original, seguida da fase de agrupamento, na qual são definidos os nós de cada DMC e por fim, a fase de setorização, onde é possível verificar a locação dos dispositivos de medição de fluxo e das válvulas de fechamento de fronteira.

Figura 19 - Etapas do particionamento de uma rede de distribuição de água; (a) rede original; (b) fase de agrupamento; (c) fase de setorização



Fonte: Adaptado de Bui, Marlim e Kang (2020)

A criação de DMCs implica na modificação do comportamento hidráulico das redes de distribuição de água e é uma tarefa difícil (Brentan *et al.*, 2022). No âmbito do agrupamento, deve-se ter o cuidado com perdas de pressão levando a nós com pressões abaixo do nível mínimo recomendado em norma. E, de fato, se por um lado instalar dispositivos de controle melhora a gestão da rede, por outro lado, existe o impacto nos custos de projeto e na operação.

Bui, Marlim e Kang (2020) citam algumas possíveis desvantagens dos DMCs: (a) Resiliência reduzida a falhas; (b) Flexibilidade operacional reduzida; (c) Potencial impacto negativo na qualidade da água; (d) Questões de segurança em áreas periféricas e casos de emergência; (e) Alto custo de investimento inicial; (f) Redundância hidráulica

reduzida. Entretanto, esses pontos conseguem ser contornados e os pesquisadores da área concordam que os benefícios da criação de DMCs são maiores do que os infortúnios.

A complexidade da setorização aumentou ao longo dos anos com a introdução de novos parâmetros a serem considerados além de vários objetivos a serem alcançados. Necessitando, portanto, de ferramentas mais robustas para a resolução dos problemas e a criação de novos métodos de setorização. O que resulta em alto esforço computacional e pode impossibilitar as concessionárias de água a adotarem, devido a orçamentos, esses métodos tão complexos. Com isso, o que se espera é chegar à um método de setorização com uma série de critérios hidráulicos econômicos e com menor esforço computacional possível (Sharma *et al.*, 2022).

3.7.1 Técnicas de setorização na literatura

A utilização de algoritmos, redes neurais e técnicas de inteligência artificial na setorização é algo significativo no contexto das redes de distribuição de água, tanto para melhoria da eficiência operacional, quanto para a gestão do sistema. Na setorização, essas ferramentas podem ser aplicadas tanto na fase de agrupamento quanto na fase de otimização.

3.7.1.1 Setorização de redes utilizando algoritmos

Brentan *et al.* (2018b), utilizaram algoritmos de detecção de comunidade para definir cenários setorização propostos pela competição científica *Battle of Water Networks District Metered Areas* que busca apresentar desafios aos pesquisadores para atender um conjunto de variáveis de decisão e restrições. Os autores aplicaram três métodos de otimização: *Particle Swarm Optimization*, (PSO), algoritmos genéticos e *Soccer League Competition* e sugeriram uma abordagem para setorização da rede de abastecimento de água da E-Town. Embora o método proposto não tenha atendido a todas as restrições do desafio, especialmente ao critério de pressão máxima, conseguiu obter indicadores satisfatórios de pressão e uniformidade de demanda com o uso dos três algoritmos.

Sharma *et al.* (2022) propuseram um método para a setorização de redes de água por meio de três fases: a primeira delas utiliza o *Fast Newman Algorithm* para identificar grupos de nós iniciais. Em sequência o *Nondominated Sorting Genetic Algorithm III* (NSGA – III) foi usado para obter soluções de otimização de fronteira considerando diversos objetivos simultaneamente e, por fim, o método de tomada de decisão de

múltiplos atributos foi aplicado para definir qual das soluções geraria a melhor configuração de DMCs. O artigo discute a aplicação do método em um estudo de caso da rede de distribuição EXNET. Os resultados mostraram que a abordagem proposta foi capaz de fornecer soluções de DMC eficientes e economicamente viáveis, considerando vários objetivos, como minimização de custos, maximização da eficiência hidráulica e minimização de perdas de vazamento

Shekofteh, Yousefi-Khoshqalb e Piratla (2023) propuseram um método de setorização envolvendo algoritmos baseados na teoria de grafos, na fase de agrupamento, e no algoritmo genético NSGA – II, na fase de otimização. Os DMCs foram otimizados com base no número de dispositivos de medição de fluxo e de válvulas de fechamento de fronteira, enquanto reduz o esforço computacional. O método proposto pelos autores visa a minimização de custos com a instalação de dispositivos e o monitoramento e gerenciamento das perdas de água. A eficácia da abordagem foi demonstrada através da sua implementação em seis redes de distribuição de água, que incluem centenas de tubulações e nós. Os resultados mostraram que a abordagem oferece um meio econômico para as empresas de abastecimento de água estabelecerem DMCs e gerirem de maneira eficaz as redes de distribuição de água, mas requer modificações no número de medidores de vazão e válvulas para acomodar mudanças nos requisitos da rede.

Sitzenfrei *et al.* (2023) apresentaram um método de setorização considerando a topografia da rede combinando o algoritmo de Análise de Redes Complexas (ou CNA) e simulações hidráulicas utilizando o EPANET. A abordagem proposta foi demonstrada em dois estudos de caso: na rede de irrigação de Balerna e na virtRome, e o artigo traz um pseudocódigo indicando os processos da metodologia. De acordo com os autores, o CNA demonstrou significativamente menor esforço computacional em comparação com abordagens evolutivas da literatura, porém, estes não citam quais algoritmos evolutivos.

Wei *et al.* (2023) combinaram o algoritmo *Density Peak Clustering* (DCP) com a técnica de *Spectral Clustering* para determinar os grupos de nós (setores) e também a localização dos dispositivos de medição de fluxo e das válvulas de fechamento na rede de *benchmark* Balerna. Os resultados mostraram que o método proposto agrupou os nós similares rapidamente e de forma eficaz além de otimizar a localização dos hidrômetros e válvulas.

Anchieta, Meirelles e Brentan (2024) desenvolveram algoritmos híbridos a partir de algoritmos de particionamento já existentes na literatura: *Fast-Greedy* e *Louvain* para a

fase de agrupamento e o PSO para a fase de otimização. As combinações dos algoritmos foram testadas na rede de *benchmark* Modena e os resultados obtidos foram comparados pela análise de critérios hidráulicos, custo, conectividade e quantidade de válvulas alocadas nas tubulações. No geral, os algoritmos formados pelo *Louvain* geraram melhores resultados.

Neste trabalho, utilizou-se o algoritmo genético NSGA – II na fase de otimização da setorização. Essa ferramenta tem se mostrado satisfatória na resolução de problemas de otimização multiobjetivo, portanto, pode ser ideal ao cenário de inúmeras variáveis a serem consideradas em redes de distribuição de água. Deb *et al.* (2002) são os criadores do NSGA – II e o definem como rápido e elitista, o que significa que o algoritmo dá a prioridade à preservação das melhores soluções encontradas ao longo das gerações mantendo a diversidade das soluções. Além disso, é um algoritmo de solução não-dominada, o que significa que não há outra solução que seja melhor em todos os objetivos simultaneamente.

3.7.1.2 Setorização de redes utilizando Inteligência Artificial

Técnicas de Inteligência Artificial (IA) têm sido amplamente aplicadas na setorização de redes de distribuição de água, principalmente na fase de agrupamento dos nós para a definição dos DMCs. O uso de IA na criação de DMCs permite uma abordagem mais inteligente, adaptável e eficiente, lidando com a complexidade inerente a esses sistemas e promovendo práticas operacionais mais sustentáveis.

Brentan *et al.* (2018a) apresentam um método de setorização cuja fase de agrupamento é feita por meio do SOM associado ao algoritmo *k-means*. Nesta abordagem o SOM é usado como uma técnica de pré-processamento produzindo um mapa com a arquitetura ideal alcançada para que então seja aplicado o algoritmo *k-means* gerando um número menor de grupos que seja mais adequado à processos de tomada de decisão. Os resultados da criação dos DMCs foram satisfatórios, criando grupos com elevações de nós similares o que ajuda no gerenciamento de pressões na rede.

Novarini *et al.* (2019) apresentaram uma comparação de um modelo híbrido que associa o SOM ao algoritmo *k-means* com o método que utiliza apenas o algoritmo *k-means* como ferramenta de agrupamento e criação de DMCs. Os autores aplicaram o método proposto na rede D-Town. O algoritmo *k-means* apresentou boa qualidade nos índices de avaliação

e capacidade de simplificação do abastecimento de água. O modelo híbrido, por sua vez, manteve um padrão de agrupamento em faixas diagonais e alongadas, perdendo a essência de setores compactos.

Fu *et al.* (2022) foram os primeiros a desenvolverem um método de setorização utilizando uma rede neural de grafos, aplicada normalmente para classificação de dados gráficos. Os autores testaram o método em três redes: Hanoi, C-town e E-town. As simulações hidráulicas foram realizadas no *software* EPANET e o apontaram como resiliente a emergências e gerador de soluções interpretáveis e rápidas.


Rong *et al.* (2023) propuseram um método (GANDMA) baseado em uma rede neural de atenção de grafos para realizar a etapa de agrupamento dos nós baseando-se na similaridade da área e no balanço da demanda de água. Os autores disponibilizaram um pseudocódigo com a arquitetura dos processos de setorização do GANDMA e testaram em três redes: Hanoi, C-town e E-town. O método agregou os nós de acordo com suas características de forma automática, resultou em um número de conexões de aproximadamente 2500 nós em cada DMC e se mostrou prático, confiável e interpretativo.

Nesse estudo, foi utilizada a rede neural mapas auto-organizáveis, em seu estado puro, sem associação a outro algoritmo ou ferramenta computacional, na fase de agrupamento dos nós da rede de distribuição.

4. METODOLOGIA

Essa seção delinea as etapas e técnicas empregadas para coletar, analisar e interpretar os resultados gerados pelas simulações. A metodologia dessa pesquisa seguiu as etapas ilustradas pela linha de trabalho apresentada na Figura 20.

Figura 20 - Etapas da metodologia utilizada




Fonte: A autora

A linguagem de programação utilizada para a condução do estudo foi o Python, uma ferramenta que se destaca pela sua sintaxe clara e legibilidade. Um dos inúmeros motivos dessa escolha é a ampla comunidade de desenvolvedores que disponibilizam bibliotecas especializadas, além de fóruns de discussão que proporcionam troca de informações, suporte, ajuda e resolução de problemas em conjunto. Portanto, a preferência do Python como linguagem de programação para este estudo se baseia em sua acessibilidade, versatilidade, robustez e relevância no cenário atual de pesquisa e desenvolvimento científico.

Os códigos foram elaborados, em Python 3.11.5 – no Ambiente de Desenvolvimento Integrado (IDE) *Spyder*, em conformidade com as etapas da setorização, sendo a primeira delas a fase de agrupamento, seguida pela fase de otimização.

A escolha do IDE *Spyder* foi fundamentada principalmente por sua interface intuitiva – ilustrada na Figura 21 – e que permite a visualização de gráficos e mapas de forma interativa, sendo de grande valia na implementação da SOM. Além disso, o *Spyder* possui um explorador de variáveis que exibe os conteúdos armazenados nas variáveis, *arrays* e *dataframes*, o que é especialmente útil durante a depuração do código porque permite a inspeção de valores em tempo real e poupa a escrita de comandos de impressão de variáveis na tela.

Figura 21 - Interface do IDE *Spyder*




Fonte: Spyder, 2023 (spyder-ide.org)

Por fim, o *Spyder* é um IDE de código aberto, muito utilizado por pesquisadores, desenvolvedores e demais profissionais que trabalham com Python, portanto, também possui uma comunidade de usuários que fornecem suporte, tutoriais e recursos que garantem ajuda sempre que necessário.

Além das ferramentas descritas anteriormente, neste trabalho foi utilizado o *software* de modelagem e simulação hidráulica EPANET, na versão americana 2.2 para a verificação das pressões e do comportamento hidráulico da rede. O *software* é disponibilizado gratuitamente no sítio eletrônico² da *Environmental Protection Agency*. A interface do EPANET, com o modelo da rede Balerma aberto, pode ser visualizada na Figura 22.

² Disponível em: <<https://www.epa.gov/water-research/epanet>>. Acesso em: 11 jun. 2024.

Figura 22 - Interface do EPANET - rede Balerna



Fonte: A autora

A escolha desta ferramenta se deu por diversos motivos, sendo estes:

- a. É um dos *softwares* mais utilizados por pesquisadores da área, o que confere uma validação, credibilidade adicional e maior aceitação na comunidade científica;
- b. Possui distribuição gratuita, tornando o acessível a pesquisadores e instituições com orçamentos limitados;
- c. Possui código aberto, ou seja, é possível verificar como os cálculos estão sendo feitos, permitindo modificações necessárias ao usuário e a adequação de suas necessidades através de linguagens de programação;
- d. Possibilita a integração a outros *softwares* e ferramentas de análises, para estudos mais abrangentes e sofisticados.

4.1 ETAPA 1: DEFINIÇÃO DAS CARACTERÍSTICAS DOS NÓS A SEREM CONSIDERADAS NO AGRUPAMENTO


As características dos nós a serem consideradas na setorização são dados significativos a serem utilizados efetivamente na Fase 1 (agrupamento) da Etapa 5 deste trabalho. A divisão da rede de distribuição implica na criação de DMCs com características similares,

ou seja, é interessante que os nós dos setores possuam aspectos semelhantes para manter a estabilidade interna de cada setor.

A estabilidade interna envolve o alto grau de correlação de características, como longitude, latitude e altitude dos nós. As características dos pontos de consumo são os dados de entrada para que a rede neural realize o agrupamento dos nós e, conseqüentemente, a definição dos DMCs.

Na Figura 23 é possível visualizar uma parte dos dados de entrada do modelo de *benchmark* (modelo de referência) utilizado neste trabalho: a rede Balerma.

Figura 23 - Dados de entrada da rede Balerma



	Índice	NodeID	Elevation	Demand	X_Coord	Y_Coord
1	0	179001	60.0	5.55	60.74	-12.58
2	1	179	60.0	5.55	53.44	12.58
3	2	177	58.9	5.55	15.3	27.6
4	3	174	60.0	5.55	62.44	40.96
5	4	173	59.3	5.55	45.59	38.83
6	5	171001	60.0	5.55	45.86	62.36
7	6	171	60.0	5.55	56.68	67.23
8	7	172	60.0	5.55	66.96	67.23
9	8	170	60.0	5.55	44.51	81.57
10						

Fonte: A autora

Esses dados são dispostos em formato .csv contendo as mesmas características utilizadas nos trabalhos de Brentan *et al.* (2018a) e Rong *et al.* (2023): elevação, demanda e coordenadas x e y.

4.2 ETAPA 2: DEFINIÇÃO DA REDE NEURAL PARA AGRUPAMENTO

A rede neural empregada na etapa de agrupamento dos nós da rede de distribuição utilizada neste estudo foi a *Self-Organizing Maps* (SOM) – Mapas auto-organizáveis. A escolha do SOM baseou-se em alguns fatores, mas principalmente na capacidade de aprendizado e agrupamento não-supervisionado, o que a permite agrupar os nós sem a necessidade de rótulos prévios. Além disso, pode-se destacar:

- a. Preservação da topologia da rede – o SOM é capaz de manter as relações espaciais entre os nós, ou seja, a disposição espacial dos neurônios no mapa reflete a

proximidade geográfica dos pontos na rede de distribuição. O que é fundamental para garantir que os setores resultantes correspondam à estrutura física da rede.

