



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

**JOSÉ ELOIM SILVA DE MACÊDO**

**DIMENSIONAMENTO ÓTIMO DE SISTEMAS DE DISTRIBUIÇÃO  
DE ÁGUA VIA *PARTICLE SWARM OPTIMIZATION***

Caruaru  
2018

JOSÉ ELOIM SILVA DE MACÊDO

**DIMENSIONAMENTO ÓTIMO DE SISTEMAS DE DISTRIBUIÇÃO DE ÁGUA  
VIA *PARTICLE SWARM OPTIMIZATION***

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro Acadêmico do Agreste Ambiental da Universidade Federal de Pernambuco, como cumprimento às exigências para obtenção do título de Mestre em Engenharia Civil e Ambiental.

Área de Concentração: Tecnologia Ambiental.

Orientador: Prof. Dr. Saulo de Tarso Marques Bezerra

Caruaru  
2018

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

M141d Macêdo, José Eloim Silva de  
Dimensionamento ótimo de sistemas de distribuição de água via particle swarm  
optimization. / José Eloim Silva de Macêdo. - 2018.  
90 f.; il.: 30 cm.

Orientador: Saulo de Tarso Marques Bezerra.  
Dissertação (Mestrado) – Universidade Federal de Pernambuco, CAA, Programa de  
Pós-Graduação em Engenharia Civil e Ambiental, 2018.  
Inclui Referências.

1. Otimização matemática. 2. Algoritmos. 3. Água - Distribuição. 4. Água –  
Qualidade (geo). 5. Engenharia de abastecimento de água (geo). I. Bezerra, Saulo de  
Tarso Marques (Orientador). II. Título.

620 CDD (23. ed.)

UFPE (CAA 2018-051)

JOSÉ ELOIM SILVA DE MACÊDO

**DIMENSIONAMENTO ÓTIMO DE SISTEMAS DE DISTRIBUIÇÃO DE ÁGUA  
VIA *PARTICLE SWARM OPTIMIZATION***

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

Aprovada em 15/06/2018.

**BANCA EXAMINADORA**

---

Prof<sup>o</sup>. Dr. Saulo de Tarso Marques Bezerra (Orientador)  
Universidade Federal de Pernambuco

---

Prof<sup>o</sup>. Dr. José Roberto Gonçalves de Azevedo (Examinador Externo)  
Universidade Federal de Pernambuco

---

Prof<sup>a</sup>. Dra. Maísa Mendonça Silva (Examinador Externo)  
Universidade Federal de Pernambuco

---

Prof<sup>o</sup>. Dr. Allan Sarmiento Vieira (Examinador Externo)  
Universidade Federal de Campina Grande

## AGRADECIMENTOS

Primeiramente, a **Deus**, por sua presença constante em minha vida, pelas oportunidades colocadas em minha vida, por ter-me iluminado e dado tranquilidade para seguir em frente com os meus objetivos e para não desanimar com as dificuldades na realização deste trabalho.

Agradeço à minha mãe e minha avó (em memória), pela dedicação de uma vida toda e por serem as principais responsáveis pelos meus estudos, assim como de todas as conquistas que obtive na minha vida.

Dedico e agradeço à minha esposa, Jéssica Vasconcelos de Lacerda, pelos dias de compreensão, noites de sono cuidando de nosso filho e grande apoio para realização deste trabalho.

A todos os meus familiares, em especial a minha irmã Sofia, pelo exemplo de sucesso e sabedoria que tem sido sempre pra mim.

Agradeço ao meu orientador Saulo de Tarso Marques Bezerra pelos conhecimentos compartilhados, pela sua disposição a me atender em suas horas de descanso e lazer, e pela paciência nesse período de estudo.

A todos que de forma direta ou indireta contribuíram para a realização deste trabalho.

## RESUMO

A otimização de sistemas de distribuição de água tem recebido atenção especial de projetistas e pesquisadores da área de recursos hídricos devido, principalmente, aos altos custos de implantação e operação. Não existe um método de otimização que resolva eficientemente todos os tipos de problemas, e é por isso que, ao longo do tempo, pesquisadores têm desenvolvido várias técnicas de busca com diversos algoritmos matemáticos. Nas últimas décadas, a classe de algoritmos evolucionários, inspirados na inteligência coletiva proveniente da auto-organização e do comportamento adaptativo da sociedade de certos animais, vem se destacando por apresentar bons resultados. No entanto, a questão da baixa eficiência computacional da maioria dos algoritmos dificulta a aplicação desses em problemas reais de grande porte. Essa pesquisa objetiva o desenvolvimento de um novo modelo de otimização, fundamentando no algoritmo *Particle Swarm Optimization* – PSO, para o dimensionamento de quaisquer redes de distribuição de água. O PSO modificado foi aplicado em exemplos de referência, que incluem redes de distribuição reais de grande porte, obtendo bons resultados na busca de solução ótima e elevado desempenho computacional.

Palavras-chave: Problemas de otimização. Algoritmos evolucionários. Epanet.

## **ABSTRACT**

The optimization of water distribution systems has received special attention from designers and researchers in the area of water resources due, mainly, to the high costs of implementation and operation. There is not optimization method that solves all kinds of problems efficiently, and this is why, over time, researchers have developed several search techniques with several mathematical algorithms. In the last decades, evolutionary algorithms, based on collective intelligence proven of the self-organization and the adaptive behavior of the society of certain animals, have been emphasizing in the environment academic for presenting good results. However, the question of the low computational efficiency of most algorithms makes it difficult to apply large real problems. This research aims at the development of a model based on the technique of Particles Swarm Optimization – PSO for the design of any water distribution systems. The modified PSO algorithm was applied in reference examples, which include large real distribution networks, obtaining good results in the search for optimal solution and high computational performance.

**Keywords:** Optimization problems. Evolutionary algorithms. Epanet.

## LISTA DE FIGURAS

Figura 1 – Representação de uma rede ramificada.....	21
Figura 2 – Representação de uma rede malhada. ....	22
Figura 3 – Topologias (a) Global e (b) Local.....	38
Figura 4 – Processo iterativo entre o modelo de otimização e o simulador hidráulico. ....	47
Figura 5 – Comunicação ente partículas na Topologia Local-Global.....	52
Figura 6 – Layout do <i>Hanoi Network problem</i> . ....	56
Figura 7 – Layout do <i>New York Tunnels problem</i> .....	66
Figura 8 – <i>New York Tunnels problem</i> Dimensionada (Ampliação).....	71
Figura 9 – <i>Balerma Network</i> . ....	72
Figura 10 – Cotas e Demandas nodais na <i>Balerma Network</i> .....	73
Figura 11 – Diâmetros e pressões nodais da <i>Balerma Network</i> pelo PSO-TG. ....	74
Figura 12 – Diâmetros e pressões nodais da <i>Balerma network</i> pelo PSO-TL.....	75
Figura 13 – Diâmetros e pressões nodais da <i>Balerma network</i> pelo PSO-TLG.....	75

## **LISTA DE FLUXOGRAMAS**

Fluxograma 1 – Fluxograma básico para o algoritmo PSO com Topologia Global. ....	38
Fluxograma 2 – Fluxograma básico para o algoritmo PSO com Topologia Local. ....	39
Fluxograma 3 – Composição da solução inicial. ....	50
Fluxograma 4 – Fluxograma básico do algoritmo PSO-TLG. ....	53

## LISTA DE GRÁFICOS

Gráfico 1 – Análise da influência do número de partículas no custo ótimo. ....	59
Gráfico 2 – Análise de proporção entre o número de partículas sob topologias Local e Global. ....	60
Gráfico 3 – Evolução do custo ao longo do processo de otimização com e sem pré-seleção. ....	61
Gráfico 4 – Resultado de 100 execuções do algoritmo PSO-TLG com pré-seleção e população de 50 partículas. ....	62
Gráfico 5 – Resultado de 100 execuções do algoritmo PSO-TLG com pré-seleção e população de 100 partículas. ....	62
Gráfico 6 – Resultado de 100 execuções do algoritmo PSO-TLG com pré-seleção e população de 150 partículas. ....	62
Gráfico 7 – Evolução do custo ao longo do processo de otimização (comparativo entre topologias). ....	62
Gráfico 8 – Evolução do custo ao longo do processo de otimização (comparativo entre topologias). ....	68