- b. Robustez em relação a padrões não lineares – o SOM é capaz de entender padrões complexos e não lineares, o que é crucial em redes de distribuição de água, onde as características dos nós podem ser altamente variáveis e não lineares.
- c. Facilidade de implementação e ajuste de parâmetros – existem bibliotecas e ferramentas disponíveis para implementação do SOM, com parâmetros que podem ser ajustados pelo programador de acordo com as necessidades do problema a ser resolvido.

4.3 ETAPA 3: DEFINIÇÃO DO ALGORITMO GENÉTICO PARA OTIMIZAÇÃO

Na segunda fase da setorização, a fase de otimização, empregou-se o algoritmo genético NSGA – II. OS AGs são poderosas ferramentas de exploração de espaços de busca amplos para encontrar ótimos globais, sendo extremamente úteis na resolução de problemas complexos. O NSGA – II é um AG que se destaca e tem sido aplicado em inúmeras situações por diversos pesquisadores.

A aspiração pelo uso do NSGA – II neste trabalho é pautada nos seguintes motivos:

- a. Foi projetado para resolver problemas multiobjetivo e é reconhecido por sua eficácia em encontrar as soluções que representam a frente de Pareto.
- b. Possui forte estrutura de manutenção de diversidade, por meio do mecanismo de distância de aglomeração, indo de encontro a exploração de uma gama de configurações possíveis para identificar soluções eficazes.
- c. É um dos algoritmos mais estudados e utilizados pela literatura científica, havendo amplo conteúdo de suporte, implementações de código aberto e uma comunidade ativa de profissionais que podem fornecer assistência e exemplos de aplicações.
- d. É um algoritmo elitista, ou seja, prioriza a preservação das melhores soluções encontradas ao longo das gerações, o que evita a perda de boas soluções.

4.4 ETAPA 4: DEFINIÇÃO DA REDE DE DISTRIBUIÇÃO DE ÁGUA A SER ESTUDADA

Para avaliar o método de setorização proposto neste estudo, foi escolhida uma rede de distribuição previamente analisada na literatura científica, que serve como modelo de referência. A utilização de um modelo *benchmark*, amplamente estudado por outros pesquisadores, oferece a vantagem de fornecer um indicador de desempenho comparativo para diversos aspectos, como calibração de redes, design, operação, expansão, estudos de resiliência, setorização e otimização.

Aplicou-se o método no modelo Balerma que possui 443 nós de demanda, 4 reservatórios e 317 tubulações. Essa rede de distribuição foi proposta por Reza e Martínez (2006) e é uma adaptação de uma rede existente no distrito de irrigação Sol-Poniente, localizado em Balerma, na província de Almeria – Espanha. O layout da rede é mostrado, com mais detalhes na Figura 24.

Figura 24 - Layout do modelo Balerma



Fonte: Reza e Martínez (2006)

O modelo Balerma está disponibilizado no sítio eletrônico³ do repositório institucional da Universidade de Kentucky, pelo *Kentucky Water Research Institute* (KWRI), que gerencia inúmeros projetos de pesquisa, fornece suporte técnico e educa e treina especialistas em recursos hídricos. O KWRI possui um banco de dados sobre redes de distribuição de água com um resumo narrativo da história e características do sistema, além do arquivo compatível com a extensão do EPANET.

Alguns trabalhos que utilizam a rede Balerma são: De Paola, Galdiero e Giugni (2017), Shekofteh, Jalili Ghazizadeh e Yazdi (2020), Wei *et al.* (2023), Shekofteh, Yousefi-Khoshqalb e Piratla (2023) e Sintzenfrei *et al.* (2023).

4.5 ETAPA 5: IMPLEMENTAÇÃO DAS FERRAMENTAS PARA SETORIZAÇÃO

A setorização da rede Balerma foi feita em duas fases: agrupamento e otimização. A primeira teve como objetivo delinear as fronteiras entre os setores, definindo os limites físicos para cada um e foi feita utilizando mapas auto-organizáveis implementados com a biblioteca *MiniSom*. Já na segunda, que visa principalmente o controle de pressão e fluxo de água na rede por meio da locação de dispositivos hidráulicos (medidores de vazão e válvulas de controle) para isolar parcialmente os setores, utilizou-se o algoritmo genético NSGA – II.

4.5.1 Implementação dos Mapas Auto-Organizáveis

A implementação dos Mapas Auto-Organizáveis foi feita a partir da biblioteca *MiniSom* desenvolvida em Python por Vettigli (2018). Essa biblioteca é utilizada por pesquisadores de diversas áreas, oferece uma implementação eficiente e simples do algoritmo do SOM e está disponível gratuitamente.

A *MiniSom* inicia com os seus parâmetros em valores padrão, como mostra a Tabela 2, que podem ser alterados a depender da necessidade do usuário. A biblioteca tem sido utilizada em múltiplas áreas do conhecimento por diversos autores, como por exemplo: Kiran e Vasumathi (2021); Saha, Baruah e Nayak (2021); Muhammad *et al.* (2022); Nanda e Prabowo (2022); Koivula, Shamsuzzoha e Shamsuzzaman (2024); Shield e Houston (2024), Lara *et al.* (2024b, 2024c, 2024d).

³ Disponível em: <https://uknowledge.uky.edu/wdst_models>. Acesso em: 25 mar. 2024.

Tabela 2 - Configuração padrão da biblioteca MiniSom

Parâmetro	Default
Tamanho da grade de neurônios – x, y	Não se aplica
Quantidade de atributos – <i>input_len</i>	Não se aplica
Taxa de aprendizado – <i>learning_rate</i>	0,5
Raio de vizinhança – <i>sigma</i>	1
Distância de ativação – <i>activation_distance</i>	Euclidiana
Função de vizinhança – <i>neighborhood_function</i>	Gaussiana
Função de decaimento da taxa de aprendizado	Equação (9)

Fonte: A autora

Tais parâmetros e suas definições serão discutidos a seguir.

4.5.1.1 Grade de neurônios

O tamanho da grade de neurônios deve ser definido pelo usuário. A quantidade de neurônios da rede é talvez a demanda mais questionada em um SOM por não existir um método que delimite um valor assertivo de neurônios adequado para cada situação. Atualmente, o que existe na literatura é uma sugestão, proposta por Vesanto e Alhoniemi (2000), pela qual essa quantidade de neurônios pode ser definida heurísticamente pela Equação (15).

$$\text{Tamanho do mapa} = 5\sqrt{N} \quad (15)$$

O tamanho do mapa, proposto por Vesanto e Alhoniemi (2000), é dado pela multiplicação da raiz quadrada do número de amostras por cinco, o que resulta na sugestão do número de neurônios a ser informado ao algoritmo.

Kohonen (2013) ressalta que não é possível estimar o tamanho exato da grade de neurônios antecipadamente e julga necessário utilizar o método de tentativa e erro depois de visualizar e analisar a qualidade do mapa resultado do primeiro palpite. Tipicamente, o SOM possui uma grade com dezenas até centenas de neurônios e, como sua maior virtude é a visualização, o que se deseja é um mapa no qual as estruturas dos grupos estejam visíveis.

Neste trabalho, para a definição do número de neurônios, empregou-se a metodologia proposta por Vesanto e Alhoniemi (2000) utilizando a Equação (15) como um guia inicial.

Como a rede Balerna possui 443 nós, resolvendo a Equação (15), encontra-se um tamanho de mapa com aproximadamente 105 neurônios. Portanto, optou-se por definir uma matriz 10 x 11, ou seja, com 110 neurônios para realizar os testes com o tamanho de mapa baseado em Vesanto e Alhoniemi (2000).

Ainda, foram testadas configurações com uma matriz de neurônios 20 x 20, totalizando 400 neurônios, a título de comparação de resultados. A apreciação visual dos mapas gerados foi feita baseando-se na clareza, ou não, dos grupos no mapa. E, como em Melo *et al.* (2019), foi escolhido o mapa mais informativo e com maior capacidade de discriminação, além de melhores resultados nas métricas de avaliação da rede neural.

4.5.1.2 Quantidade de atributos

O segundo parâmetro que deve ser informado à biblioteca é o *input_len* que é a quantidade de atributos que caracterizam os dados. Neste estudo, as características dos nós consideradas no agrupamento foram: coordenada x, coordenada y, elevação e demanda. Portanto, o parâmetro *input_len* recebeu o valor 4.

4.5.1.3 Taxa de aprendizado

A taxa de aprendizado (*learning_rate*) controla a magnitude das atualizações dos pesos, ou velocidade de convergência, durante o treinamento e pode variar de 0 a 1. Há controvérsias em relação a definição do valor desse parâmetro e, normalmente, ele é testado em uma faixa determinada pelo estudo ou pesquisa que está implementando o SOM. Costa (1999) recomenda a inicialização de uma taxa de aprendizado próxima a 1 para possibilitar o seu decaimento com o tempo.

Machado *et al.* (2007) sustentam que quanto menor for o valor desse parâmetro, mais suave será a trajetória dos pesos sinápticos no espaço de pesos já que estes sofrerão menor variação de uma iteração para outra, o que pode retardar o processo de aprendizagem, mas também aumentar a precisão. Em contrapartida, altas taxas de aprendizagem podem tornar a rede neural instável, fazendo com que o erro oscile.

As configurações do SOM podem ser inúmeras e podem variar com as diversas aplicações possíveis, por isso, a definição dos parâmetros, principalmente da taxa de aprendizado, não é nada trivial. Por isso, percentuais de taxa de aprendizado no intervalo de 0 a 1 –

mantendo a função de decaimento padrão da biblioteca – foram testados e avaliou-se o comportamento dos mapas gerados, observando-se a qualidade visual dos dados nos neurônios do mapa, além dos valores dos erros de quantização e topográfico.


4.5.1.4 Raio de vizinhança

O raio de vizinhança (*sigma*), é o raio dos centroides, ou seja, a distância que a função de vizinhança alcança. Uma ilustração desse parâmetro, em mapas hexagonais (à direita) e retangulares (à esquerda) pode ser visualizada na Figura 25.

Kohonen (1998) salienta que mapas com grandes quantidades de neurônios necessitam de um raio maior para manter a distribuição de pesos suave. Em seu trabalho, por exemplo, o raio variou entre 11 e 10 para um mapa com 104.040 neurônios.

O raio de vizinhança, assim como a taxa de aprendizagem, é uma função que decai com o passar das iterações. Kohonen (2013) postula que a definição da forma matemática do parâmetro *sigma* não é crucial desde que seu valor inicial seja relativamente alto no início do processo de treinamento.

Figura 25 - Vizinhanças (0, 1 e 2) do neurônio central



Fonte: Vesanto *et al.* (2000)

O raio de vizinhança é uma função que decresce uniformemente no tempo. Se o raio for muito pequeno, o mapa não será ordenado globalmente. Uma recomendação é iniciar com um raio amplo e deixar este se “encolha” ao longo das iterações (Kohonen, 1990; Kohonen, 2001). Este trabalho seguiu a recomendação de Costa (1999), Haykin (2009) e Kohonen (2013) de adotar o raio inicial como metade do diâmetro do tamanho do mapa definido previamente.

4.5.1.5 Distância de ativação

A distância de ativação, ou medida de dissimilaridade, determina a similaridade entre os dados de entrada e os pesos dos neurônios do mapa. Esse parâmetro calcula o quão distante os valores dos dados de entrada estão em relação aos pesos dos neurônios. O cálculo é feito pela função Euclidiana – Equação (3) – parâmetro *default* da biblioteca *MiniSom* e função mais utilizada em diversos trabalhos, com o uso do SOM, dos mais variados campos científicos.

O conceito da distância Euclidiana é usado para agrupar os dados de acordo com a abordagem do neurônio vencedor (Jevtić; Mladenović; Granić, 2023). O neurônio que possuir a menor distância, ou maior similaridade, com o dado de entrada, vence. A distância de ativação é utilizada no processo de competição da rede neural e neste trabalho, adotou-se a distância Euclidiana.

4.5.1.6 Função de vizinhança

A função de vizinhança define como a influência dos neurônios vizinhos é calculada durante o treinamento. É este parâmetro que tem o papel mais central na auto-organização (Kohonen, 2013). A função de vizinhança determina a taxa de mudança dos pesos da vizinhança ao redor do neurônio vencedor e influencia o resultado do treinamento do SOM atuando como um núcleo de suavização sobre a grade de neurônios (Costa, 1999; Natita; Wiboonsak; Dusadee, 2016).

As funções de vizinhança mais comumente utilizadas na implementação de mapas auto-organizáveis são a Gaussiana e a *Bubble*, sendo a Gaussiana mais prevalente na literatura científica. Stefanovic e Kurasova (2011) compararam resultados obtidos da combinação dessas duas funções com diferentes funções de decaimento da taxa de aprendizado no SOM e chegaram a menores erros de quantização em configurações utilizando a combinação da função Gaussiana com funções de decaimento não lineares para a taxa de aprendizado.

A associação da função de vizinhança Gaussiana com a distância de ativação Euclidiana é habitualmente utilizada em pesquisas de diversas áreas, trazendo resultados extremamente satisfatórios na organização e visualização dos dados de alta dimensão. Dessa forma, optou-se por manter a função Gaussiana – Equação (10), *default* da

biblioteca *MiniSom*, como função de vizinhança para a configuração do SOM deste trabalho.

4.5.1.7 Número de iterações (épocas)

O número de iterações, ou épocas, no algoritmo influencia na precisão do mapeamento. Esse parâmetro pode variar conforme complexidade dos dados de entrada e pela capacidade de convergência do algoritmo. Como o aprendizado é um processo estocástico, para garantir melhor acurácia do mapa, o número de épocas deve ser relativamente elevado (Kohonen, 1990; Costa, 1999).

Em termos quantitativos, Kohonen (1990) e Haykin (2009) sugerem que, em geral, para boa acurácia estatística, a adoção do número de épocas deve ser pelo menos 500 vezes o número de neurônios da rede. Porém, ao mesmo tempo, Kohonen (1990) ressalta que 10.000 épocas, ou menos, em alguns casos pode ser suficiente.

O algoritmo do SOM exige pouco esforço computacional, portanto, foram testados cenários com 10.000 épocas e, as configurações que geraram menores EQ e ET, além de melhor apreciação visual, foram testadas com o número de épocas definido pela multiplicação do número de neurônios por 500 e pelos números de épocas arbitrários fixados em 1.000.000 e 5.000.000 à título de comparação e análise de resultados.

4.5.1.8 Configurações simuladas

As configurações iniciais do SOM testadas com o objetivo de entender o comportamento dos dados da rede Balerma na rede neural, são apresentadas na Tabela 3.

Tabela 3 - Configurações teste dos mapas auto-organizáveis

Configuração	Tamanho do mapa	Taxa de aprendizado (α)	Raio de vizinhança (σ)
C01	10 x 11	0,01	6
C02	10 x 11	0,1	6
C03	10 x 11	0,5	6
C04	10 x 11	0,9	6
C05	20 x 20	0,01	10
C06	20 x 20	0,1	10
C07	20 x 20	0,5	10
C08	20 x 20	0,9	10

Fonte: A autora

Ao total, foram feitos testes com oito configurações diferentes que variaram basicamente o tamanho do mapa (quantidade de neurônios) e a taxa de aprendizado. O raio de vizinhança foi fixado como sendo a metade do diâmetro da grade de neurônios e os demais parâmetros ajustáveis da rede neural, e suas definições, foram discutidos nas subseções desta metodologia.

Os oito testes iniciais guiaram o processo de ajuste fino dos parâmetros do SOM. Por meio dos mapas gerados e valores das métricas de avaliação resultantes de cada uma das configurações, foi possível entender o comportamento da rede neural de forma a ajustar os parâmetros em, busca de menores erros e apreciação visual adequada dos mapas.

4.5.2 Implementação do NSGA – II

A implementação do NSGA – II foi feita por meio da biblioteca *Pymoo* (versão 0.6.1.3) desenvolvida em Python por Blank e Deb (2020). Dentre as características do *Pymoo* as que se destacam para a definição desta ferramenta para implementação do NSGA – II são:

- d) Deb, um dos desenvolvedores da biblioteca, é o criador do NSGA – II.
- e) É uma biblioteca de otimização de problemas multiobjetivo, em constante atualização e que contém um módulo específico de implementação do NSGA – II.
- f) Os desenvolvedores disponibilizam um guia inicial para ajudar os usuários a se familiarizarem com as funcionalidades e capacidades do pacote.
- g) Se integra facilmente com outras ferramentas e bibliotecas, como *Numpy* e *Matplotlib*, o que facilita a manipulação e visualização dos dados.
- h) Documentação abrangente, com exemplos de aplicação, e uma comunidade ativa que promove ajuda e suporte.

A biblioteca *Pymoo* é amplamente utilizada em diversas áreas de pesquisa, justamente por sua robustez, simplicidade de aplicação e pela variedade de algoritmos que a compõem além do NSGA-II, dentre eles, R – NSGA – II, NSGA – III, U – NSGA – III, PSO e RVEA. No que se refere ao emprego do *Pymoo* em redes de distribuição de água, podem ser citados os estudos de Di Nardo e Santonastaso (2022), Ferreira *et al.* (2023), Alsanad, Mahmoud e Aljadhari (2024) e Marlim e Kang (2024).

Para a implementação da biblioteca e pleno funcionamento do AG, foi necessário determinar as variáveis de decisão, as funções objetivo e as restrições, estabelecer a

interface EPANET x Python, criar o modelo do problema a ser solucionado, definir os operadores genéticos, o critério de parada e as sementes aleatórias. Esses pontos, e seus detalhes, serão discutidos em sequência.

4.5.2.1 Formulação do problema de otimização

A segunda fase da setorização consiste na alocação dos dispositivos hidráulicos (medidores de fluxo e válvulas) nas tubulações de fronteira, que conectam os setores da rede. Essas tubulações são as variáveis de decisão do problema de otimização, definidas após a fase de agrupamento, quando os setores foram estabelecidos e os tubos elegíveis para instalação dos dispositivos foram identificados.

Neste estudo, optou-se por utilizar válvulas redutoras de pressão (VRPs) assumindo status totalmente aberto ou totalmente fechado, representando o que ocorreria em uma situação de seccionamento da tubulação. Dessa forma, pensando na gestão de uma rede real, e a de sua expansão, esses dispositivos poderiam ser ajustados e manobrados com o objetivo de atender novos padrões de demanda.

O AG busca pelo melhor posicionamento dos medidores de fluxo e das VRPs dentro desse conjunto de tubulações de fronteira. As variáveis de decisão são binárias: 1 representa tubulações abertas e 0 representa tubulações fechadas. A princípio, em sua configuração inicial, a rede Balerma possui todas as tubulações com status igual a 1. O AG testou possíveis combinações entre tubulações de fronteira abertas – as quais receberam medidores de fluxo – e fechadas (as quais receberam VRPs) de forma a contemplar as funções objetivos e as restrições do problema.

Um objetivo comum na setorização é o de minimizar custos associados à instalação dos dispositivos hidráulicos. Os medidores de fluxo possuem, no geral, um custo mais elevado em relação às VRPs, portanto, assim como nos trabalhos de Zhang *et al.* (2021), Yu *et al.* (2022), Sharma, Dongre e Gupta (2023) e Shekofteh, Yousefi-Khoshqalb e Piratla (2023), a primeira função objetivo deste problema de otimização envolve minimizar a instalação de medidores de fluxo e pode ser visualizada na Equação (16).

$$\min FO1 = \sum_{n=1}^{n_p} N_{mf} \quad (16)$$

Onde, $FO1$ é a função que implica na minimização do número de tubulações abertas, ou seja, na minimização da instalação de medidores de fluxo; N_{mf} é o número de medidores de fluxo (ou tubulações abertas – status igual a 1) e n_p é o número de tubulações de fronteira, ou seja, potenciais locais para instalação de dispositivos hidráulicos.

Considerando que o fator que mais contribui para os vazamentos é a pressão da água, é necessário minimizar a pressão média da rede de distribuição, assim como fizeram Zhang *et al.* (2019) e Sharma, Dongre e Gupta (2023). A segunda função objetivo pode ser visualizada na Equação (17).

$$\min FO2 = \frac{1}{n_{nd}} \sum_{n=1}^{n_{nd}} P_{nd} \quad (17)$$

Onde, $FO2$ é a função que visa a minimização da pressão média da rede; P_{nd} é a pressão no nó de demanda d , e n_{nd} é o número de nós de demanda da rede.

Ambas as funções objetivo são otimizadas sob a restrição de que a pressão em cada nó de demanda esteja de acordo com o mínimo exigido para o serviço da rede, Equação (18).

$$H_i \geq H_{min} \quad (18)$$

Onde, H_i é a pressão no i ésimo nó de demanda e H_{min} é a pressão mínima de serviço exigida e indicada, por Reza e Martínez (2006), como 20 mca para cada nó de demanda da rede Balerna, logo, $H_{min} = 20$ mca.

Não existe na literatura um consenso sobre quantas ou quais funções objetivo e restrições a otimização da setorização deve ter. A definição dessas condições e critérios depende do recorte do problema que está sendo analisado pelo estudo.

Nesta pesquisa, optou-se pelas funções e restrições expressas acima visando reduzir a complexidade e esforço computacional, facilitando a convergência do algoritmo e permitindo maior foco na viabilidade técnica das soluções encontradas.

Ambas as funções, podem representar uma maior tendência à instalação de VRPs, porém, mesmo que estas não sejam diretamente conflitantes, a restrição imposta ao problema pode provocar esse confronto, já que o fechamento de mais tubulações não implica

necessariamente em diminuição da pressão na rede, mas sim a implantação estratégica dos dispositivos de fechamento.

Essa formulação prioriza dois objetivos fundamentais que são o custo e a eficiência, preservando a funcionalidade básica da rede por meio de uma única restrição. Além do mais, foi um ponto de partida para entendimento da integração entre ferramentas diferentes e suas respectivas funcionalidades.

4.5.2.2 Interface EPANET x Python

A integração entre o *software* de modelagem e simulações hidráulicas EPANET e a linguagem de programação Python foi feita pela biblioteca *EPyT* (versão 1.2.0) desenvolvida por Kyriakou *et al.* (2023) do *KIOS Research and Innovation Center of Excellence*, Universidade do Chipre. O acoplamento foi essencial para que o algoritmo do NGSA-II conseguisse realizar simulações dentro do EPANET a cada geração.

De acordo com Kyriakou *et al.* (2023), a biblioteca *EPyT* captura a função completa e os espaços de parâmetros do EPANET, isso permite a utilização de todas as funcionalidades oferecidas pelo *software* e a manipulação direta de parâmetros (válvulas, condições de operação, índices dos nós, dentre outros) por meio da linguagem Python. Além disso, um dos objetivos dos autores foi o de reduzir o tempo e esforço necessários para estabelecer conexão com as funções do EPANET.

A manipulação do *EPyT* é simples e a sua documentação inclui amplos exemplos da utilização das ferramentas disponíveis, além de possuir uma comunidade de usuários ativa, em constante aprimoramento e fácil contato com os desenvolvedores. Na Figura 26 é possível visualizar, por exemplo, como foi feito o carregamento do arquivo (.inp) da rede Balerma no código, etapa precedente à implementação do algoritmo genético em si.

Figura 26 - Interface EPANET x Python

```
# Importar biblioteca para acoplamento do python e EPANET
from epyt import epanet

# Criar o objeto "rede" e carregar o arquivo da rede Balerma
rede = epanet ('Balerma_Benchmark.inp')
```

Fonte: A autora

Ademais, foram utilizados comandos de inicialização de análise hidráulica, verificação de pressões nos nós, mudança de status das tubulações de fronteira, execução de simulação e plotagem de imagem da rede. Outros comandos, tal como contagem de reservatórios, nós de demanda, tubulações e verificação de índices também foram empregados de forma a averiguar o funcionamento da biblioteca e extrair informações sobre o comportamento da rede diante do fechamento de tubulações.

A biblioteca *EPyT* é relativamente nova e foram identificados apenas dois estudos que aplicam a ferramenta em sua metodologia: Ayyash *et al.* (2024) que estudam a operação ideal do abastecimento intermitente da rede D-Town sob escassez de água e Medio *et al.* (2024) que localizam vazamentos por meio de um modelo de aprendizado de máquina e utilizam um AG para posicionar sensores no modelo da rede de *benchmark* Hanoi e no modelo de uma outra rede real.

4.5.2.3 Criação do modelo do problema

Após a realização da interface EPANET x Python é necessário definir o problema de otimização pela biblioteca *Pymoo*. Blank e Deb (2020) exemplificam na documentação da biblioteca a formulação de um problema, como pode ser observado na Figura 27. Com o *Pymoo*, o problema é definido por um objeto que contém alguns dados, por exemplo, o número de variáveis de decisão (n_var), de objetivos (n_obj), de restrições (n_constr) e os limites inferior (xl) e superior (xu) dos valores que as variáveis de decisão podem assumir. Esses atributos devem ser definidos no construtor do problema.

Figura 27 - Exemplo de formulação de um problema utilizando a biblioteca *Pymoo*

```

from pymoo.model.problem import Problem

class MyProblem(Problem):

    def __init__(self):
        super() . __init__(n_var=2,
                           n_obj=2,
                           n_constr=2,
                           xl=anp.array([-2,-2]),
                           xu=anp.array([2,2]))

    def _evaluate(self, x, out, *args, **kwargs):
        f1 = x[:,0]**2 + x[:,1]**2
        f2 = (x[:,0]-1)**2 + x[:,1]**2

        g1 = 2*(x[:, 0]-0.1) * (x[:, 0]-0.9) /
              0.18
        g2 = - 20*(x[:, 0]-0.4) * (x[:, 0]-0.6) /
              4.8

        out["F"] = anp.column_stack([f1, f2])
        out["G"] = anp.column_stack([g1, g2])

```

Fonte: Adaptado de Blank e Deb (2020)

Blank e Deb (2020) ressaltam que nos módulos do *Pymoo* são considerados apenas problemas de minimização. Entretanto, não há perda de generalidade já que um objeto pode ser maximizado, bastando apenas multiplica-lo por -1 e minimizá-lo. Além disso, todas as restrições devem ser formuladas como “menor ou igual a”, por isso, as restrições também devem ser multiplicadas por -1 para inverter o sinal de desigualdade.

Além disso, é fundamental implementar a função *_evaluate* na classe que representa o problema de otimização. Essa função é responsável por avaliar cada indivíduo da população, calculando os valores das funções objetivo que devem ser minimizadas ou maximizadas, além de verificar o cumprimento das restrições do problema. É dentro da *_evaluate* que toda a formulação do problema é estruturada, incluindo a definição das funções objetivo e das condições que as soluções precisam atender.

Nesta etapa, os comandos da biblioteca *EPyT* também são utilizados dentro da função *_evaluate*, anteriormente ao cálculo das funções objetivo, para que o algoritmo realize a abertura e o fechamento das tubulações de fronteira, bem como as simulações a cada iteração e restrições mencionadas no subitem 4.5.2.1 deste trabalho.

Após realizar os cálculos necessários, os valores das funções objetivo são adicionados a um dicionário de saída com a chave F , enquanto os valores das restrições são armazenados com a chave G .

4.5.2.4 Inicialização do algoritmo, população e operadores genéticos

Posteriormente à construção do objeto do problema, no *Pymoo*, é necessário criar o objeto de inicialização do algoritmo genético que envolve a configuração de elementos essenciais que determinam como o processo de otimização será iniciado. Nesta etapa, define-se a quantidade de indivíduos da população (*pop_size*), o número de descendentes (*n_offsprings*), o tipo de amostragem inicial da população (*sampling*), os parâmetros genéticos (*crossover* e *mutação*) e o parâmetro de controle de soluções duplicadas (*eliminate_duplicates*), como mostra a Figura 28.

Figura 28 - Inicialização do NSGA – II pela biblioteca *Pymoo*

```
from pymoo.algorithms.nsga2 import NSGA2
from pymoo.factory import get_sampling ,
    get_crossover , get_mutation

algorithm = NSGA2(
    pop_size=40,
    n_offsprings=10,
    sampling=get_sampling("real_random") ,
    crossover=get_crossover("real_sbx" , prob=0.9 ,
        eta=15) ,
    mutation=get_mutation("real_pm" , eta=20) ,
    eliminate_duplicates=True
)
```

Fonte: Blank e Deb (2020)

A definição dos parâmetros para o funcionamento do algoritmo genético é um desafio em si e depende das especificidades de cada problema e do funcionamento do AG. A decisão em relação aos valores a serem adotados para cada um destes elementos, foi baseada em estudos da literatura que também abordaram a temática de setorização de redes de distribuição utilizando o NSGA – II. Um compilado destes estudos pode ser visualizado na Tabela 4.

Tabela 4 - Definição de parâmetros do NSGA – II utilizada por estudos da literatura

Autores	População	Gerações	Crossover (%)	Mutação (%)
Zhang <i>et al.</i> (2019)	100	500	Padrão do MATLAB (não mencionado)	Padrão do MATLAB (não mencionado)
Yao <i>et al.</i> (2020)	50	200	80	10
Zeidan, Li e Ostfeld (2021)	50; 100	30; 80	Padrão do MATLAB (não mencionado)	Padrão do MATLAB (não mencionado)
Zhang <i>et al.</i> (2021)	50	200	80	10
Shekofteh, Yousefi- Khoshqalb e Piratla (2023)	400	2000	90	20


Fonte: A autora

Neste trabalho, optou-se por uma população composta por 50 indivíduos. O número de descendentes não foi informado ao algoritmo, no entanto, por padrão, o *Pymoo* o configura automaticamente como sendo igual ao tamanho da população.

A amostragem determina como os indivíduos da população inicial serão gerados, podendo adotar diversas estratégias conforme o tipo de variável do problema, como a aleatória e a Amostragem de Hipercubo Latino. Tendo em vista que as variáveis de decisão são as tubulações de fronteira, que podem assumir valor zero ou um, utilizou-se a amostragem binária.