## LISTA DE TABELAS

Tabela 1 – Dados referentes a <i>Hanoi Network Problem</i> . .....	57
Tabela 2 – Custo das tubulações para a <i>Hanoi Network problem</i> . .....	58
Tabela 3 – Resultados do dimensionamento ótimo da <i>Hanoi Network problem</i> (Diâm.).....	64
Tabela 4 – Comparação de dimensionamentos ótimos da literatura – Custos. ....	65
Tabela 5 – Dados referentes à <i>New York Tunnels problem</i> . .....	67
Tabela 6 – Custo das tubulações para a rede <i>New York Tunnels problem</i> . ....	67
Tabela 7 – Tempo médio do processo de otimização.....	69
Tabela 8 – Resultados do dimensionamento ótimo da <i>New York Tunnels problem</i> .....	69
Tabela 9 – Resultados das pressões resultantes nos nós da <i>New York Tunnels problem</i> . ....	70
Tabela 10 – Comparação de dimensionamentos ótimos da literatura – Custos. ....	70
Tabela 11 – Custo para a <i>Balerna Network</i> . ....	73
Tabela 12 – Comparação entre topologias – Custos e tempo médio de execução. ....	74
Tabela 13 – Comparação de dimensionamentos ótimos da literatura – Custos. ....	76

## LISTA DE ABREVIATURAS E SIGLAS

ACO	<i>Ant Colony Optimization</i> [=Otimização por Colônia de Formiga]
BCO	<i>Bee Colony Optimization</i> [=Otimização por Colônia de Abelhas]
DE	<i>Differential Evolution</i> [=Evolução Diferencial]
DLL	<i>Dynamic-Link Library</i> [= Biblioteca de Link Dinâmico]
EA	Evolutionary Algorithm [=Algoritmo Evolucionário]
EPA	<i>Environment Protection Agency</i> [= Agencia de Proteção Ambiental]
FoFo	Ferro Fundido
GA	<i>Algorithm Genetic</i> [=Algoritmo Genético]
HBMO	<i>Honey-Bee Mating Optimization</i> [=Otimização por Acasalamento de Abelhas]
HM	<i>Heuristic Method</i> [= Método Heurístico]
PRFV	Poliéster Revestido com Fibra de Vidro
PSO	<i>Particle Swarm Optimization</i> [=Otimização por Enxame de Partículas]
PSO-TG	<i>Particle Swarm Optimization</i> de Topologia Global
PSO-TL	<i>Particle Swarm Optimization</i> de Topologia Local
PSO-TLG	<i>Particle Swarm Optimization</i> de Topologia Local-Global
PVC	Policloreto de Vinila
SFLA	<i>Shuffled Frog Leaping Algorithm</i>
SS	<i>Scatter Search</i> [=Busca Dispersa]

## LISTA DE SÍMBOLOS

$C$	Coefficiente de rugosidade
$C(D, L)$	Custo do tubo de diâmetro $D$ e comprimento $L$
$c_1$	Fator social
$c_2$	Fator cognitivo
$D$	Diâmetro de uma tubulação
$D_{min}$	Diâmetro mínimo de uma tubulação
$f(p)$	Função objetivou ou <i>fitness</i>
$G_{best}$	Melhor posição no espaço de busca percorrido por alguma das partículas associada a todo o enxame
$H$	Perda de carga ao longo de uma tubulação
$k$	Fator de aceleração
$Kp$	Coefficiente de penalização
$L$	Comprimento do trecho
$N$	Número total de iterações
$n$	Número total de nós de uma rede ou número total de partículas
$N^{PSO-TG}$	Número de partículas, do total do enxame, sob topologia local
$N^{PSO-TL}$	Número de partículas, do total do enxame, sob topologia local
$N^{rep}$	Número de vezes que determinado valor ótimo se repete
$N^{total}$	Número máximo de iterações
$\phi$	Constante numérica do fator de aceleração
$p$	Pressão no nó
$P_{best}$	Melhor posição individual que cada partícula percorreu no espaço de busca
$p_{min}$	Pressão mínima requerida no mesmo nó
$PV_{best}$	Melhor posição no espaço de busca percorrido por alguma das partículas vizinha direta
$Q$	Vazão em um trecho
$Q_e$	Vazão de abastecimento ou demanda do nó
$Q_{ent}$	Vazão que está chegando ao nó
$Q_{mínima}$	Vazão mínima em um trecho
$Q_{sai}$	Vazão que sai do nó
$rand()$	Gerador randômico (valores entre 0 e 1)
$Rh$	Raio hidráulico

$S_f$	Gradiente hidráulico
$V$	Velocidade da água na tubulação
$v_{(t)}$	Velocidade da partícula em um instante $t$
$v_{(t+1)}$	Velocidade da partícula em um instante $t+1$
$V_{max}$	Velocidade máxima da partícula
$w$	Fator de inércia
$w_{fim}$	Fator de inercia final
$w_{ini}$	Fator de inercia inicial
$x_{(t)}$	Posição da partícula no tempo $t$
$x_{(t+1)}$	Posição da partícula no tempo $t+1$
$x^I$	Limites inferior da posição da partícula
$x^S$	Limites superior da posição da partícula
$\alpha$	Constante numérica de conversão na fórmula da velocidade de escoamento
$\varphi_C$	Fator cognitivo
$\varphi_S$	Fator social
$\omega$	Constante numérica de conversão na fórmula de perda de carga

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>16</b>
<b>2</b>	<b>OBJETIVOS .....</b>	<b>19</b>
2.1	OBJETIVO GERAL .....	19
2.2	OBJETIVOS ESPECÍFICOS .....	19
<b>3</b>	<b>REVISÃO BIBLIOGRÁFICA .....</b>	<b>20</b>
3.1	REDES DE DISTRIBUIÇÃO DE ÁGUA .....	20
<b>3.1.1</b>	<b>Traçado de Rede .....</b>	<b>20</b>
<b>3.1.2</b>	<b>Variáveis de Projeto .....</b>	<b>22</b>
<b>3.1.3</b>	<b>Escoamento.....</b>	<b>22</b>
<b>3.1.4</b>	<b>Tubulações.....</b>	<b>23</b>
3.2	ESTRUTURA DOS PROBLEMAS DE OTIMIZAÇÃO .....	23
<b>3.2.1</b>	<b>Projeto de otimização de redes de distribuição de água .....</b>	<b>26</b>
3.3	ALGORITMOS DE OTIMIZAÇÃO METAHEURÍSTICOS .....	29
<b>3.3.1</b>	<b><i>Genetic Algorithm (GA)</i> .....</b>	<b>29</b>
<b>3.3.2</b>	<b><i>Shuffled Frog Leaping Algorithm (SFLA)</i> .....</b>	<b>30</b>
<b>3.3.3</b>	<b><i>Ant Colony Optimization (ACO)</i>.....</b>	<b>31</b>
<b>3.3.4</b>	<b><i>Honey-Bee Mating Optimization (HBMO)</i> .....</b>	<b>31</b>
<b>3.3.5</b>	<b><i>Scatter Search (SS)</i>.....</b>	<b>32</b>
<b>3.3.6</b>	<b><i>Differential Evolution (DE)</i> .....</b>	<b>32</b>
3.4	PARTICLE SWARM OPTIMIZATION (PSO) .....	33
<b>3.4.1</b>	<b>Parâmetros .....</b>	<b>35</b>
<b>3.4.2</b>	<b>Topologia das partículas .....</b>	<b>37</b>
3.5	SIMULADOR HIDRÁULICO (EPANET 2.0 BRASIL) .....	39
3.6	ESTADO DA ARTE.....	40
<b>4</b>	<b>METODOLOGIA.....</b>	<b>47</b>
4.1	FORMULAÇÃO NUMÉRICA E PENALIZAÇÃO .....	48
4.2	PRÉ-SELEÇÃO DE PARTÍCULAS .....	49
4.3	PSO DE TOPOLOGIA LOCAL-GLOBAL (PSO-TLG).....	50
<b>4.3.1</b>	<b>Estrutura da Topologia Local-Global.....</b>	<b>51</b>
<b>4.3.2</b>	<b>Comunicação da Topologia.....</b>	<b>51</b>
<b>4.3.3</b>	<b>Algoritmo PSO com a Topologia Local-Global .....</b>	<b>52</b>