Blank e Deb (2020) disponibilizam uma variedade de operadores de *crossover* no *Pymoo* e a Figura 29 auxilia no entendimento de como a troca de informação (genes) é feita entre os pais. Fonte: Blank e Deb (2020). Desses operadores: o One-Point, o Two-Point, o Uniform Crossover (UX) e o Half Uniform Crossover (HUX) são os operadores que trabalham com variáveis binárias. Uma diferença importante entre eles é que, o UX e o HUX foram projetados exclusivamente para variáveis binárias e os demais podem ser utilizados em outros tipos de variáveis. Com o UX, cada gene possui uma probabilidade de 50% de ser herdada de um dos pais; já com o HUX, há a troca de exatamente 50% dos genes que são diferentes entre os dois pais.

Figura 29 – Ilustração de *crossovers* para diferentes tipos de variáveis do *Pymoo*



Tendo em vista a natureza binária do problema e a necessidade de preservar boas configurações iniciais que reduzam o risco de gerar soluções que possam violar a restrição de pressão mínima da rede de distribuição, optou-se por utilizar o HUX. Esse operador permite um equilíbrio entre a exploração e a preservação de boas soluções já que troca apenas metade dos genes que diferem entre os pais, mantendo características originais de cada solução. Em contrapartida, o UX é caracterizado por certa aleatoriedade, que gera indivíduos mais diversificados e aumentam o risco de gerar soluções inviáveis.

No *Pymoo*, Blank e Deb (2020) fornecem a mutação polinomial para variáveis reais e inteiras e a *bit-flip* para as variáveis binárias. Portanto, a *bit-flip* foi utilizada neste trabalho. A mutação por troca de *bit* altera valores de alguns *bits* (0 ou 1) no cromossomo de um indivíduo, promovendo a diversidade na população e a busca em novas regiões. No *Pymoo*, é possível definir o percentual de chances que cada *bit* tem de ser alterado. Caso a probabilidade de mutação não seja especificada pelo usuário, o padrão do algoritmo segue a formulação expressa na Equação (19).

$$prob. de mutação = \frac{1}{n} \quad (19)$$

Onde n é o número de variáveis de decisão. Isso significa que, em média, um único *bit* será alterado por indivíduo. Esse padrão adapta-se automaticamente ao tamanho do problema e pode ser viável em situações com grande quantidade de variáveis, já que uma taxa de probabilidade de mutação alta pode levar ao comportamento aleatório do algoritmo e corromper boas soluções.

A escolha da taxa de mutação varia na literatura científica, no entanto, os valores mais comuns estão em um intervalo de 0,01 a 5% (Grefenstette, 1986; Lin, Lee e Hong, 2003), podendo, em alguns casos, chegar a 10%. Isto posto, neste trabalho, definiu-se a probabilidade de mutação como sendo de 5%.

Por fim, o parâmetro de controle de soluções duplicadas foi mantido ativo para evitar a geração de indivíduos com as mesmas características na população inicializada ou nas subsequentes. Dessa maneira, mantém-se uma população diversificada e amplia-se o espaço de busca por melhores indivíduos.

Vale ressaltar que atualizações na maneira de importação dos módulos da biblioteca foram feitas pelos desenvolvedores do *Pymoo* e não correspondem mais ao que é exposto na Figura 27 e na Figura 28. A Figura 30 exibe uma versão atualizada da importação dos módulos que foram utilizados neste trabalho.

Figura 30 - Modo de importação atualizado dos módulos do *Pymoo*

```

8  # Importar módulos para o NSGA-II
9  from pymoo.algorithms.moo.nsga2 import NSGA2
10 from pymoo.optimize import minimize
11 from pymoo.core.problem import Problem
12 from pymoo.operators.sampling.rnd import BinaryRandomSampling
13 from pymoo.operators.mutation.bitflip import BitflipMutation
14 from pymoo.operators.crossover.hux import HUX

```

Fonte: A autora

A estrutura de construção das classes exibida na Figura 27 e na Figura 28 foi mantida mesmo após a atualização.

4.5.2.5 Função “minimize”, número de gerações e sementes aleatórias

Seguidamente à construção da inicialização do algoritmo, é necessário realizar a chamada da função *minimize*, responsável por executar a otimização. Essa função conecta o problema de otimização definido, o algoritmo escolhido (como o NSGA – II), o número de gerações (*n_gen*) e a semente aleatória (*seed*). Além disso, ela armazena os resultados da otimização em uma variável (*res*), que pode ser usada para acessar as soluções e os valores das funções objetivo. A estrutura da função *minimize* é apresentada na Figura 31.

Figura 31 - Estrutura da função *minimize* do *Pymoo*

```
from pymoo.optimize import minimize

res = minimize(MyProblem() ,
               algorithm ,
               ('n_gen' , 40) ,
               seed=1,
               verbose=True)
```

Fonte: Blank e Deb (2020)

Considerando que o problema deste trabalho apresenta um espaço de busca finito, devido à quantidade de tubulações de fronteira e à natureza binária das possíveis soluções, o número de gerações foi definido como 100. Esse valor promove redundância suficiente para exploração de diferentes regiões e ajuda a evitar a convergência prematura do algoritmo, além de propiciar menor esforço computacional.

A semente aleatória é uma forma de escolher um “ponto de partida” da geração de números pseudoaleatórios para se garantir a reprodutibilidade dos resultados a cada vez que o código for executado. Neste trabalho, foram testadas sete sementes diferentes, sendo estas: 1, 2, 3, 4, 5, 42 e 700. Cada semente leva a um estado inicial diferente do gerador pseudoaleatório, ou seja, gera populações iniciais distintas, permitindo verificar se há variabilidade e a consistência dos resultados obtidos.

Ademais, o argumento *verbose* foi conservado como *True* (verdadeiro) para exibir o progresso do algoritmo no terminal, evidenciando o número da geração e os valores dos indivíduos, por exemplo, permitindo o acompanhamento da evolução do algoritmo.

4.6 ETAPA 6: CÁLCULO DE PERDAS E ANÁLISES DE RESULTADOS

O cálculo da estimativa do percentual de perdas será feito por meio da Equação (20) proposta por Silva (2003), que é uma adaptação dos estudos de Germanopoulos e Jowitt (1989), utilizada também por Silva *et al.* (2020), Silva (2023) e Lara *et al.* (2024a).

$$\sum_{i=1}^{nós} Perdas = P_{média}^{0,5} \times 7,27 \quad (20)$$

Essa é uma correlação entre as perdas de água e pressões, sendo considerados pequenos vazamentos em torno de cada nó e a pressão d'água. O resultado é obtido em porcentagem e a $P_{média}$ é a média aritmética das pressões nos nós da rede. As constantes da equação foram ajustadas por Silva (2003) de acordo com a faixa média de perdas em redes de distribuição.

5. RESULTADOS

Os resultados deste trabalho estão divididos em três subseções. A primeira delas abarca a fase de agrupamento dos nós, com os resultados dos mapas gerados a partir das configurações do SOM propostas na Tabela 3; a segunda compreende os resultados obtidos na fase de otimização, na qual os dispositivos hidráulicos são alocados e na terceira, calcula-se as perdas de água na rede.

5.1 FASE 1: AGRUPAMENTO DOS NÓS

A fase de agrupamento dos nós envolveu, em primeira instância, a simulação das configurações teste do SOM apresentadas na Tabela 3. A partir dos resultados obtidos, em termos das métricas de avaliação do SOM (erro de quantização e erro topográfico) e da apreciação visual dos mapas gerados pelas configurações iniciais, foi possível realizar o ajuste fino dos parâmetros para definir a configuração mais apropriada para o agrupamento de nós da rede Balerma.

5.1.1 Resultados dos testes das configurações iniciais do SOM

Os resultados provenientes dos testes com as configurações propostas, em termos de valores de erros de quantização e erros topográficos são apresentados na Tabela 5.

Tabela 5 - Resultados dos testes com as configurações do SOM propostas

Configuração	Erro de quantização	Erro topográfico
C01	0,1159	0,0948
C02	0,1057	0,0880
C03	0,1130	0,0926
C04	0,1122	0,1422
C05	0,0985	0,1084
C06	0,0848	0,0880
C07	0,0877	0,1106
C08	0,0903	0,1806
C09*	0,1877	0,7991
C10*	0,1403	0,7675

Fonte: A autora


A partir das simulações feitas e para entender o efeito de uma taxa de aprendizado bem menor do que as propostas na Tabela 3, foram feitos dois testes adicionais: C09 e C10. A configuração C09 foi feita com tamanho de mapa 10 x 11; taxa de aprendizado de 0,001 e raio de vizinhança 6. A C10 foi feita com tamanho de mapa 20 x 20; taxa de aprendizado de 0,001 e raio de vizinhança 10.

A Tabela 5 evidencia menores erros para a configuração C06 o que é um indicativo de maior aderência dos dados à configuração com tamanho de mapa 20 x 20 (400 neurônios), taxa de aprendizado de 0,1, raio de vizinhança igual a 10 e o treinamento em 10.000 épocas ou iterações.

As configurações adicionais, C09 e C10, foram propostas para avaliar o comportamento de uma taxa de aprendizado muito baixa em relação às demais. Essas foram as configurações com os maiores erros encontrados tanto para 110 quanto para 400 neurônios. Reduzidas taxas de aprendizado levam a um aprendizado mais lento dos dados, uma possível maneira de lidar com tal situação seria aumentar o número de épocas para entender como seria o desempenho da taxa de 0,001 em relação à redução ou não dos valores de erro.

Nota-se que os menores erros foram encontrados com a taxa de aprendizagem em 0,1 tanto para a grade de 10 x 11 quanto para a grade de 20 x 20 neurônios, configurações C02 e C06, respectivamente. A análise dos resultados também foi feita pela apreciação visual dos mapas gerados. Os mapas de 110 neurônios e de 400 neurônios podem ser visualizados na Figura 32 na Figura 33, respectivamente.


Figura 32 - Mapas gerados com 110 neurônios: (a) C01; (b) C02; (c) C03 e (d) C04



Fonte: A autora

A localização de grupos nos mapas pode não ser tão trivial. Observa-se que não é possível identificar grupos com clareza nos mapas que seguiram a sugestão de Vesanto e Alhoniemi (2000) em relação à definição da quantidade de neurônios, a não ser na configuração C09, que produziu um mapa mais limpo e de fácil identificação de *clusters* – Figura 34, mas que não produziu resultados satisfatórios quanto aos valores dos erros.


Figura 33 - Mapas gerados com 400 neurônios: (a) C05; (b) C06; (c) C07 e (d) C08



Fonte: A autora

Nos mapas de grade 20 x 20, em especial o C06 e o C07 existem mais neurônios “vazios” o que permite melhor visualização da disposição dos dados nos mapas e, conseqüentemente, maior facilidade em identificar os *clusters* formados para além do particionamento a partir da coloração das áreas do mapa.


Figura 34 - Mapas gerados para as configurações adicionais: (a) C0 e (b) C10



Fonte: A autora

Também foram gerados gráficos de forma a verificar a evolução dos erros à medida que as iterações foram sendo efetuadas. Os gráficos que podem ser observados na Figura 35 correspondem aos erros gerados para os mapas com as configurações de 110 neurônios.


Figura 35 – Evolução de erros das configurações de 110 neurônios: (a) C01; (b) C02; (c) C03 e (d) C04



Fonte: A autora

Já os gráficos que podem ser observados na Figura 36 correspondem aos erros gerados para os mapas com as configurações de 400 neurônios. Pela Figura 35 e pela Figura 36 é possível observar não somente a evolução dos erros ao longo das épocas para cada configuração de mapa, mas também o comportamento dos erros à medida que a taxa de aprendizado foi aumentada. O que foi pontuado por Machado *et al.* (2007) pôde ser observado: a taxa de aprendizado de 0,01 leva ao comportamento mais suave dos erros. Ao passo que as taxas de aprendizado foram aumentando de acordo com as configurações, foi possível observar o comportamento instável de aprendizagem.


Figura 36 – Evolução de erros das configurações de 400 neurônios: (a) C05; (b) C06; (c) C07 e (d) C08



Fonte: A autora

Ainda que o comportamento de taxas de aprendizado altas seja instável, os resultados mostram que há a tendência de queda nos valores tanto do erro de quantização quanto do erro topográfico. Pode ser que a instabilidade seja resolvida com o aumento da quantidade de épocas. A Figura 37 mostra a evolução dos erros das configurações adicionais, bem como o lento decaimento dos valores desses erros. Esse fenômeno, como mencionado anteriormente, pode ser justificado pela baixa taxa de aprendizado, necessitando de maior quantidade de épocas para aprendizagem.

Figura 37 - Erro de quantização e erro topográfico das configurações adicionais: (a) C09 e (b) C10



Fonte: A autora

As configurações de teste simuladas forneceram um panorama do comportamento dos dados de entrada na rede neural, permitindo a compreensão dos padrões necessários para o ajuste fino dos parâmetros do SOM. De modo geral, as configurações testadas indicaram a necessidade da combinação entre uma baixa taxa de aprendizado e um número elevado de épocas, a fim de garantir que a aprendizagem da rede neural ocorra de maneira suave, buscando minimizar os erros ao máximo.

5.1.2 Ajuste fino dos parâmetros do SOM

O ajuste fino dos parâmetros do SOM foi feito a partir dos resultados das configurações iniciais testadas previamente. A partir das simulações iniciais, por apreciação visual percebeu-se maior adequabilidade, aos dados de entrada, dos mapas com grade de 400 neurônios, portanto, os testes de aperfeiçoamento da rede neural foram feitos com grades deste tamanho.

As demais considerações feitas para definição dos ajustes dos parâmetros da rede neural envolveram dois critérios. O primeiro deles foi a manutenção de baixas taxas de aprendizado para garantir a suave aprendizagem do SOM. O segundo critério envolveu em primeira instância, a multiplicação da quantidade de neurônios por 500 – como sugerido por Kohonen (1990) e Haykin (2009) – resultando em configurações com 200.000 épocas. Para efeito de comparação de resultados e entendimento de limites da rede neural, também foram simuladas configurações com 1.000.000 e com 5.000.000 de épocas, valores estes definidos arbitrariamente, porém visando um número considerável de iterações do algoritmo.

A configuração C06 – como explicitado na Tabela 5, com taxa de aprendizado de 0,1 – foi a que apresentou o menor erro de quantização e o menor erro topográfico em relação às demais testadas. Isto posto, optou-se por variar a quantidade de épocas da C06 para entender o efeito gerado nas métricas de avaliação do SOM.

Com base dos testes iniciais, a configuração adicional C10, possuindo a menor taxa de aprendizado testada (0,001), resultou nos mais elevados valores de erro devido à baixa quantidade de épocas disponíveis para aprendizado. Isso sugere que o aprendizado da rede neural nessa configuração foi comprometido. Por isso, a configuração C10 foi novamente testada sob condições de um número maior de épocas.

A Tabela 6 apresenta os valores do erro de quantização e do erro topográfico obtidos para as simulações realizadas com as configurações C06 e C10 sob os três cenários de quantidade de épocas testados.

Tabela 6 – Resultados dos valores dos erros provenientes do ajuste fino do SOM

	200.000		1.000.000		5.000.000	
Configuração	EQ	ET	EQ	ET	EQ	ET
C06	0,0819	0,0700	0,0883	0,1354	0,0846	0,1490
C10	0,0901	0,0926	0,0840	0,0948	0,0854	0,1196

Fonte: A autora

A quantidade de épocas definida com base nas sugestões de Kohonen (1990) e Haykin (2009) resultou nos menores erros de quantização e topográfico para todas as simulações feitas: 0,0819 e 0,0700, respectivamente, na configuração C06. Superando os resultados obtidos na fase anterior.


Observa-se que o erro de quantização, nas simulações feitas para a C06, não diminuiu significativamente com o aumento das épocas, mas manteve-se na casa dos 0,08 o que sugere que o SOM atingiu um ponto convergência, ou seja, o modelo está representando os dados de maneira ideal em relação aos vetores de peso, indicando adequada generalização dos dados. Além disso, o erro topográfico sofreu variações aumentando para 0,1354 com 1.000.000 e para 0,1490 com 5.000.000 de épocas o que é um indicativo de que o SOM perdeu a capacidade de manter a topologia à medida que a quantidade de épocas aumentou excessivamente e neurônios que deveriam estar próximos no espaço do mapa começam a se distanciar.

Os valores dos erros para a configuração C10 mostraram um padrão de declínio, alcançando cerca de 0,08 no erro de quantização a partir de 1.000.000 de épocas. O erro topográfico atingiu o seu valor mínimo com 1.000.000 e mesmo assim não superou o mínimo alcançado pela C06. Esses resultados destacam a lenta convergência do SOM com uma baixa taxa de aprendizado, exigindo um maior número de épocas e, conseqüentemente, aumentando o esforço computacional.

Desse modo, com base nos resultados apresentados pela Tabela 6, a configuração que evidenciou a convergência do SOM aos menores erros de quantização e topográfico foi a C06 com 200.000 épocas e taxa de aprendizado de 0,01. O mapa gerado para a C06 e o

gráfico que mostra a evolução dos erros ao longo das épocas podem ser visualizados na Figura 38

Figura 38 - Configuração C06: (a) Mapa gerado e (b) Gráfico de evolução dos erros



Fonte: A autora

O mapa gerado após o treinamento do SOM revela uma pequena área vermelha no canto inferior direito, indicativo de que os neurônios têm maiores distâncias em relação aos seus vizinhos. Isso pode sugerir a variação nos padrões dos dados mapeada pela rede neural possivelmente por uma menor densidade de dados similares ou presença de dados atípicos e que são difíceis de agrupar.


A grande área avermelhada ao centro do mapa, não necessariamente indica a presença de dados atípicos. Essa região não está isolada ou cercada por BMUs com áreas com cores significativamente diferentes, mas representa um espaço significativo do mapa, o que pode apontar que esses neurônios possuem similaridade entre si, ou seja, pode revelar características específicas dos dados de entrada. Os valores dos erros por si só são evidências de ajuste adequado dos dados ao mapa e é possível ver o decaimento desses valores no decorrer das épocas, pela Figura 38, atingindo a convergência ao final do treinamento.

Os mapas e gráficos resultantes do treinamento da C06 com 1.000.000 e 5.000.000 de épocas e dos três cenários de épocas da C10 podem ser apreciados no Apêndice A deste trabalho.

5.1.3 Definição dos setores da rede Balerna

A definição dos setores da rede Balerna foi feita a partir da identificação de grupos formados no mapa gerado após o treinamento do SOM que pode ser visto na Figura 38 (a). O reconhecimento de *clusters* não é trivial e foi feito por apreciação visual identificando neurônios vencedores localizados próximos uns aos outros e pelas mudanças de cores nas regiões do mapa. A representação dos *clusters* identificados que resultou nos DMCs da rede pode ser visualizada na Figura 39.


Figura 39 - Identificação de *clusters* no SOM para setorização



Fonte: A autora

Além disso, a análise foi complementada pelo entendimento dos dados contidos em cada um dos neurônios vencedores do mapa de forma a entender os grupos formados ou a presença de dados que poderiam distorcer as interpretações feitas. O resultado desta etapa foi a definição dos setores da rede Balerna que podem ser visualizados na Figura 40.

Figura 40 - Setores (DMCs) da rede Balerma




Fonte: A autora

A partir do mapa gerado pelo SOM – Figura 38 (a) – a rede Balerma foi setorizada em cinco Distritos de Medição e Controle. Alguns nós foram posicionados em neurônios de grupos nos quais não havia a possibilidade de formação de *cluster* por não existir uma tubulação conectando-os ao setor, sendo estes:

- nó 266 – localizado no DMC 3, porém indicado ao DMC 4 pelo SOM;
- nós 52, 55 e 59 – localizados no DMC 5, porém indicados ao DMC 2 pelo SOM;
- nó 159 – localizado no DMC 2, porém indicado ao DMC 5 pelo SOM;
- nó 25004 e 180004 – localizados no DMC 3, porém indicados ao DMC 1 pelo SOM;
- nó 95 – localizado no DMC 2, porém indicado ao DMC 4 pelo SOM.

A Figura 41 indica o posicionamento desses nós na rede Balerma.

Figura 41 - Nós conflituantes no processo de setorização



Fonte: A autora

Assim como ocorreu em Lara *et al.* (2024d), esses nós possuem características similares no que tange a localização topográfica da rede Balerna, o que é um indício de correta representação e captura dos dados pelo SOM.

O nó 82 foi posicionado em um neurônio da formação do DMC 4, porém, foi adicionado ao DMC 2 pois sua inserção no outro grupo geraria o isolamento do nó 228 (pertencente ao DMC 2) e a necessidade de alocação de 3 dispositivos hidráulicos tendo em vista que este é um ponto de conexão tripla de tubulações.

No mapa final gerado pelo SOM nota-se a presença de um neurônio em vermelho, indício de possível *outlier* – localizado na coordenada (14, 2). Os dados associados a este neurônio são dos nós 383 e 384. Ao avaliar estes pontos, percebe-se que estão próximos ao nó 601: único que possui demanda nula em toda a rede e que está localizado no neurônio (15, 0). Os demais nós possuem demanda de 5,55 L/s. Isso posto, assim como

ocorreu em Lara *et al.* (2024d) no estudo da rede Modena, com o SOM foi possível identificar uma característica atípica entre os nós da rede Balerna.


5.2 FASE 2: OTIMIZAÇÃO

A fase de otimização da rede envolveu, primeiramente, a identificação das tubulações de fronteira. Em sequência, executou-se o NSGA – II com as configurações, parâmetros e as sementes aleatórias definidas na seção de metodologia. A partir dos resultados obtidos, foi possível entender o posicionamento ótimo de VRPs e medidores de fluxo.

5.2.1 Identificação das tubulações de fronteira

As tubulações de fronteira são as variáveis de decisão do problema de otimização e correspondem àquelas localizadas entre os setores. A identificação destes elementos foi feita a partir da Figura 40, na qual os setores são apresentados. A Figura 42 destaca as 8 tubulações de fronteira e seus respectivos identificadores que foram informados ao NSGA – II: 552, 480, 173, 164, 221, 349, 248 e 165. Esses identificadores são informados ao algoritmo em forma de vetor.


Figura 42 - Tubulações de fronteira e seus respectivos identificadores



Fonte: A autora

Observa-se que dos reservatórios R38 e R43 saem duas tubulações que realizam o abastecimento em direções distintas. Do R38 derivam as tubulações 5 e 338 e do R43 as tubulações 194 e 223. Destas, a 5, a 338 e a 194, podem desempenhar um papel estratégico, visto que são potenciais locais para alocar VRPs e que a diminuição da pressão média na rede é de grande interesse à setorização. A tubulação 223 é o único meio de abastecer uma parte do DMC 3, portanto, não pode ser fechada por uma VRP. Além das tubulações de fronteira, a Figura 43 destaca as tubulações estratégicas que saem dos reservatórios R38 e R43.

Figura 43 - Tubulações de fronteira e tubulações estratégicas



Fonte: A autora

Isto posto, resolveu-se por também realizar execuções do AG, sob as mesmas condições expostas na metodologia, contemplando as tubulações estratégicas como variáveis de decisão do problema. Dessa forma, o NSGA – II não apenas otimiza as fronteiras entre os setores, mas também considera a influência dos reservatórios sobre múltiplos setores. Isso aumenta a flexibilidade do modelo e o espaço de busca do algoritmo para 11 variáveis de decisão, podendo contribuir com soluções eficazes no que tange o objetivo de redução de perdas.

5.2.2 Execução do NSGA – II

A execução do NSGA – II com as sete sementes aleatórias produziu os mesmos padrões binários nas variáveis de decisão, tanto para o caso com oito variáveis (sem incluir as tubulações estratégicas), quanto para o caso com onze variáveis (incluindo as tubulações estratégicas). A Tabela 7 exibe os resultados encontrados pelo algoritmo.

Tabela 7 - Resultados da execução do NSGA – II

Variáveis de decisão	Melhores soluções	Medidores de fluxo	VRPs	Pressão mínima (mca)	Pressão média (mca)	Pressão máxima (mca)
8	(1, 0, 1, 1, 0, 1, 1, 1)	6	2	20,71	49,76	97,88
11	(1, 0, 1, 1, 0, 1, 1, 1, 1, 1, 1)	9	2	20,71	49,76	97,88
	(1, 0, 1, 1, 0, 1, 1, 1, 1, 0, 1)	8	3	22,77	50,16	97,88

Fonte: A autora

O fato de todas as sementes aleatórias terem levado o algoritmo a convergir para o mesmo resultado, é um indício de consistência e convergência do NSGA – II para um ótimo global. Isso sugere que o algoritmo convergiu para soluções idênticas independentemente da inicialização. Esse comportamento é esperado em problemas menores e binários, já que o espaço de busca é finito.

Além do mais, a alteração do status de uma tubulação pode impactar no comportamento da rede como um todo, podendo inclusive criar pontos indesejados de pressão negativa. A restrição de pressão mínima de serviço resolve essa questão e acaba também reduzindo as opções de busca disponíveis para o algoritmo. Dessa forma, o algoritmo consegue explorar todo o espaço de busca e convergir mais rápido à uma solução otimizada, exigindo menor esforço computacional.

A análise da rede pelo algoritmo com 8 variáveis de decisão, indicou como melhor solução o fechamento das tubulações 480 e 221. Essa configuração resultou na instalação de duas VRPs e seis medidores de fluxo, conforme ilustrado na Figura 44.

Figura 44 - Solução com 8 variáveis de decisão: instalação de 2 VRPs e 6 medidores de fluxo



Fonte: A autora

Quando o algoritmo foi aplicado com 11 variáveis de decisão, duas soluções foram identificadas. A primeira replicou o fechamento das mesmas tubulações de fronteira sugeridas na análise com 8 variáveis. Já a segunda solução incluiu, além dessas, o fechamento da tubulação 5, conectada ao reservatório R38, conforme Figura 45.

Figura 45 - Solução com 11 variáveis de decisão: instalação de 3 VRPs e 8 medidores de fluxo




Fonte: A autora

A pressão média da rede original era de 52,13 mca. O fechamento de duas tubulações de fronteira, com a instalação de VRPs nas tubulações 480 e 221, reduziu a pressão média para 49,76 mca, representando uma redução de 4,55%. Já o fechamento de três tubulações, incluindo a tubulação estratégica 5, resultou na pressão média de 50,16 mca, correspondendo a uma redução de 3,78%. A Figura 46 mostra o mapa de pressões da rede Balerma em seu formato original.

A pressão mínima da rede original é de 20,71 mca. Este valor se manteve nas soluções que adicionam VRPs nas tubulações 480 e 221 e aumentou para 22,77 mca na solução que inclui o fechamento da tubulação 5.

A pressão máxima da rede original é de 100,02 mca. Todas as soluções encontradas resultaram na diminuição deste valor para 97,88 mca, representando uma redução de 2,14 pontos percentuais.


Figura 46 - Mapa de pressões da rede Balerma em seu formato original



Fonte: A autora

Em termos absolutos, analisando os valores de pressão média, a diferença percentual entre as duas soluções encontradas é relativamente pequena (0,77%). O mapa de pressão de cada uma das soluções pode ser visualizado na Figura 47.

Figura 47 - Mapa de pressões das soluções encontradas: (a) 2 VRPs; (b) 3 VRPs



Fonte: A autora

Comparando visualmente os mapas, a redução de pressão ocorreu mais notoriamente ao centro da rede Balerna onde as pressões estavam em um intervalo de 50 a 75 mca, na rede original, e passaram para o intervalo de 25 a 50 mca, nas redes setorizadas, vide coloração dos nós de demanda. O que não é indício de que somente nesses pontos houve a redução de pressão. Esta é uma avaliação que deve ser feita ponto a ponto.

As soluções que envolvem a instalação de duas VRPs evidenciam maior redução na pressão média e a instalação de apenas 6 medidores de fluxo geraria menor custo para a rede. Observa-se que a instalação de uma terceira VRP, na tubulação estratégica 5, tem como consequência o aumento de pressão em nós próximos ao reservatório R43, o que culmina em uma pressão média ligeiramente maior do que a da configuração com duas tubulações fechadas.

O nó 19 era o único que apresentava pressão acima de 100 mca (precisamente: 100,02 mca) na rede original. Ponto que poderia ser uma preocupação para os gestores. A instalação de VRPs na rede possibilitou a queda de pressão para 97,88 mca neste nó (redução de cerca de 2,14%).

Vale destacar que a pressão mínima exigida para serviço da rede, de acordo com Reca e Martínez (2006), criadores do modelo Balerma, é de 20 mca. No entanto, em redes reais não é incomum que essa exigência seja de 10 mca, como o exemplo do que é imposto para as redes brasileiras pela NBR 12218 (ABNT, 2017). A pressão mínima tem impacto significativo na busca do algoritmo por soluções. Com a pressão mínima mais elevada, o algoritmo tem o espaço de busca mais restrito, o que significa que menos tubulações podem ser consideradas viáveis para instalação de VRPs, limitando a redução mais expressiva da pressão.

Com base nessas considerações, foram realizados testes adicionais adotando o limite de pressão mínima de 10 mca para avaliar o impacto de um espaço de busca menos restrito no desempenho do algoritmo e nas soluções obtidas. Os testes foram realizados sob as mesmas condições e configurações explícitas na subseção 4.5.2 deste trabalho e seus resultados podem ser visualizados na Tabela 8.

Tabela 8 - Resultados da execução do NSGA – II com a restrição de pressão mínima de 10 mca

Variáveis de decisão	Melhores soluções	Medidores de fluxo	VRPs	Pressão mínima (mca)	Pressão média (mca)	Pressão máxima (mca)
8	(0, 1, 0, 1, 0, 1, 1, 1)	5	3	12,04	44,54	82,44
	(1, 0, 0, 1, 1, 1, 1, 1)	6	2	10,50	42,26	81,59
11	(0, 1, 0, 1, 0, 1, 1, 1, 0, 1, 1)	7	4	10,69	43,14	82,44
	(1, 0, 0, 1, 1, 1, 1, 1, 0, 1, 1)	8	3	10,50	40,87	81,59

Fonte: A autora

Nos testes adicionais, o NSGA – II convergiu para os mesmos resultados mesmo com diferentes sementes aleatórias, evidenciando, novamente, a convergência do algoritmo ao ótimo global.