<b>5</b>	<b>RESULTADOS E DISCUSSÕES.....</b>	<b>55</b>
5.1	<i>HANOI NETWORK PROBLEM.....</i>	55
5.2	<i>NEW YORK TUNNELS PROBLEM.....</i>	65
5.3	<i>BALERMA NETWORK.....</i>	71
<b>6</b>	<b>CONCLUSÕES E RECOMENDAÇÕES .....</b>	<b>77</b>
	<b>REFERÊNCIAS.....</b>	<b>79</b>

## 1 INTRODUÇÃO

A otimização de sistemas de distribuição de água tem recebido atenção especial de projetistas e pesquisadores da área de recursos hídricos devido, principalmente, aos altos custos de implantação e operação. Pesquisadores têm aplicado algoritmos matemáticos na busca de um modelo de otimização que resolva eficientemente os diversos tipos de problemas.

Inicialmente, os métodos propostos se restringiam à seleção de diâmetros que proporcionassem o equilíbrio hidráulico das redes de distribuição de água e respeitassem as restrições impostas (GOMES *et al.*, 2009). No final da década de sessenta, a consolidação da informática nos centros de pesquisa permitiu o desenvolvimento de técnicas direcionadas ao dimensionamento otimizado de redes hidráulicas. Os primeiros algoritmos de otimização empregados eram fundamentados em técnicas de programação linear (KARMELLI; GADISH; MEYERS, 1968), programação não linear (JACOBY, 1968) e programação dinâmica (LIANG, 1971). Estas técnicas reconhecem as soluções por meio da verificação das condições de otimalidade e que, segundo destacou Zhou, Li & Gao (2013), podem resultar em soluções ruins.

As últimas décadas foram marcadas pelo surgimento dos algoritmos evolucionários: *Genetic Algorithm* – GA (SIMPSON; DANDY; MURPHY, 1994; JOHNS; KEEDWELL; SAVIC, 2014, BRAGALLI *et al.*, 2015; NAWAYSEH; JARNDAL; HAMDAN, 2017), *Shuffled Frog Leaping Algorithm* – SFLA (EUSUFF; LANSEY, 2003; MORA-MELIA *et al.*, 2015; KAUR; MEHTA, 2017), *Ant Colony Optimization* – ACO (MAIER *et al.*, 2003; WONG; MOIN, 2017; OLIVAS *et al.*, 2017), *Particle Swarm Optimization* – PSO (SURIBABU; NEELAKANTAN, 2006; AGHDAM *et al.*, 2014, ALINAGHIAN *et al.*, 2017; CHATTERJEE *et al.*, 2017), *Scatter Search* – SS (LIN *et al.*, 2007; GUO; TANG, 2015; GUO *et al.*, 2017), *Honey-Bee Mating Optimization* – HBMO (JAHANSHAHI; HADDAD, 2008; HADDAD *et al.*, 2016; SOLGI; BOZORG-HADDAD; LOÁICIGA, 2017) e *Differential Evolution* – DE (SURIBABU, 2010; ZHENG; ZECCHIN; SIMPSON, 2015; ROQUE; MARTINS, 2018). Esses métodos, conhecidos também como metaheurísticos, não fornecem garantias de que a solução obtida é a melhor possível entre as existentes, porém convergem para uma solução próxima ao ótimo global (KRIPKA; MEDEIROS, 2012).

Os algoritmos evolucionários apresentam diferentes comportamentos, cada um tem suas próprias vantagens e desvantagens, adaptando-se melhor a certos problemas do que a outros. O processo metaheurístico dos algoritmos dotam seus elementos de capacidades

específicas para resolver de forma eficiente alguns tipos de problemas, embora sejam ineficientes com outros problemas de natureza diferente (MONTALVO *et al.*, 2014).

Os algoritmos evolucionários, que são fundamentados na inteligência coletiva proveniente da auto-organização e do comportamento adaptativo da sociedade de certos animais, vêm apresentando bons resultados para o dimensionamento de sistemas de distribuição de água. Entretanto, a maioria das aplicações destes métodos considera apenas a obtenção do custo mínimo na definição de seus parâmetros, que são ajustados heurísticamente. Muitos trabalhos que envolvem dimensionamento de sistemas de distribuição de água por meio de algoritmos evolucionários buscam a “melhor” solução de custo mínimo, mas não se aprofundam em outros aspectos, tais como o impacto do ajuste de parâmetros das redes nas soluções finais, a repetitividade das soluções e o tempo computacional.

O aumento do tamanho e da complexidade de sistemas de distribuição de água resulta em desafios expressivos para a obtenção de soluções ótimas de boa qualidade em um tempo computacional aceitável. Os métodos são aplicados, geralmente, em problemas simples, como a *Two-Loop Network* (ALPEROVITS; SHAMIR, 1977), o *14-Pipe Network Expansion problem* (SIMPSON; DANDY; MURPHY, 1994), o *New York Tunnels problem* (SCHAAKE; LAI, 1969) e o *Hanoi Network problem* (FUJIWARA; KHANG, 1990).

Com base no exposto, Bi, Dandy & Maier (2015) citam que nos últimos anos há um movimento na comunidade científica para aumentar a complexidade e o realismo dos estudos de caso. É necessário melhorar a eficiência computacional dos métodos para torná-los mais aplicáveis à otimização de problemas reais (MAIER *et al.*, 2014). O GA é uma das técnicas mais adotada pelos pesquisadores para a análise ótima de redes hidráulicas, porém, como destacado por Bi, Dandy & Maier (2015), o tempo de processamento foi identificado como a principal causa para a não aplicação desta em sistemas reais complexos.

Dentre os métodos, o *Particle Swarm Optimization* – PSO (KENNEDY; MENDES, 2006) vem apresentando bons resultados em problemas de otimização. O PSO foi desenvolvido pelo psicólogo social James Kennedy e o engenheiro eletricitista Russel Eberhart em 1995; e foi inspirado no comportamento e na dinâmica do “comportamento social” observado em espécies de pássaros, insetos e cardumes de peixes. Desde que Kennedy & Eberhart (1995) apresentaram o PSO, o algoritmo têm sido amplamente aplicado em diversas áreas: recursos hídricos (MORA-MELIA *et al.*, 2015; SHOURIAN; MOUSAVI, 2017), controle e automação industrial (YOSHIDA; FUKUYAMA, 2017; DELICE *et al.*, 2017), medicina (MANDAL; CHATTERJEE; MAITRA, 2017; MIN; JIAYUE & DAMIN, 2017),

robótica (STENDER *et al.*, 2017; NAWAYSEH; JARNDAL; HAMDAN, 2017), computação (BEHESHTI; SHAMSUDDIN; SULAIMAN, 2014; VALDEZ *et al.*, 2017) e economia (SHEN *et al.*, 2017; ALINAGHIAN *et al.*, 2017).

No PSO, os indivíduos da população são representados por pontos, denominados de partículas, que se movimentam em um espaço de busca. O PSO “padrão” aplica, geralmente, as Topologias Global ou Local para buscar soluções ótimas. A Topologia Global foi a primeira a ser proposta e estabelece que as partículas estão conectadas com todas as outras do enxame, ou seja, a posição de cada partícula é influenciada pelas partículas de toda a população do espaço de busca. Embora a literatura apresente resultados satisfatórios, os algoritmos com topologias tradicionais ainda apresentam desvantagens (BEHESHTI; SHAMSUDDIN; SULAIMAN, 2014), impulsionando pesquisadores a proporem o uso do PSO com outras técnicas (MONTALVO *et al.*, 2014; CHATTERJEE *et al.*, 2017), e variações no algoritmo por meio de alterações na topologia (BEHESHTI; SHAMSUDDIN; SULAIMAN, 2014; ALINAGHIAN *et al.*, 2017) e na seleção de parâmetros (LUO; YI, 2008; JUANG; TUNG; CHIU, 2011).