A partir da adoção da pressão mínima de 10 mca, foi possível obter uma solução na qual a pressão média da rede atingiu 40,87 mca, o que representa a redução de 21,60% em relação a pressão média da rede original. Essa solução conta com 11 variáveis de decisão e visa a instalação de VRPs nas tubulações 480, 173 e 194. A solução similar a esta, envolvendo 8 variáveis de decisão, deixou de fechar a tubulação 194 (elemento ligado ao


reservatório R43) e atingiu pressão média de 42,26, reduzindo em 18,93% a pressão em relação à rede original. Ambas as soluções obtiveram pressão mínima de 10,50 mca e pressão máxima de 81,59 mca (redução de 18,43% da máxima original).

5.2.3 Comparação com estudos de setorização aplicados à rede Balerma

Identificou-se dois estudos na literatura que utilizaram a rede Balerma para aplicação de abordagens de setorização: Shekofteh, Yousefi-Khoshqalb e Piratla (2023) e Wei *et al.* (2023). Esses trabalhos apresentam metodologias semelhantes à proposta deste estudo, envolvendo as duas fases da setorização e sendo, portanto, referências importantes para a comparação de resultados, especialmente no que se refere à redução da pressão média na rede e, conseqüentemente, à diminuição de perdas.

Shekofteh, Yousefi-Khoshqalb e Piratla (2023) testaram a fase de agrupamento com três algoritmos diferentes: *Girvan-Newman* (GN), *Fast Greedy* (FG) e *Short Random Walk* (SWR), utilizando o NSGA – II na fase de otimização. A rede após a setorização, pela associação de cada um dos algoritmos com o NSGA – II, pode ser visualizada na Figura 48.

Figura 48 - Setorização da rede Balerma pelo estudo de Shekofteh, Yousefi-Khoshqalb e Piratla (2023)



Fonte: Shekofteh, Yousefi-Khoshqalb e Piratla (2023)

As setas em verde indicam o posicionamento de medidores de fluxo e em vermelho das VRPs. Todos os três algoritmos de agrupamento resultaram em 6 DMCs. Os resultados da aplicação de cada algoritmo associado ao NSGA – II podem ser vistos na Tabela 9.

Tabela 9 - Resultados da setorização do estudo de Shekofteh, Yousefi-Khoshqalb e Piratla (2023)

Algoritmo	VRPs	Tubulações de fronteira fechadas	Medidores de fluxo	Pressão média (mca)	Diminuição da pressão (%)
<i>Girvan- Newman</i>	3	174, 457 e 366	4	51,58	1,06
<i>Fast Greedy</i>	3	366, 363 e 128	6	51,69	0,84
<i>Short Random Walk</i>	2	174 e 366	5	51,75	0,73

Fonte: A autora

Observa-se que a diminuição percentual da pressão média da rede não superou ao percentual encontrado neste estudo (4,55%) em nenhuma das 3 associações de algoritmos propostas pelos autores. A quantidade de VRPs que o NSGA – II encontrou foi similar à encontrada neste trabalho, apesar das posições destas terem sido diferentes devido às tubulações de fronteira distintas.

Verifica-se certa semelhança em alguns dos DMCs definidos pelos três algoritmos testados por Shekofteh, Yousefi-Khoshqalb e Piratla (2023) com os definidos neste trabalho:


- DMCs 5, 4 e 5 definidos pelos algoritmos GN, FG e SRW, respectivamente, possuem semelhança com o DMC 3, definido pelo SOM.
- O DMC 2 (definido pelos 3 algoritmos) é similar ao DMC 1 deste trabalho.

Essa correspondência reforça os grupos formados e o padrão reconhecido por técnicas diferentes, mesmo com algumas variações. Podendo ser um indício de áreas com características que devem ser preservadas.

Wei *et al.* (2023) propuseram uma abordagem utilizando o DCP otimizado por *clustering* espectral. O objetivo dos autores era manter a uniformidade de pressão nos setores, o que não causou nenhuma alteração na pressão da rede após a otimização. Como pode ser

visualizado na Figura 49, nenhuma VRP foi instalada. Para os autores a instalação de VRPs não teria impacto positivo nas tubulações da rede.

Figura 49 - Setorização da rede Balerna pelo estudo de Wei *et al.* (2023)




Fonte: Wei *et al.* (2023)

A abordagem de Wei *et al.* (2023) resultou na divisão da rede Balerna em 4 setores, sendo dois destes similares aos encontrados neste trabalho e no de Shekofteh, Yousefi-Khoshqalb e Piratla (2023): o DMC 1 e o DMC 3. Porém, vale ressaltar que, o agrupamento de nós e a instalação de medidores de fluxo por si só não alteram a pressão média da rede, não fornecem o isolamento total ou parcial entre os setores, não controlam rupturas e não contribuem para o controle de perdas na rede.

A similaridade, citada anteriormente, entre os setores definidos neste trabalho e os estudos analisados, se dá em áreas nas quais os nós de demanda da rede possuem maior elevação, como pode ser observado na Figura 50.

Figura 50 - Elevações dos nós da rede Balerma



Fonte: A autora

Ao que parece, a elevação é uma característica dominante em áreas elevadas e se sobressai em relação aos demais atributos dos nós da rede, como demanda e coordenadas, levando os algoritmos a convergirem para soluções aproximadas, tendo como exemplo os DMCs citados anteriormente.

5.3 CÁLCULO DE PERDAS NA REDE BALERMA

Os resultados dos cálculos dos percentuais de perdas, feitos por meio da Equação (20), podem ser visualizados na Tabela 10. Ambas as soluções encontradas pelo NSGA – II resultaram na diminuição da pressão média da rede e, consequentemente, na diminuição do percentual de perdas. A solução que envolve a instalação de duas VRPs levou a uma redução de 1,21 pontos percentuais em relação ao cenário original da rede; enquanto a solução de instalação de três VRPs reduziu em 1 ponto percentual.

Tabela 10 - Cálculo do percentual de perdas da rede Balerma

Balerma	Pressão média (mca)	% Perdas
Original	52,13	52,49
Instalação de 2 VRPs	49,76	51,28
Instalação de 3 VRPs	50,16	51,49

Fonte: A autora

A Tabela 9 e a Tabela 10 evidenciam que adicionar mais VRPs nem sempre resulta em ganhos proporcionais de diminuição da pressão média e que isso depende da alocação estratégica das válvulas na rede.

Os testes adicionais, a partir da pressão mínima de serviço de 10 mca, resultaram na menor pressão média de 40,86 mca. Por meio da Equação (20), as perdas na rede, em condições de menor pressão de serviço, para esta solução, seriam de 46,47%. Esse valor está 6,02 pontos percentuais abaixo do percentual de perdas calculado para a rede original.

6. CONCLUSÕES E RECOMENDAÇÕES

Este trabalho propôs uma metodologia para setorização de redes de distribuição de água que compreende o uso da rede neural mapas auto-organizáveis, em seu estado puro, na fase de agrupamento dos nós de demanda e do algoritmo genético NSGA – II na fase de otimização. A abordagem proposta foi aplicada à rede de *benchmark* Balerma visando a diminuição da pressão média e, consequentemente, do percentual de perdas de água.

A implementação do SOM foi feita por meio da biblioteca *MiniSom* e o ajuste fino dos parâmetros da rede neural se mostrou uma etapa valiosa para que esta tenha tempo de aprender e trabalhar com os dados de entrada. A configuração que atingiu menor erro de quantização (0,0819) e menor erro topográfico (0,0700) foi a C06, com taxa de aprendizado de 0,01 e 200.000 épocas.

O uso do SOM puro, ou seja, sem associação da rede neural com outros algoritmos de agrupamento – como *k-means*, se mostrou promissor, considerando-se os resultados encontrados na geração do mapa final para as métricas de avaliação da ferramenta (EQ e ET). A rede neural conseguiu captar os padrões dos nós de demanda resultando na divisão da rede Balerma em cinco Distritos de Medição e Controle e oito tubulações de fronteira, envolvendo baixo esforço computacional.

Como esperado, a análise do mapa final gerado pelo SOM não foi trivial e deve-se ressaltar a necessidade do conhecimento dos dados de entrada da rede para que a interpretação seja mais fiel possível à realidade. Fato é que a rede neural se mostrou mais uma vez eficiente em reconhecer padrões e dados atípicos, se mostrando como uma ferramenta útil principalmente no gerenciamento de redes de distribuição de água.

Na fase de otimização, com a implementação do NSGA – II pela biblioteca *Pymoo*, as sete sementes aleatórias testadas reproduziram os mesmos resultados. Isso evidencia que o algoritmo genético alcançou o ótimo global do problema. Essa tarefa se torna mais factível em problemas binários e que possuem poucas variáveis de decisão, como a situação deste trabalho, já que o espaço de busca do algoritmo é finito e limitado pelas restrições impostas.

A solução que implica na instalação de duas VRPs (fechamento das tubulações 480 e 221) e 6 medidores de fluxo na rede foi a que obteve a menor pressão média: 49,76 mca, e

menor percentual de perdas (51,28%) representando uma redução de 4,55% em relação à pressão média da rede original e de 1,21 pontos percentuais em relação as perdas do cenário original da rede.

Os resultados deste trabalho possibilitaram um cenário de setorização com menores perdas, se comparados aos dos demais estudos da literatura que utilizaram a rede Balerna na aplicação de métodos de setorização – Shekofteh, Yousefi-Khoshqalb e Piratla (2023) e Wei *et al.* (2023) – indicando, mais uma vez, a importância da fase de agrupamento e da identificação das tubulações de fronteira. Além de apontar a não trivialidade da alocação de VRPs que pode gerar alterações na rede como um todo e que deve ser realizada de maneira estratégica.

A dificuldade de reduzir significativamente a pressão média da rede Balerna pode ser atribuída às características topográficas e à pressão mínima de serviço exigida, o que torna a setorização mais desafiadora. A rede apresenta uma variação de relevo considerável, com cotas entre 1,20 m e 127,00 m. Essa diferença de elevação leva a pressões maiores nas áreas baixas e a menores pressões em regiões mais altas. Assim, a topografia aliada à necessidade de manter a pressão mínima de serviço, impõem limitações físicas à possibilidade de reduções mais drásticas na pressão média da rede.

Testes envolvendo a adoção da pressão mínima de 10 mca revelaram uma redução de 21,60% na pressão média da rede original e de 18,43% na pressão máxima, o que evidencia o impacto significativo que a pressão mínima de serviço possui na busca do algoritmo por soluções viáveis. Este valor representa 16,95 pontos percentuais acima do encontrado com a pressão mínima de serviço de 20 mca. Houve, consequentemente, um reflexo da pressão média também na redução de perdas: sendo estas de 46,47% para pressão mínima de 10 mca, isto é, uma diminuição de 6,02 pontos percentuais em relação às perdas da rede original.

A comparação dos resultados deste trabalho com os estudos de Shekofteh, Yousefi-Khoshqalb e Piratla (2023) e Wei *et al.* (2023) reforça a complexidade da setorização da rede Balerna e a dificuldade da redução significativa da pressão média por meio da setorização com DMCs fixos. Esse comportamento indica a necessidade do estudo de outras abordagens para superar as limitações impostas pela rede.

Além disso, recomenda-se para trabalhos futuros:

- a. A aplicação da abordagem proposta em outras redes de *benchmark* para que o seu desempenho seja avaliado sob condições e características diferentes.
- b. O estudo da aplicabilidade do método proposto sob a condição de variação de demanda dos nós ao longo do dia.
- c. A introdução de novos objetivos ao algoritmo genético, permitindo uma investigação mais ampla e próxima aos cenários reais.
- d. A investigação do uso de restrições adicionais como a de pressão máxima a qual a rede pode ser submetida.

Ademais, o método proposto demonstrou que a combinação do SOM puro e do NSGA – II é uma abordagem eficiente para a setorização de redes. O método foi aplicado em uma rede com características topográficas e operacionais desafiadoras e ainda assim, foi capaz de identificar setores consistentes e posicionar VRPs e medidores de fluxos de maneira a encontrar uma configuração que superou resultados alcançados por estudos da literatura científica.

7. REFERÊNCIAS

- ABNT. **NBR 12218**: Projeto de rede de distribuição de água para abastecimento público. Rio de Janeiro, 2017.
- ABRAHAM, A. **Artificial neural networks**. Handbook of measuring system design, 2005.
- AGÊNCIA NACIONAL DAS ÁGUAS E SANEAMENTO BÁSICO (ANA). **Atlas águas**: segurança hídrica do abastecimento urbano. Brasília: ANA, 2021.
- AKSELA, K.; AKSELA, M.; VAHALA, R. Leakage detection in a real distribution network using a SOM. **Urban Water Journal**, v. 6, n. 4, p. 279-289, 2009.
- ALMEIDA, G. F. **Algoritmos Multiobjetivos para Planejamento Sistemático de Conservação: Estudo de Caso para Plantas e Mamíferos Terrestres**. 2016. 96 f. Monografia (Curso de Engenharia da Computação) – Universidade de Brasília, Brasília, 2016.
- ALSANAD, A. H.; MAHMOUD, A. A. B.; ALJADHAI, S. I. An Optimal Upgrading Framework for Water Distribution Systems Operation. **Water**, v. 16, n. 12, 2024.
- AMARAL, H. L. M. **Desenvolvimento de uma nova metodologia para previsão do consumo de energia elétrica de curto prazo utilizando redes neurais artificiais e decomposição de séries temporais**. Tese de Doutorado. Universidade de São Paulo, 2020.
- ANCHIETA, T. F. F.; MEIRELLES, G.; BRENTAN, B. M. Optimal district metered areas design of water distribution systems: A comparative analysis among hybrid algorithms. **Journal of Water Process Engineering**, v. 63, 2024.
- ARSENE, C. T. C.; AL-DABASS, D.; HARTLEY, J. A study on modeling and simulation of water distribution systems based on loop corrective flows and containing controlling hydraulics elements. In: **2012 Third International Conference on Intelligent Systems Modelling and Simulation**. IEEE, 2012. p. 423-430.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 12218 – Projeto de rede de distribuição de água para abastecimento público – Procedimento**. Rio de Janeiro, 2017.

AYYASH, F.; ZHANG, C.; JAVADI, A. A.; FARMANI, R. Optimal Operation of Intermittent Water Supply Systems under Water Scarcity. **Journal of Water Resources Planning and Management**, v. 150, n. 3, 2024.

AZEVEDO NETTO, J.; FERNANDEZ, M. F.; ARAÚJO, R. **Manual de Hidráulica**. 8 ed. São Paulo: Editora Edgard Blücher, 1998.

BARDANACHVILI, C. A. **Otimização Multiobjetivo com Estratégias Evolutivas Aplicada a Projetos Estruturais**. 2006. 104 f. Tese (Doutorado em Ciências em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. Neurônios e Glia. In: ZANCAN, D. M.; DALMAZ, C. **Neurociências: desvendando o sistema nervoso**. 4 ed. Porto Alegre: Artmed, 2017.