Para superar as desvantagens do PSO padrão em aplicações de dimensionamento de sistemas de distribuição de água reais de grande porte, esta pesquisa objetivou a aplicação da técnica PSO de Topologia Global-Local (PSO-TLG) e de uma pré-seleção dos diâmetros iniciais, a fim de diminuir a aleatoriedade na escolha, obtendo assim a minimização dos custos de projeto e o aperfeiçoamento da performance computacional. O algoritmo PSO-TLG realizará uma busca em todo o espaço com uma velocidade de convergência, relativamente, rápida devido à pré-seleção dos diâmetros iniciais e da hibridização da Topologia Local e Global.

## 2 OBJETIVOS

### 2.1 OBJETIVO GERAL

A pesquisa objetivou o desenvolvimento de um novo modelo de otimização, fundamentado na técnica *Particle Swarm Optimization* (PSO), para o dimensionamento de sistemas de distribuição de água, visando a minimização dos custos de projeto e o aperfeiçoamento do desempenho computacional.

### 2.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos da pesquisa foram:

- Analisar os métodos metaheurísticos de otimização aplicados em projetos ótimos de sistemas de distribuição de água apresentados na literatura, visando o desenvolvimento de uma técnica que reduza o fator aleatório da solução inicial e aumente a eficiência da otimização;
- Desenvolver um algoritmo PSO com modificações na topologia de busca para o dimensionamento ótimo de sistemas de distribuição de água reais; e
- Avaliar o comportamento das variáveis de decisão do modelo em função do número de iterações necessárias e do tempo computacional.

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 REDES DE DISTRIBUIÇÃO DE ÁGUA

Rede de distribuição de água é a parte do sistema de abastecimento formada de tubulações e órgãos acessórios (conexões, bombas válvulas e reservatórios) interconectados, destinados a colocar água potável à disposição dos consumidores, de forma contínua, mantendo a quantidade, qualidade e pressão adequadas (ABNT NBR 12218, 2017).

Quando relaciona-se todo o conjunto de processos de obtenção de água até sua utilização por parte dos consumidores, tem-se o sistema de distribuição de água. Esse sistema compreende da captação de água no manancial ou através de águas profundas, da estação elevatória, da adutora, da estação de tratamento, do reservatório, da rede de distribuição até as ligações domiciliares. Segundo Salvino (2009), a rede de distribuição de água, integrante do sistema de abastecimento de água, representa mais de 50% de custo total de investimento deste sistema.

Para melhor entendimento das partes que compõem uma rede de distribuição, a seguir será apresentada a nomenclatura de diversos componentes de uma rede de distribuição.

- Trecho ou Tubulação ou Conduitos – Tubulação específica com um determinado comprimento, com um início em um nó e término em outro nó;
- Nó – Ponto de conexão entre trechos, representado por um simples ponto e pode ser associado a uma determinada demanda de água;
- Ramal – Conjunto de trechos conectados em série;
- Artérias – Trechos principais da rede de distribuição de água;
- Traçado da rede – Configuração da rede de distribuição de água, ou seja, das tubulações que a compõem e a forma por meio da qual a rede se apresenta fisicamente;
- Cabeceira – Local onde se localiza o reservatório de distribuição ou o bombeamento direto, ou seja, a origem da rede de distribuição. Ressaltando que algumas redes podem ser alimentadas por mais de um reservatório.

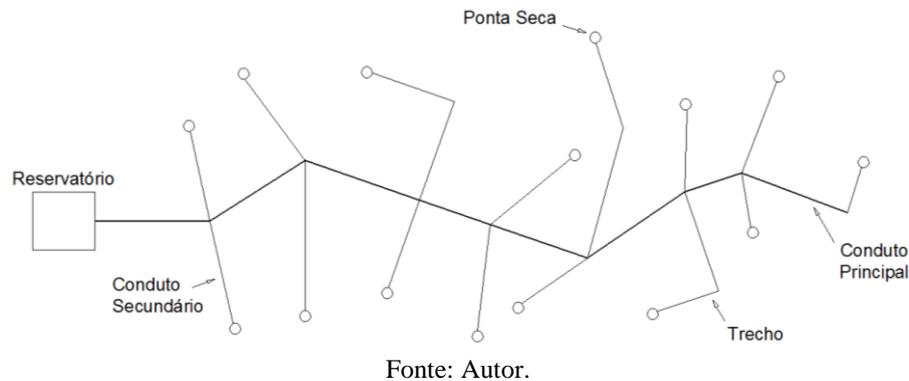
##### 3.1.1 Traçado de Rede

O traçado de uma rede de distribuição remete-se à configuração adotada desta rede, com definição topográfica de todos os componentes da mesma. Os condutos de uma rede são

classificados em condutos principais ou condutos troncos e condutos secundários. Os condutos principais possuem maior diâmetro e abastecem os condutos secundários, que possuindo menor diâmetro tem a função de abastecer diretamente os pontos de consumo do sistema.

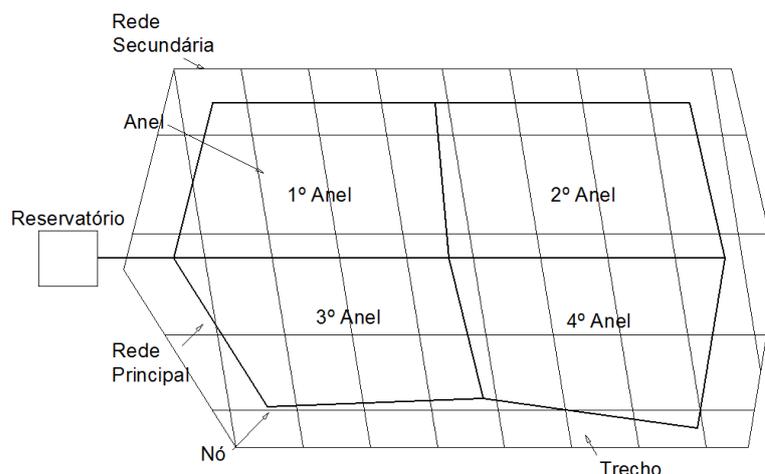
De acordo com a disposição dos condutos principais e o sentido de escoamento nas tubulações secundárias as redes podem ser classificadas em rede ramificada, rede malhada e a rede mista. Essa última é formada pela combinação dos dois tipos anteriores. Na rede ramificada (Figura 1), o sentido do escoamento em qualquer trecho possui uma única direção e as vazões são conhecidas.

Figura 1 – Representação de uma rede ramificada.



As redes malhadas (Figura 2) têm como característica os trechos interligados em forma de anéis, ou malhas, ficando o sentido do fluxo dependente da carga hidráulica nos nós, uma vez que o sentido do fluxo é do ponto com maior carga hidráulica para o ponto com menor carga. O dimensionamento desse tipo de rede é bastante complexo, quando comparada às redes ramificadas, pois qualquer alteração nos dados dos nós e/ou trechos resulta na alteração das variáveis de estado da rede de distribuição e pode alterar o sentido do fluxo de certos trechos.

Figura 2 – Representação de uma rede malhada.



Fonte: Autor.

### 3.1.2 Variáveis de Projeto

Entre as variáveis de estado a se analisar, tem-se a pressão e a velocidade da água nas tubulações, como fator fundamental de controle, pois as mesmas interferem diretamente na qualidade do serviço, nas perdas reais de água e no custo de implantação e operação do sistema.

### 3.1.3 Escoamento

O escoamento na rede de distribuição de água é realizado em condutos forçados, ou seja, pressurizados. As pressões dentro de um conduto são não uniformes, devido à variação de diâmetros que o sistema possui, além das variações topográficas e outras, diferindo-a da pressão atmosférica, que possui uma maior uniformidade.

Além de pressurizado, o escoamento, também, é classificado como sendo viscoso, por apresentar uma tensão de cisalhamento nas paredes da tubulação, e com o comportamento turbulento, devido ao movimento aleatório das partículas do fluido. A tensão de cisalhamento é responsável pela força de atrito que por sua vez, transforma a energia mecânica, referente a movimentação das partículas do fluido, em energia térmica ao longo da tubulação, de modo irreversível. Esse decréscimo de energia mecânica é denominado de perda de carga.

### 3.1.4 Tubulações

Uma rede de distribuição de água, integrante do sistema de distribuição, representa mais de 50% de custo total de investimento deste sistema (SALVINO, 2009), e esse custo é refletido diretamente na escolha correta das tubulações e no seu dimensionamento, levando sempre em consideração diversos fatores, por exemplo, pressões de trabalho, observando as situações extremas de pressão, a velocidade que a tubulação é submetida, e o material da tubulação, que, atualmente, são mais utilizados em redes de distribuição de água os de plástico – Policloreto de Vinila (PVC), polietileno de alta densidade (PEAD), poliéster revestido com fibra de vidro (PRFV), e os metálicos – ferro fundido (FoFo) e aço, sendo o de PVC e o de FoFo os mais utilizados.

### 3.2 ESTRUTURA DOS PROBLEMAS DE OTIMIZAÇÃO

A otimização, como o principal objetivo do projeto em engenharia, envolve sempre encontrar a "melhor" solução para um problema, em termos de qualidade, custo, confiabilidade ou qualquer outro critério de utilidade. A "melhor" solução manifesta-se como um extremo, máximo ou mínimo, de uma determinada função de  $n$  variáveis de decisão, conhecida como função objetivo, e que representa um certo critério a otimizar.

Na maioria dos sistemas físicos que estão sujeitos a otimização, as variáveis de decisão que caracterizam seu estado geralmente estão ligadas entre si por uma série de leis de comportamento, de modo que o processo de otimização é restrito a conjuntos de variáveis que verificam essas leis de comportamento. Os problemas de otimização em engenharia exigem o estabelecimento de condições adicionais que descrevem os limites do bom funcionamento do sistema.

O conjunto de leis de comportamento do sistema e das condições operacionais impostas pode ser expresso funcionalmente por meio de um conjunto de equações chamadas restrições (Equações 1), do seguinte tipo:

$$\begin{aligned}
 a. \quad & g_j(x_1, x_2, \dots, x_n) = b_j & j = 1 \dots m_1 \\
 b. \quad & g_k(x_1, x_2, \dots, x_n) \geq b_k & k = 1 \dots m_2 \\
 c. \quad & g_l(x_1, x_2, \dots, x_n) \leq b_l & l = 1 \dots m_3
 \end{aligned} \tag{1}$$

O conjunto formado pela função objetivo e as restrições é chamado de modelo matemático. Muitos autores concebem um modelo como o binômio formado pela representação matemática-funcional (ou algorítmica) dele, e pelo conjunto de dados necessários para sua resolução. É necessário que haja um compromisso entre o nível de detalhe exigido para o modelo, as técnicas numéricas disponíveis para sua resolução, a disponibilidade e a facilidade de manipulação de todos os dados envolvidos e as conclusões que finalmente devem ser extraídas dos resultados.

Tradicionalmente, os projetos de inúmeros sistemas em engenharia foram realizados por análises de tentativa e erro, que podem fornecer soluções apropriadas ao trabalhar com sistemas simples, uma vez que um projetista experiente é capaz de prever ou intuir a influência das variáveis de projeto sobre o funcionamento do mesmo. No entanto, é quase impossível soluções “ótimas” no projeto de sistemas complexos, devido ao grande número de variáveis envolvidas e à interdependência extensa e complexa que geralmente existe entre as variáveis.

A aplicação das técnicas de Pesquisa Operacional substituiu o processo tradicional de definição dos projetos, propondo métodos funcionalmente diretos para obter, como resultado, o dimensionamento mais adequado de diversos sistemas, usando como entrada os requisitos para sua operação. Além disso, a aplicação sistemática de métodos de otimização permite estudar a influência e os efeitos da alteração de parâmetros de projeto na solução ótima. Nesse sentido, descobre-se que a maioria das contribuições feitas para a otimização de sistemas data dos últimos 20 ou 25 anos, devido ao advento das técnicas de Pesquisa Operacional desde a Segunda Guerra Mundial, bem como a aparência e evolução dos computadores que serviram como suporte fundamental para o desenvolvimento dessas técnicas (MORA-MELIA *et al.*, 2015).

De forma geral, pode-se classificar os problemas de otimização, bem como as técnicas disponíveis para sua resolução, da seguinte maneira:

1. Técnicas do Cálculo Diferencial Clássico: se o problema não tiver restrições, o ótimo é obtido por cálculo diferencial. No caso de restrições, o problema pode ser transformado em um equivalente sem restrições por meio da técnica dos Multiplicadores de Lagrange;
2. Otimização Linear ou Programação Linear (PL): neste caso, trata-se de encontrar o mínimo ou o máximo de uma função objetivo de natureza linear, sujeita a um conjunto de restrições que também são lineares. O algoritmo mais conhecido para resolver problemas de PL é o SIMPLEX;

3. Otimização Não Linear Convexa: esse tipo de problema contém pelo menos uma função não linear e, devido às propriedades da convexidade, se tiver algum ótimo, será global. Dependendo do tipo de problema, podem ser propostas diferentes soluções de resolução, tais como:
  - a. Linearização: neste caso, o problema não linear é transformado em um linear, o que proporciona uma aproximação adequada e suficiente ao problema real a ser tratado.
  - b. Programação Quadrática, que trata de funções objetivo quadráticas e restrições lineares. Vários procedimentos de resolução foram desenvolvidos, uma das mais conhecidas como transformação em um problema linear equivalente.
  - c. Método do Gradiente: é um procedimento iterativo no qual a solução é melhorada na direção do gradiente da função objetivo. O processo acaba encontrando o ótimo.
  
4. Otimização Não Convexa: Se o problema de otimização não for convexo, ele pode conter um ótimo local, de modo que as primeiras técnicas desenvolvidas, como o Método Gradiente, podem convergir em um ótimo local sem ter explorado “melhores” soluções. Os procedimentos aplicáveis aos casos não convexos são os seguintes:
  - a. Enumeração Explícita ou Exaustiva: em problemas que possuem um número finito de possíveis soluções, onde são avaliadas e comparadas todas as soluções possíveis.
  - b. Enumeração Implícita ou Parcial: o processo de enumeração é estruturado de tal forma que apenas uma fração de todas as soluções possíveis são examinadas no processo de escolha.
  - c. Métodos Metaheurísticos: estes conseguem melhorar uma solução inicial por meio de uma aproximação racional, porém não garantem a obtenção do ótimo global e possuem uma grande flexibilidade na adaptação de diversos problemas específicos. Esses métodos têm sido amplamente estudados nas últimas décadas, o que aprofundou de maneira marcante o conhecimento sobre o processo de resolução de problemas complexos. Alguns exemplos de Metaheurísticas são: *Ant Colony Optimization (ACO)*, *Genetic Algorithm (GA)*, *Shuffled Frog Leaping Algorithm (SFLA)*, *Honey-Bee Mating Optimization (HBMO)*, *Particle Swarm Optimization (PSO)*.

5. Problemas Especiais: são técnicas específicas que foram desenvolvidas para uma grande variedade de problemas que possuem estruturas especiais, embora também sejam úteis em problemas de estrutura convexa ou mesmo na resolução de problemas lineares que também possam ser resolvidos por técnicas padrão. Um bom exemplo deste tipo de técnicas é a Programação Dinâmica, orientada para a otimização de um determinado problema por meio da decomposição em uma sequência de subproblemas, sendo particularmente indicado nos casos em que o sistema em questão pode ser decomposto em uma série de estágios.