BECKONERT, O.; MONNERJAHN, J.; BONK, U.; LEIBFRITZ, D. Visualizing metabolic changes in breast-cancer tissue using ^1H -NMR spectroscopy and self-organizing maps. **NMR in Biomedicine**, v. 16, n. 1, p. 1-11, 2003.

BLANK, J.; DEB, K. Pymoo: Multi-objective optimization in python. **IEEE Access**, v. 8, 2020.

BRASIL. Ministério do Desenvolvimento Regional. Secretaria Nacional de Saneamento – SNS. **Sistema Nacional de Informações sobre Saneamento: 25º Diagnóstico dos Serviços de Água e Esgotos** – 2019. Brasília: SNS/MDR, 2020. 183 p.: il.

BRENTAN, B. M.; MEIRELLES, G.; LUVIZOTTO JR., E.; IZQUIERDO, J. Hybrid SOM+k-Means clustering to improve planning, operation and management in water distribution systems. **Environmental Modelling & Software**, v. 106, 2018a.

BRENTAN, B.; CAMPBELL, E.; GOULART, T.; MANZI, D.; MEIRELLES, G.; HERRERA, M.; IZQUIERDO, J.; LUVIZOTTO JR., E. Social Network Community Detection and Hybrid Optimization for Dividing Water Supply into District Metered Areas. **Journal of Water Resources Planning and Management**, v. 144, n. 5, 2018b.

BRENTAN, B. M.; CARPITELLA, S.; IZQUIERDO, J.; LUVIZOTTO JR., E.; MEIRELLES, G. District metered area design through multicriteria and multiobjective optimization. **Mathematical Methods in the Applied Sciences**, v. 45, n. 6, p. 3254-3271, 2022.

BOSSEL, H. **Modeling and simulation**. AK Peteres/CRC Press, 2018.

BUI, X. K.; MARLIM, M. S.; KANG, D. Water Network Partitioning into District Metered Areas: A State-Of-The-Art Review. **Water**, v. 12, n. 4, p. 1002, 2020.

CHAGAS, E. M. P.; RODRIGUES, D. L.; TAVARES, J. M. R. S. Método de segmentação de objectos em imagens baseado em contornos activos e algoritmo genético. In: **CMNE 2009 (Congreso de Métodos Numéricos en Ingenieria)**. 2009.

COSTA, J. A. F. **Classificação Automática e Análise de Dados por Redes Neurais Auto-Organizáveis**. 1999. 359 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1999.

COSTA, J. A. F.; ANDRADE NETTO, M. L. Segmentação de mapas auto-organizáveis com espaço de saída 3-D. **Sba: Controle & Automação Sociedade Brasileira de Automática**, v. 18, p. 150-162, 2007.

COSTA, L. H. M.; FROTA, A. F. **Tutorial da ferramenta Toolkit do Epanet para programadores**. XIV Simpósio Ítalo-Brasileiro de Engenharia Sanitária e Ambiental, Associação Brasileira de Engenharia Sanitária e Ambiental, 2018.

COSTA, E. L. R. Mapas auto-organizáveis aplicados à análise de poluentes atmosféricos. 2022. 94f. Dissertação (Mestrado em Engenharia Elétrica e de Computação). Universidade Federal do Rio Grande do Norte, Natal, 2022.

COSTA, E. L. R.; BRAGA, T.; DIAS, L. A.; ALBUQUERQUE, E. L.; FERNANDES, M. A. C. Self-organizing maps applied to the analysis and identification of characteristics related to air quality monitoring stations and its pollutants. **Neural Computing and Applications**, 2024.

DE PAOLA, F.; GALDIERO, E.; GIUGNI, M. Location and Setting of Valves in Water Distribution Networks Using a Harmony Search Approach. **Journal of Water Resources Planning and Management**, v. 143 n. 6, 2017.

DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II. **IEEE transactions on evolutionary computation**, v. 6, n. 2, p. 182-197, 2002.

DEBOECK, Guido; KOHONEN, Teuvo (Ed.). **Visual explorations in finance: with self-organizing maps**. Springer Science & Business Media, 1998.

DIAO, K.; ZHOU, Y.; RAUCH, W. Automated creation of District Metered Areas boundaries in Water Distribution Systems. **Journal of Water Resources Planning and Management**, v. 139, n. 2, 2012.

DI NARDO, A.; DI NATALE, M.; GIUDICIANNI, C.; GRECO, R.; SANTONASTASO, G. F. Weighted spectral clustering for water distribution network partitioning. **Applied Network Science**, v. 2, n. 19, 2017.

DI NARDO, A.; SANTONASTASO, G. F. Innovative methods for optimal design of water network partitioning. In: **Embracing Analytics in the Drinking Water Industry**. IWA Publishing, 2022. p. 237-254, 2022.

EBBELS, T. M. D. Non-linear methods for the analysis of metabolic profiles. In: **The Handbook of Metabonomics and Metabolomics**. Elsevier Science BV, 2007. p. 201-226.

FARLEY, M. **Leakage management and control: A best practice training manual**. World Health Organization: Geneva, Switzerland, 2001.

FERNANDES, F. R. S. **Uma nova abordagem para o Problema da Patrulha Escolar: formulação matemática e metaheurísticas**. 2019. 124 f. Dissertação (Mestrado em Programa de Pós-Graduação em Ciência da Computação) – Universidade do Estado do Rio Grande do Norte, Mossoró, 2019.

FERREIRA, B.; ANTUNES, A.; CARRIÇO, N.; COVAS, D. NSGA-II parameterization for the optimal pressure sensor location in water distribution networks. **Urban Water Journal**, v. 20, n. 6, p. 738-750, 2023.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes Neurais Artificiais: Princípios Básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016.

FRITZ, R. T.; GIMENES, J. C.; PINA FILHO, A. C. Um estudo da automação para redução de perdas na rede de distribuição de água. **Brazilian Journal of Development**, v. 6, n. 8, p. 56408–56416, 2020.

FU, M.; RONG, K.; HUANG, Y.; ZHANG, M.; ZHENG, L.; ZHENG, J.; FALAH, M. W.; YASEEN, Z. M. Graph neural network for integrated water network partitioning and dynamic district metered areas. **Scientific Reports**, v. 12, n. 1, 2022.

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

GERMANOPOULOS, G.; JOWITT, P. W. Leakage reduction by excess pressure minimization in a water supply network. **Proceedings of the Institution of Civil Engineers**, v. 87, n. 2, p. 195-214, 1989.

GIUSTOLISI, O.; CILIBERTI, F. G.; BERARDI, L.; LAUCELLI, D. B. Leakage Management Influence on Water Age of Water Distribution Networks. **Water Resources Research**, v. 59, n. 1, p. 1–18, 2023.

GOLDBERG, D. E. **Genetic Algorithms in Search Optimization and Machine Learning**. United States of America: Addison-Wesley Publishing Company, Inc, 1989.

GONÇALVES, M. L.; ANDRADE NETTO, M. L.; COSTA, J. A. F. Explorando as Propriedades do Mapa Auto-organizável de Kohonen na Classificação de Imagens de Satélite. **VI Encontro Nacional de Inteligência Artificial (SBC ENIA)**, 2007.

GREFENSTETTE, J. J. Optimization of Control Parameters for Genetic Algorithms. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC-16, n. 1, p. 122-1228, 1986.

HAYKIN, S. **Neural networks and learning machines**. 3 ed. Pearson, 2009.

JEVTIĆ, M.; MLADENović, S.; GRANIĆ, A. Source Code Analysis in Programming Education: Evaluating Learning Content with Self-Organizing Maps. **Applied Sciences**, v. 13, n. 9, p. 5719, 2023.

JONG, K. Adaptive System Design: A Genetic Algorithm. **IEEE Transactions on Systems, Man and Cybernetics**, v. 10, n. 9, p. 566-574, 1980.

KIND, M. C.; BRUNNER, R. J. SOMz: photometric redshift PDFs with self-organizing maps and random atlas. **Monthly Notices of the Royal Astronomical Society**, v. 438, n. 4, p. 3409-3421, 2013.

KIRAN, G. U.; VASUMATHI, D. Predicting Parkinson's disease using extreme learning measure and principal component analysis based Mini SOM. **Annals of the Romanian Society for Cell Biology**, p. 16099-16111, 2021.

KITANI, E. C. **Mapeamento e visualização de dados em alta dimensão com mapas auto-organizados**. 2013. 181 f. Tese (Doutorado em Ciências) – Departamento de Engenharia de Sistemas Eletrônicos, Escola Politécnica da Universidade São Paulo, São Paulo, 2013.

KIVILUOTO, K. Topology preservation in self-organizing maps. In: **Proceedings of International Conference on Neural Networks (ICNN'96)**. IEEE, p. 294-299, 1996.

KOHONEN, T. Essentials of the Self-organizing map. **Neural Networks**, v. 37, p. 52-65, 2013.

KOHONEN, T. Self-Organized Formation of Topologically Correct Feature Maps. **Biological Cybernetics**, v. 43, n. 1, p. 59-69, 1982.

KOHONEN, T. The Self-Organizing Map. **Proceedings of the IEEE**, v. 78, n. 9, p. 1464-1480, 1990.

KOHONEN, T. The self-organizing map. **Neurocomputing**, v. 21, n. 1-3, p. 1-6, 1998.

KOHONEN, T. **Self-organizing maps**. 3 ed. Berlim: Springer, 2001.

KOHONEN, T.; KASKI, S.; LAGUS, K.; SALOJARVI, J.; HONKELA, J.; PAAERO, V.; SAARELA, A. Self Organization of a Massive Document Collection. **IEEE Transactions on Neural Networks**, v. 11, n. 3, p. 574-585, 2000.

KOIVULA, K.; SHAMSUZZOHA, A.; SHAMSUZZAMAN, M. Application of artificial intelligence as a knowledge creation instrument in tax procedures. **Engineering Applications of Artificial Intelligence**, v. 133, 2024.

KOWALSKA, B.; SUCHORAB, P.; KOWALSKI, D. Division of district metered areas (DMAs) in a part of water supply network using WaterGEMS (Bentley) software: a case study. **Applied Water Science**, v. 12, n. 166, 2022.

KRENKER, A.; BEŠTER, J.; KOS, A. **Introduction to the artificial neural networks. Artificial Neural Networks: Methodological Advances and Biomedical Applications**. InTech, p. 1-18, 2011.

KROGH, A. What are artificial neural networks? **Nature Biotechnology**, v. 26, n. 2, 2008.

KYRIAKOU, M. S.; DEMETRIADES, M.; VRACHIMIS, S. G.; ELIADES, D. G.; POLYCARPOU, M. M. EPyT: An EPANET-Python Toolkit for Smart Water Networks Simulations. **The Journal of Open Source Software**, v. 8, n. 92, 2023.

LARA, L. L. D.; SILVA, F. G. B.; SILVA, A. T. Y. L.; MARQUES, S. M.; BARBEDO, M. D. G.; REIS, A. T. Proposal of a methodology for adjusting hydraulic parameters and pressures using variations of genetic algorithm operators for optimization and reduction of losses in water distribution networks. **Engenharia Sanitaria e Ambiental**, v. 29, 2024a.

LARA, L. L. D.; SILVA, F. G. B.; SILVA, P. M. G.; ALVES, S. C. R.; MARQUES, S. M.; SILVA, A. T. Y. L.; BARBEDO, M. D. G. Análise comparativa de agrupamento de nós para setorização de rede de distribuição de água utilizando Mapas de Kohonen hexagonais e retangulares. In: **II FluHidros - Simpósio Nacional de Mecânica dos Fluidos e Hidráulica**, 2., 2024. Curitiba. Anais [...] Curitiba: ABRH, 2024b, 8p.

LARA, L. L. D.; SILVA, F. G. B.; SILVA, A. T. Y. L.; BARBEDO, M. D. G.; MARQUES, S. M.; BRITO, G. G. Agrupamento de nós da rede Hanoi visando a setorização utilizando mapas auto-organizáveis: variações na taxa de aprendizado. In: **I Congresso Nacional da Associação Brasileira de Engenharia Hídrica**, 2024. Itajubá. Anais [...] Itajubá: Even3, 2024c, 11p.

LARA, L. L. D.; SILVA, F. G. B.; SILVA, P. M. G.; ALVES, S. C. R.; MARQUES, S. M.; SILVA, A. T. Y. L.; BARBEDO, M. D. G. Desempenho de mapas auto-organizáveis em agrupamento de nós de diferentes redes de distribuição de água visando a setorização. In: **II FluHidros - Simpósio Nacional de Mecânica dos Fluidos e Hidráulica**, 2., 2024. Curitiba. Anais [...] Curitiba: ABRH, 2024d, 8p.

LAROSE, D. T. **Discovering Knowledge in Data: An Introduction to Data Mining**. Wiley-IEEE Press, 2004.

LAROSE, D. T.; LAROSE, C. D. **Discovering knowledge in data: an introduction to data mining**. 2 ed. New Jersey: John Wiley & Sons, Inc., 2014.

LIN, W-Y; LEE, W-Y; HONG, T-P. Adapting Crossover and Mutation Rates in Genetic Algorithms. **Journal of Information Science and Engineering**, v. 19, n. 5, p. 889-903, 2003.

LUDERMIR, T. B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v. 35, n. 101, p. 85-94, 2021.

MACHADO, T. M.; LOIOLA, R. R.; DEBONI, M. H. L.; NEVES, C. E. V. **Mapas auto-organizáveis Kohonen para reconhecimento de padrões: uma aplicação à segmentação de mercado.** 2007. Disponível em: <https://www.researchgate.net/profile/Taylor-Machado/publication/305848206_MAPAS_AUTO-ORGANIZAVEIS_KOHONEN_PARA_RECONHECIMENTO_DE_PADROES_UMA_APLICACAO_A_SEGMENTACAO_DE_MERCADO/links/57a3714a08ae3f4529227fc3/MAPAS-AUTO-ORGANIZAVEIS-KOHONEN-PARA-RECONHECIMENTO-DE-PADROES-UMA-APLICACAO-A-SEGMENTACAO-DE-MERCADO.pdf>. Acesso em: 18 jun. 2024.

MAHALA, G.; SINDHGATTA, R.; DAM, H. K.; GHOSE, A. Multi-objective evolutionary search for optimal Robotic Process Automation architectures. **IEEE Transactions on Services Computing**, 2024.

MAHARDINI, I. R.; TANGAHU, B. V. Water Distribution System Management in District Metered Area (DMA) Kalipuro 5. **Asian Journal of Engineering, Social and Health**, v. 2, n. 10, p. 1179-1195, 2023.

MAHESH, B. Machine Learning Algorithms - A Review. **International Journal of Science and Research**, v. 9, n. 1, p. 381-386, 2020.

MARIA, A. Introduction to modeling and simulation. In: **Proceedings of the 29th conference on Winter simulation.** 1997. p. 7-13.

MARIM, M. C.; OLIVEIRA, A. M.; VILLELA, S. M. UFJF-MLTK: um framework para algoritmos de aprendizado de máquina. In: **Anais do XV Simpósio Brasileiro de Sistemas de Informação.** SBC, 2019. p. 495-502.