A visão geral mostra que há uma grande variedade de problemas e técnicas para resolvê-los, o que ainda pode ser completado com muitos outros. No entanto, é interessante fazer uma análise classificatória do problema de otimização para ter critérios suficientes para selecionar as técnicas e algoritmos mais apropriados e efetivos para sua resolução.

Em seguida, caracteriza-se o problema de otimização de redes de distribuição de água, bem como certos aspectos relevantes das funções que aparecem no projeto de redes hidráulicas.

### **3.2.1 Projeto de otimização de redes de distribuição de água**

Em redes de distribuição de água, o custo mais significativo avaliado é o custo de aquisição e assentamento da tubulação. Os sistemas otimizados deverão atender as demandas requeridas nos nós de cada rede com pressões superiores às mínimas preestabelecidas, devendo as vazões nos trechos da rede de distribuição e as pressões nos nós satisfazerem as leis de conservação de energia e massa.

Em resumo o problema pode ser descrito como:

- Minimizar: o custo de investimento de capital na implantação da rede;
- Sujeito: as restrições hidráulicas, atender as demandas e manter as pressões nos nós dentro da faixa admissível.

Alperovits & Shamir (1977) apresentaram a formulação do projeto ótimo para uma rede de distribuição de água genérica a ser minimizada, tal função objetivo  $f$  é assumida como função dos custos dos diâmetros dos tubos e de seus respectivos comprimentos, conforme a Equação 2.

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

onde  $m$  é o número total de tubos no sistema;  $C(D_i, L_i)$  é o custo do tubo  $i$  de diâmetro  $D_i$  e comprimento  $L_i$ . Em um projeto de uma rede de distribuição de água, algumas restrições devem ser satisfeitas, e com isso a função objetivo deve ser minimizada satisfazendo tais restrições descritas a seguir.

Para cada nó (exceto a fonte), a equação da continuidade deve ser satisfeita, conforme é mostrado na Equação 3.

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

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

Para cada um dos anéis da rede a equação da conservação da energia pode ser expressa pela Equação 4.

$$\sum H_i = 0 \quad (4)$$

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

Segue na Equação 5 a restrição de pressão mínima para cada nó da rede.

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

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

O projeto de redes de distribuição de água requer a compreensão das equações hidráulicas de condutos forçados. Projetistas têm como preocupação principal a previsão da capacidade de condução do sistema de dutos e, para possibilitar a determinação destes

valores, é necessário o cálculo da perda de carga ao longo dos tubos por meio de equações que consideram a pressão, vazão, comprimento e o diâmetro nos cálculos. Várias fórmulas foram desenvolvidas para determinar a perda de carga devido ao atrito. As mais conhecidas e usadas são as de Darcy-Weisbach e de Hazen-Williams. A equação empírica de Hazen-Williams é a mais utilizada nas formulações. Em sua forma original tem-se a Equação 6.

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

onde,  $V$  é a velocidade do escoamento, em m/s;  $Rh$  é o raio hidráulico, em m;  $S_f$  é o gradiente hidráulico e  $C$  é o coeficiente dimensional cujo valor numérico pode mudar de acordo com o sistema de unidades de medida utilizado. Para um conduto circular  $Rh$  é igual a  $D/4$ . A fim de simplificar a Equação 6, o valor de  $C$  é considerado constante, e assim a fórmula pode ser escrita conforme a Equação 7.

$$V = \alpha \times C.D^{0,63} \times S_f^{0,54} \quad (7)$$

onde  $D$  é o diâmetro do tubo; e  $\alpha$  é uma constante que assume o valor de 0,55 no Sistema Britânico e 0,355 no Sistema Internacional. Segue a Equação 8, a perda de carga  $H$  desejada, tendo a vazão  $Q$  conhecida.

$$H = \omega \frac{L}{C^a \times D^b} Q^a \quad (8)$$

onde  $\omega$  é a constante numérica de conversão, que depende do sistema de unidades utilizado;  $a$  é um coeficiente que vale  $1/0,54 = 1,85$ ;  $b$  é um coeficiente que vale  $2,63/0,54 = 4,87$ ; e  $L$  é o comprimento da tubulação. Diferentes pesquisadores tem usado diferentes valores para a constante de conversão  $\alpha$  e  $\omega$  em nas Equações 7 e 8. Por exemplo, Savic & Walters (1997) utilizaram o coeficiente  $\omega = 10,5088$ , Alperotivs & Shamir (1977) e o simulador hidráulico EPANET 2.0 (ROSSMAN, 2000) consideraram  $\omega = 10,6792$ .

$$H = 10,6792 \frac{L}{C^{1,85} \times D^{4,87}} Q^{1,85} \quad (9)$$

onde  $D$  é o diâmetro do tubo (m);  $Q$  a vazão no trecho ( $m^3/s$ );  $L$  o comprimento do trecho (m) e  $C$  o coeficiente de rugosidade.

### 3.3 ALGORITMOS DE OTIMIZAÇÃO METAHEURÍSTICOS

Embora todos os procedimentos descritos por metaheurísticas possam ser vistos como estratégias de busca, algumas características desses procedimentos permitem classificar a maioria das metaheurísticas em tipos bastante distintos, de acordo com a abordagem utilizada: evolução de populações compostas por soluções, construção gradual inteligente, busca por entornos e relaxação, como também, seu processo operacional (MANJARRES *et al.*, 2013): algoritmos determinísticos, probabilísticos, evolucionários, de lógica *Fuzzy*, estocásticos, neurais, inteligência de enxame, entre outros.

Os métodos de otimização probabilísticos, evolucionários e/ou de inteligência de enxame adotam parâmetros estocásticos e, em geral, avaliam somente a função objetivo. Uma das vantagens destas técnicas em relação aos algoritmos determinísticos, é que a função objetivo e as restrições não precisam ser explicitadas, podendo não haver restrição quanto ao ponto de partida dentro do espaço de busca da solução, além de trabalharem adequadamente com variáveis contínuas e discretas ou uma combinação delas. Contudo, sua principal desvantagem é o custo computacional elevado (MAIER *et al.*, 2014).

Alguns exemplos de algoritmos, apresentados resumidamente a seguir, são: *Genetic Algorithm* (GA), *Shuffled Frog Leaping Algorithm* (SFLA), *Ant Colony Optimization* (ACO), *Honey-Bee Mating Optimization* (HBMO), *Scatter Search* (SS), *Differential Evolution* (DE), *Particle Swarm Optimization* (PSO).

#### 3.3.1 *Genetic Algorithm* (GA)

*Genetic Algorithm* (GA), em português Algoritmo Genético, foi desenvolvido por John Holland (HOLLAND, 1975). O algoritmo de busca é inspirado na teoria de seleção natural de Charles Darwin e nos mecanismos da genética. Acreditava-se que seria possível a implementação de um algoritmo espelhado no processo de evolução encontrado na natureza, na genética das populações. O algoritmo genético foi estruturado de forma que as informações referentes a um determinado sistema pudessem ser codificadas de maneira análoga aos cromossomos biológicos.

No GA, uma população inicial de cromossomos é gerada e cada cromossomo representa uma possível solução para o problema. A população é avaliada, e o cromossomo recebe seu valor de *fitness* (aptidão). Os cromossomos seguem a teoria de Darwin e são selecionados para a próxima geração, transferindo suas características para seus descendentes

através da reprodução (crossover e mutação). Todo esse processo é repetido até que seja encontrada uma solução satisfatória (COSTA FILHO; OPPI, 1999).

A possível solução para o problema a ser resolvido por um GA pode ser representada de forma real, por permutação de símbolos, por árvore, por numeração binária, entre outros. A representação binária é uma das mais utilizadas pela sua simplicidade. Os GA são os mais conhecidos da classe dos algoritmos evolucionários e têm sido amplamente utilizados na análise dos diversos problemas inerentes às redes de abastecimento de água.