MARLIM, M. S.; KANG, D. Application of multiple pressure management strategies in urban water distribution networks using sequential optimization. **Sustainable Cities and Society**, v. 102, 2024.

MARQUES, S. M. **Aplicação de algoritmos genéticos em operação de redes de distribuição de água com o uso de softwares R e EPANET visando ao controle de perdas de água – estudo em uma rede teórica**. 2023. 94 f. Dissertação (Mestrado em Meio Ambiente e Recursos Hídricos) – Instituto de Recursos Naturais, Universidade Federal de Itajubá, Itajubá, 2023.

MARQUES, S. M.; SILVA, F. G. B.; SILVA, A. T. Y. L.; BARBEDO, M. D. G.; ALVES, S. C. R.; LARA, L. L. D. Aplicação de metodologia para ajuste de pressões em redes de distribuição de água utilizando EPANET e R associados visando controle de perdas. XXV Simpósio Brasileiro de Recursos Hídricos, 2023a.

MARQUES, S. M.; SILVA, F. G. B.; SILVA, A. T. Y. L.; BARBEDO, M. D. G.; MARCONDES, M. C.; ALVES, S. C. R.; REIS, J. A. T. Evaluation of hydraulic behavior of water distribution network varying reservoirs levels, roughness, and diameters with the use of R and EPANET. *Revista Ambiente & Água*, v.18, e2893, 2023b.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115–133, 1943.

MEDIO, G.; VARRA, G.; INAN, Ç. A.; COZZOLINO, L.; MORTE, R. D. Sinkhole Risk-Based Sensor Placement for Leakage Localization in Water Distribution Networks with a Data-Driven Approach. *Sustainability*, v. 16, n. 12, 2024.

MELO, D. S.; GONTIJO, E. S. J.; FRASCARELI, D.; SIMONETTI, V. C.; MACHADO, L. S.; BARTH, J. A. C.; MOSCHINI-CARLOS, V.; POMPÊO, M. L.; ROSA, A. H.; FRIESE, K. Self-Organizing Maps for Evaluation of Biogeochemical Processes and Temporal Variations in Water Quality of Subtropical Reservoirs, *Water Resources Research*, v. 55, n. 12, p. 10268-10281, 2019.

MOSETLHE, T. C.; HAMAM, Y.; DU, S.; MONACELLI, E. Appraising the Impact of Pressure Control on Leakage Flow in Water Distribution Networks. *Water*, v. 13, n. 19, 2021.

MUHAMMAD, G.; SAEED, U. ISLAM, N.; KUMAR, K.; HUSSAIN, F.; KHUHRO, M. A.; SHAIKH, A. A.; ALI, I. Gvdeepnet: Unsupervised deep learning techniques for effective genetic variant classification. *Pakistan Journal of Engineering and Technology*, v. 5, n. 1, p. 16-22, 2022.

MUHAMMETOGLU, A.; KARADIREK, E.; OZEN, O.; MUHAMMETOGLU, H. Full-scale PAT application for energy production and pressure reduction in a water distribution network. **Journal of Water Resources Planning and Management**, v. 143, n. 8, p. 1–12, 2017.

NANDA, R. E.; PRABOWO, Y. D. Pengembangan Model Pembelajaran Mesin untuk Klasifikasi Citra Lukisan Menggunakan Self-Organizing Map dengan Library Minisom. **KALBISIANA Jurnal Sains, Bisnis dan Teknologi**, v. 8, n. 1, p. 357-365, 2022

NATITA, W.; WIBOONSAK, W.; DUSADEE, S. Appropriate Learning Rate and Neighborhood Function of Self-organizing Map (SOM) for Specific Humidity Pattern Classification over Southern Thailand. **International Journal of Modeling and Optimization**, v. 6, n. 1, 2016.

NAWIK, M.; CHITTALADAKORN, S.; PILAILAR, S. DMA Characteristic Identification for Efficient Water Loss Management: Case Study of MWA Pipe Network, Thailand. **KSCE Journal of Civil Engineering**, p. 1-13, 2024.

NOVARIANI, B.; BRENTAN, B. M.; MEIRELLES, G.; LUVIZOTTO JR., E. Optimal pressure management in water distribution networks through district metered area creation based on machine learning. **Brazilian Journal of Water Resources**, v. 24, e. 37, 2019.

PEARSON, D. **Standard Definitions for Water Losses**. Londres, UK: IWA Publishing, 2019.

PORTO, R. M. **Hidráulica Básica**. 4 ed. São Carlos: EESC – USP, 2006.

RAHMAM, N. A.; MUHAMMAD, N. S.; MOHTAR, W. H. M. W. Evolution of research on water leakage control strategies: where are we now? **Urban Water Journal**, v. 15, n. 8, p. 812-826, 2018.

RAHMATBAKHSH, M.; GAGARINOVA, A.; BABU, M. Bioinformatic Analysis of Temporal and Spatial Proteome Alternations During Infections. **Frontier in Genetics**, v. 12, 2021.

RECA, J; MARTÍNEZ, J. Genetic algorithms for the design of looped irrigation water distribution networks. **Water Resources Research**, v. 42, 2006.

RIDLEY, W. F. **Leakage control policy and practice**. London: Technical Working Group on Waste in Water, National Water Council, 1980.

RONG, K.; FU, M.; HUANG, Y.; ZHANG, M.; ZHENG, L.; ZHENG, J.; SCHOLZ, M.; YASEEN, Z. M. Graph attention neural network for water network partitioning. **Applied Water Science**, v.13, n. 1, 2023.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.

SAHA, C.; BARUAH, N.; NAYAK, S. K. Implementation of self-organizing map and logistic regression in dissolved gas analysis of transformer oils. In: **2021 IEEE International Conference on the Properties and Applications of Dielectric Materials (ICPADM)**. IEEE, 2021. p. 131-134.

SALDARRIAGA, J.; BOHORQUEZ, J.; CELEITA, D.; VEGA, L.; PAEZ, D.; SAVIC, D.; DANDY, G.; FILION, Y.; GRAYMAN, W.; KAPELAN, Z. Battle of the Water Networks District Metered Areas. *Journal of Water Resources. Planning and Management*, v. 145, n. 4, 2019.

SERAFFEIM, A. V.; FOURNIOTIS, N. T.; DEIDDA, R.; KOKOSALAKIS, G.; LANGOUSIS, A. Leakages in Water Distribution Networks: Estimation Methods, Influential Factors, and Mitigation Strategies — A Comprehensive Review. **Water**, v. 16, n. 11, 2024.

SHARMA, A. N.; DONGRE, S. R.; GUPTA, R.; ORMSBEE, L. Multiphase Procedure for Identifying District Metered Areas in Water Distribution Networks Using Community Detection, NSGA-III Optimization, and Multiple Attribute Decision Making. **Journal of Water Resources Planning and Management**, v. 148, n. 8, 2022.

SHARMA, A. N.; DONGRE, S. R.; GUPTA, R. Many-objective optimisation tool for the design of district metered areas in pumped water distribution networks. **Water Supply**, v. 23, n. 9, p. 3789-3804, 2023.

SHEKOFTEH, M. R.; JALILI GHAZIZADEH, M. R.; YAZDI, J. Theoretical identification of leakage areas in virtual district metered areas of water distribution networks using the artificial neural network. **Iran-Water Resources Research**, v. 16, n. 3, p. 47-62, 2020.

SHEKOFTEH, M. R.; YOUSEFI-KHOSHQALB, E.; PIRATLA, K. R. An Efficient Approach for Partitioning Water Distribution Networks Using Multi-Objective Optimization and Graph Theory. **Water Resources Management**, v. 37, 2023.

SHIELD, S. A.; HOUSTON, A. L. Spatiotemporal characteristics of deep convection initiation in the Central United States. **International Journal of Climatology**, 2024.

SILVA, A. T. Y. L. **Aplicação de Redes Neurais Multicamadas Associadas a Algoritmos Genéticos Aplicadas a Operação de Redes de Distribuição de Água com Vistas a Eficiência Hidroenergética em Cidades Inteligentes**. 2023. 109 f. Tese (Doutorado em Meio Ambiente e Recursos Hídricos) – Instituto de Recursos Naturais, Universidade Federal de Itajubá, Itajubá, 2023.

SILVA, A. T. Y. L. **Proposição de estratégia operacional ótima em rede de distribuição de água**. 2019. 81 f. Dissertação (Mestrado em Meio Ambiente e Recursos Hídricos) – Instituto de Recursos Naturais, Universidade Federal de Itajubá, Itajubá, 2019.

SILVA, A. T. Y. L.; SILVA, F. G. B.; SILVA, A. C.; REIS, J. A. T.; FREITAS, C. L.; VALÉRIO, V. E. M. Proposal of optimal operation strategy applied to water distribution network with statistical approach. **Revista Ambiente & Água**, v. 15, 2020.

SILVA, F. G. B. **Estudos de calibração de redes de Distribuição de água através de Algoritmos Genéticos**. Tese de Doutorado apresentada a Universidade de São Paulo, Campus de São Carlos. São Carlos, 2003.

SINGH, V. P. **Elementary Hydrology**. Prentice-Hall: Upper Saddle River, NJ, USA, 1992.

SINGH, V. P. **Handbook of Applied Hydrology**. 2 ed. New York: McGraw-Hill Education, 2017.

SISTEMA NACIONAL DE INFORMAÇÕES SOBRE SANEAMENTO. SNIS. **Diagnóstico Temático serviços de Água e Esgoto – Visão geral ano de referência 2022**. Ministério das Cidades – Secretaria Nacional de Saneamento Ambiental, Brasília – DF, 2023.

SITZENFREI, R.; QIU, M.; OSTFELD, A.; SAVIC, D.; KAPELAN, Z. A Hybrid Approach for Considering Topography in Graph-Based Optimization of Water

Distribution Networks. In: **World Environmental and Water Resources Congress 2023**. p. 831-841, 2023.

SRINIVAS, M.; PATNAIK, L. M. Adaptative Probabilities of Crossover and Mutation in Genetic Algorithms. **IEEE Transactions on Systems, Man and Cybernetics**, v. 24, n. 4, p. 656-667, 1994.

SRINIVAS, N.; DEB, K. Multiobjective Optimization Using Nondominated Sorting in Genetic Algorithms. **Evolutionary Computation**, v. 2, n.3, p. 221-248, 1994.

STEFANOVIČ, P.; KURASOVA, O. Influence of learning rates and neighboring functions on self-organizing maps. In: **Advances in Self-Organizing Maps: 8th International Workshop**, WSOM 2011, Espoo, Finland, June 13-15, 2011. Proceedings 8. Springer Berlin Heidelberg, 2011. p. 141-150.

TARDELLI FIHO, J. Aspectos relevantes do controle de perdas em sistemas públicos de abastecimento de água. **Revista DAE**, v. 64, n. 201, p. 6-20, 2016.

TCHÓRZEWSKA-CIEŚLAK, B.; SZPAK, D.; ZYWIEC, J.; ROZNOWSKI, M. The concept of estimating the risk of water losses in the water supply network. **Journal of Environmental Management**, v. 359, 2024.

TSUTIYA, M. T. **Abastecimento de água**. 3 ed. Departamento de Engenharia Hidráulica e Sanitária da Escola Politécnica da Universidade de São Paulo: São Paulo, 2006.

VARGAS, D. E. C. Um estudo dos parâmetros do algoritmo NSGA-II com o operador SBX em problemas de otimização estrutural multiobjetivo. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 6, n. 2, 2018.

VEER, S.; KHANDVE, S.; PAWAR, Y.; MARALE, K.; WAGHULE, A. Design Water Supply Network Using Epanet Software. **International Journal for Research in Applied Science & Engineering Technology (IJRASET)**, v. 10, n.12, p. 108-112. 2022.

VELIČKOVIĆ, P.; CUCURULL, G.; CASANOVA, A.; ROMERO, A.; LIÒ, P.; BENGIO, Y. Graph attention networks. In **International Conference on Learning Representations**, 2018.

VESANTO, J.; ALHONIEMI, E. Clustering of the Self-Organizing Map. **IEEE Transactions on Neural Networks**, v. 11, n. 3, 2000.

VESANTO, J.; HIMBERG, J.; ALHONIEMI, E.; PARHANKANGAS, J. Self-Organizing Map in Matlab: the SOM Toolbox. In: **Proceedings of the Matlab DSP conference**, 2000.

VETTIGLI, G. **MiniSom**: minimalistic and Numpy-based implementation of the Self Organizing Map, 2018. Disponível em: < <https://github.com/JustGlowing/minisom/>>. Acesso em: 26 mar. 2024.

WEI, R.; LV, L.; HUANG, X.; WENG, J. DMA Partitioning Method for Water Supply Network Based on Density Peak Optimized Spectral Clustering. **Journal of Network Intelligence**, v. 8, n. 1, p. 157-167, 2023.

YAO, H.; ZHANG, T.; SHAO, Y.; YU, T.; LIMA NETO, I. E. Improved modularity-based approach for partition of water distribution networks. **Urban Water Journal**, v. 18, n. 2, p. 69-78, 2020.

YU, T.; ZHANG, X.; LONG, Z.; ZHOU, H.; LIU, X. Optimal design of district metered areas based on improved particle swarm optimization method for water distribution systems. **Water Supply**, v. 22, n. 11, p. 7930-7944, 2022.

ZEIDAN, M.; LI, P.; OSTFELD, A. DMA segmentation and multiobjective optimization for trading off water age, excess pressure, and pump operational cost in water distribution systems. **Journal of Water Resources Planning and Management**, v. 147, n. 4, 2021.

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, Q.; WU, Z. Y.; ZHAO, M.; QI, J.; HUANG, Y.; ZHAO, H. Automatic Partitioning of Water Distribution Networks Using Multiscale Community Detection and Multiobjective Optimization. **Journal of Water Resources Planning and Management**, v. 143, n. 9, 2017.


ZHANG, T.; YAO, H.; CHU, S.; YU, T.; SHAO, Y. Optimized DMA partition to reduce background leakage rate in water distribution networks. **Journal of Water Resources Planning and Management**, v. 147, n. 10, 2021.

ZINI, E. O. C. **Algoritmo Genético Especializado na Resolução de Problemas com Variáveis Contínuas e Altamente Restritos**. 2009. 149 f. Dissertação (Mestrado em


Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, 2009.

APÊNDICES


APÊNDICE A – MAPAS E GRÁFICOS RESULTANTES DO AJUSTE FINO FEITO NAS CONFIGURAÇÕES C06 E C10




(a) SOM – C06 com 1.000.000 de épocas




(b) EQ e ET – C06 com 1.000.000 de épocas




(c) SOM – C06 com 5.000.000 de épocas




(d) EQ e ET – C06 com 5.000.000 de épocas




(e) SOM – C10 com 200.000 de épocas




(f) EQ e ET – C10 com 200.000 de épocas




(g) SOM – C10 com 1.000.000 de épocas



(h) EQ e ET – C10 com 1.000.000 de épocas



(i) SOM – C10 com 5.000.000 de épocas



(j) EQ e ET – C10 com 5.000.000 de épocas