### **3.3.2 *Shuffled Frog Leaping Algorithm* (SFLA)**

O algoritmo *Shuffled frog Leaping Algorithm* (SFLA) apresentado por Eusuff & Lansey (2003), é uma metaheurística memética (referente à memória, esse termo é análogo do gene na genética) que visa encontrar uma solução ótima através da realização de uma busca heurística local. O algoritmo é fundamentado na evolução de memes transmitidos por indivíduos e na troca global de informações entre a população, transformando Rãs em uma evolução memética. O algoritmo usa a evolução memética sob a forma de infecção de ideias entre os indivíduos na busca local, e uma estratégia de embaralhamento que permite a troca de informações entre as buscas locais para se mover em direção ao valor ótimo.

O SFLA não altera as características físicas de um indivíduo, em vez disso, melhora progressivamente o comportamento de cada sapo em uma chamada população virtual. A população virtual consiste de um conjunto de sapos (possíveis soluções) que são particionados em subconjuntos chamados de *memplexes*. Os diferentes *memplexes* são considerados como diferentes culturas de sapos que realizam a busca local em cada *memplex*, ou seja, as ideias são passadas entre todos os indivíduos da população, enquanto que apenas as interações dos pais e irmãos são permitidas em um GA (EUSUFF; LANSEY; PASHA 2006).

Os sapos mantêm ideias individuais, que podem ser influenciadas pelas ideias de outros sapos e assim evoluem utilizando um processo de evolução memética. Depois de um número de passos evolutivos, as ideias são passadas entre os *memplexes* em um processo de embaralhamento. A busca local e o processo global de embaralhamento continuam até que o critério de convergência seja satisfeito (EUSUFF; LANSEY; PASHA 2006).

### 3.3.3 *Ant Colony Optimization (ACO)*

*Ant Colony Optimization (ACO)*, em português Otimização por Colônia de Formigas, é um algoritmo de otimização introduzido por Dorigo (1992) no começo da década de 90 em sua tese de doutorado, que propõe o estudo de sistemas artificiais inspirados no comportamento cooperativo de colônias de formigas. Cada solução candidata do algoritmo ACO é representada por uma formiga. Cada formiga escolhe uma rota e deposita certa quantidade de feromônio na rota percorrida. As melhores rotas seriam identificadas pela quantidade de feromônio. A ideia central desta metaheurística consiste em simular o processo de depósito e evaporação de feromônio, substância utilizada para guardar um caminho enquanto as formigas se movimentam em busca de alimento, excretada pelas formigas reais, como mecanismo de aprendizagem de um sistema multiagente (no caso, as formigas) proposto a solucionar um determinado problema combinatorial.

### 3.3.4 *Honey-Bee Mating Optimization (HBMO)*

O algoritmo *Honey-Bee Mating Optimization (HBMO)* ou Otimização por Acasalamento de Abelhas em português, possui uma versão uniobjetivo proposta por Haddad, Afshar & Marino (2006) que teve como base a ideia apresentada por Abbass (2001). O desenvolvimento dessa técnica de otimização tem como fonte de inspiração o processo de acasalamento de abelhas domésticas.

Existem outros algoritmos evolucionários fundamentados em comportamento social de abelhas, mais especificamente no processo de coleta de néctar, como o BCO (*Bee Colony Optimization*) empregado por Chong *et al.* (2006).

Uma colônia de abelhas é composta de uma colmeia (conjunto de soluções aleatórias que representa a população inicial) e os indivíduos que nela vivem: a abelha rainha (melhor valor de *fitness*), os zangões (soluções semi-aleatórias com certo grau de dependência da melhor valor de *fitness*) e as operárias (responsáveis pela manutenção da colmeia no descarte de soluções candidatas através de base probabilísticas). No caso da rainha, esta representa o indivíduo mais importante, pois ela é a única abelha que tem o ovário totalmente desenvolvido, é dela que descendem todos os outros indivíduos. Durante o processo de evolução da colmeia, a rainha gera novos descendentes que podem ser tanto uma nova rainha, como zangões ou operárias.

O processo reprodutivo das abelhas consiste do cruzamento da rainha com os zangões, que são pouco mais de uma dezena, e são os pais da colmeia. Esse processo se dá inicialmente de um processo conhecido como voo de acasalamento (teste seletivo, no qual, probabilisticamente, determina-se se a melhor solução). É justamente durante esse voo, que a rainha seleciona os machos que irão cruzar. Uma rainha cruza diversas vezes durante sua vida, enquanto o zangão inevitavelmente vem a morrer após cruzar com a rainha, realizando assim o seu único papel na colônia que é transmitir informação genética (descarte da solução oferecida pelo zangão). Dessa forma, exposta à seleção natural, a colmeia evolui de maneira que os seus indivíduos estejam mais aptos e adaptados ao ambiente.

### **3.3.5 *Scatter Search* (SS)**

O *Scatter Search* (SS) foi proposto por Glover (1977) para a resolução de problemas de programação inteira, sua tradução para o português é Busca Dispersa. De forma semelhante aos outros métodos evolucionários, esse método adota uma população de soluções e não apenas uma solução a cada iteração. Diferentemente de alguns algoritmos evolucionários (GA, PSO, ACO, etc.), o SS possui um maior direcionamento na busca do valor ótimo, não dependendo apenas de aleatoriedade para as suas operações. São estabelecidos previamente critérios de escolha nas soluções da população que serão combinadas, retirando a aleatoriamente da escolha. As soluções escolhidas formam um conjunto chamado de conjunto de soluções referência (CUNG *et al.*, 1996).

As soluções que são escolhidas para compor o conjunto de soluções referência são as consideradas melhores. O conceito de melhor, neste caso, leva em consideração o valor da função objetivo e da diversidade, onde esse último evita que o algoritmo convirja prematuramente para um ótimo local e não consiga sair dele (CUNG *et al.*, 1996).

### **3.3.6 *Differential Evolution* (DE)**

O algoritmo *Differential Evolution* (DE), em português Evolução Diferencial, é uma técnica de pesquisa estocástica proposta por Storn & Price (1997) que, apesar de ser relativamente simples, apresenta bons resultados e se tornou um otimizador eficiente no domínio de busca contínua. Assemelha-se à estrutura dos algoritmos evolucionários, diferenciando na geração de novas soluções candidatas e pelo uso de um esquema de seleção "ganancioso".

O DE foi aplicado com êxito em diversos campos, como engenharia mecânica (ROGALSKY; DERKSEN; KOCABIYIK, 1999; JOSHI; SANDERSON, 1999), comunicação (STORN, 1997) e reconhecimento de padrões (ILONEN; KAMARAINEN; LAMPINEN, 2003). Em DE, existem muitas estratégias de geração de vetores de teste, das quais alguns podem ser adequados para resolver um problema específico. Além disso, há três parâmetros de controle cruciais envolvidos em DE, são eles: tamanho de população; fator de escala; e taxa de cruzamento. Esses parâmetros podem influenciar significativamente no desempenho de otimização do DE.

O DE funciona da seguinte forma: inicialmente todos os indivíduos são definidos aleatoriamente e avaliados usando a função de *fitness* fornecida e o seguinte processo será executado enquanto a condição de término não for cumprida. Depois, para cada indivíduo da população, um conjunto de “filhos” é criado usando a diferença ponderada das soluções “pai” (solução principal). A prole (conjunto de filhos) pode substituir o pai se apresentar melhor resultado. Caso contrário, o pai sobrevive e é transmitido para a próxima iteração do algoritmo.

### 3.4 PARTICLE SWARM OTIMIZATION (PSO)

O algoritmo Otimização por Enxame de Partículas, em inglês *Particle Swarm Optimization*, foi desenvolvido pelo psicólogo social James Kennedy e o engenheiro eletricitista Russel Eberhart em 1995 (KENNEDY; EBERHART, 1995). Este foi inspirado no comportamento e na dinâmica do “comportamento social” observado em muitas espécies de pássaros, insetos, cardumes de peixes e até mesmo do comportamento social humano, para tratar problemas no domínio contínuo.

No algoritmo PSO, os indivíduos da população são representados por pontos, denominados de partículas, que se deslocam em um espaço de busca. As variações nos atributos desses pontos levam a novos pontos no espaço, ou seja, correspondem a movimentações no espaço. Uma ideia inspirada em sistemas cognitivos é a de que essas partículas tenderão a mover-se em direção umas das outras e irão influenciar umas às outras.

A maior parte dos algoritmos de PSO empregam dois princípios sócio métricos do movimento das partículas: a melhor posição no espaço de busca percorrido por alguma das partículas (*Gbest*) associada a todo o enxame e a melhor posição individual que cada partícula percorreu no espaço (*Pbest*) que é associada a cada partícula do enxame. Ambas as métricas são medidas por uma função de aptidão,  $f(p)$ , função objetivo ou de aptidão (*fitness*) do problema de otimização.

A influência exercida pelas métricas  $Gbest$  e  $Pbest$  no movimento das partículas pode ser definida por duas constantes, a saber: o fator social ( $c_1$ ) e o fator cognitivo ( $c_2$ ). O primeiro princípio conecta conceitualmente todos os membros de uma população entre si. Como consequência, o comportamento de cada partícula é influenciado pelo comportamento de todas as outras partículas. A segunda métrica ( $Pbest$ ) cria uma vizinhança para cada indivíduo composta por ele próprio e seus vizinhos mais próximos. Além disso, a capacidade de exploração do espaço de busca pela partícula é controlada pelo fator de inércia ( $w$ ). Assim, uma partícula irá se mover em uma determinada direção que é função da posição atual  $x_i(t)$ , de sua velocidade  $v_i(t)$ , da posição da partícula que levou ao seu melhor desempenho até o momento e do melhor desempenho global do sistema até o momento ( $Gbest$ ). A velocidade da partícula será ajustada pela Equação 10.

$$v_{i(t+1)} = w v_{i(t)} + rand c_1 (Pbest - x_{i(t)}) + rand c_2 (Gbest - x_{i(t)}) \quad (10)$$

onde  $c_1$  e  $c_2$  são constantes limitadas a um intervalo finito e  $rand$  gera valores aleatórios entre 0 e 1. Kennedy & Eberhart (1995) denominaram as constantes como os componentes “cognitivo” e “social”, respectivamente.

Após o cálculo da velocidade da partícula, a posição da partícula “ $i$ ” na próxima iteração é estabelecida como uma influência aditiva da posição antiga e da velocidade calculada, sendo expressa pela Equação 11.

$$x_{i(t+1)} = x_{i(t)} + v_{i(t+1)} \quad (11)$$

Para limitar a velocidade de uma partícula, para que o sistema não extrapole o espaço de busca, são impostos limites para seus valores em cada dimensão do espaço de busca. O algoritmo PSO é executado repetidamente até que o critério de parada seja alcançado ou as mudanças nas velocidades das partículas estejam próximas do valor zero.

No algoritmo PSO tradicional o conjunto inicial de partículas  $x_i$  é gerado de forma aleatória e espalhado pelo espaço de busca conforme a Equação 12.

$$x_i^I \leq x_i \leq x_i^S \quad i=1, \dots, n \quad (12)$$

onde  $x_i^I$  e  $x_i^S$  contém os limites inferior e superior das posições das partículas, respectivamente e  $n$  é o número de partículas. As dimensões das partículas são determinadas pelo problema a ser otimizado, de acordo com o número de variáveis de projeto. O algoritmo básico do PSO pode ser descrito brevemente utilizando os passos observados no algoritmo 1.

---

Algoritmo 1: Pseudocódigo do algoritmo PSO

---

```

1 inicializaEnxame();
2 para cadaIteracao faça
3 | para cadaPartícula faça
4 | | para cadaDimensao faça
5 | | | atualizaVelocidadePosicao();
6 | | fim
7 | | calculaFitness;
8 | fim
9 | AtualizaLíder;
10 | se fitnessAtual < melhorFitnessIndividual então
11 | | melhorFitnessIndividual = fitnessAtual;
12 | fim
13 | se fitnessAtual < melhorFitnessVizinhaca então
14 | | melhorFitnessVizinhaca = fitnessAtual;
15 | fim
16 | iteracao ++ ;
17 fim

```

---

### 3.4.1 Parâmetros

Apesar de o algoritmo PSO padrão possuir um número pequeno de parâmetros para serem determinados pelo usuário, a definição destes podem alterar consideravelmente o comportamento do algoritmo e provocar instabilidade no processo de busca. Os fatores social ( $c_1$ ) e cognitivo ( $c_2$ ) são comumente definidos com o valor 2 (EBERHART; SHI, 2000).

Shi & Eberhart (1998a) apresentam dois novos parâmetros determinados em experimentos: inércia e fator de aceleração, tais parâmetros foram introduzidos com a finalidade de tentar melhorar a busca pelo ótimo com mais rapidez e precisão. Eles são discutidos nos próximos itens.

### Inércia

Shi & Eberhart (1998a, 1998b) propuseram o parâmetro denominado inércia  $w$ , com o desejo de controlar melhor a exploração global e local, e reduzir a importância da  $V_{max}$  ou eliminá-la completamente. O parâmetro de inércia  $w$  está relacionado com a exploração das partículas em seu campo de busca, e a determinação adequada do valor de  $w$  proporcionará um equilíbrio entre a exploração global e local, resultando em uma quantidade de iterações menores para encontrar uma boa solução. O parâmetro  $w$  é introduzido na primeira parcela da Equação 10.

A exploração global tem sua atuação mais efetiva no início das buscas, pois as partículas são espalhadas em um campo de busca bastante abrangente, e começar o algoritmo com valores maiores para  $w$  melhora esse tipo de busca. E ao longo das iterações, o valor de  $w$  vai sendo reduzido gradativamente, favorecendo a exploração local, possibilitando que as partículas encontrem a solução de forma mais rápida. A sugestão proposta por Eberhart & Shi (2000) foi utilizar uma variação linear da inércia com um valor inicial de 0,9 e final de 0,4, conforme Equação 13.

$$w_i = (w_{ini} - w_{fim}) \frac{(N-i)}{N} + w_{fim} \quad (13)$$

onde  $w_{ini}$  e  $w_{fim}$  são os valores inicial e final, respectivamente,  $N$  é o número total de iterações e  $i$  é a iteração atual.

Naturalmente, outras estratégias podem ser adotadas para ajustar o valor da inércia e os coeficientes  $c_1$  e  $c_2$  com variação ao longo das iterações em muitos problemas (CHATTERJEE; SIARRY, 2006; RATNAWEERA; HALGAMUGE; WATSON 2004), porém com pouca aplicação no dimensionamento de redes de distribuição de água. Essas propostas pretendem melhorar a velocidade de convergência do algoritmo e refinar a busca no espaço multidimensional.

### Fator de aceleração

Uma nova estratégia, inicialmente estudada por Kennedy (1990), denominada fator de aceleração, foi introduzida com a finalidade de controlar a convergência das partículas e ajustando a velocidade das mesmas. Esse fator, denominado  $k$ , pode ser observado na Equação 14, com  $\phi > 4$ .

$$k = \frac{2}{\phi - 2 + \sqrt{\phi^2 - 4\phi}} \quad (14)$$

É comum determinar  $\phi$  com o valor de 4 (KENNEDY, 1990), e assim, a constante  $k$  é aproximadamente 0,7298, porém seu valor pode variar de acordo com o problema e pode ser determinado após uma análise do valor  $V_{max}$  que as partículas deverão ter, ou seja, o Fator  $k$  se torna um agente limitante de velocidade. Na implementação desse fator, Clerc & Kennedy (2002) utilizaram uma maneira muito simples, multiplicando  $k$  por todos os outros parâmetros, conforme mostra a Equação 15.

$$v_{i(t+1)} = k \left( w v_{i(t)} + rand c_1 (Pbest - x_{i(t)}) + rand c_2 (Gbest - x_{i(t)}) \right) \quad (15)$$

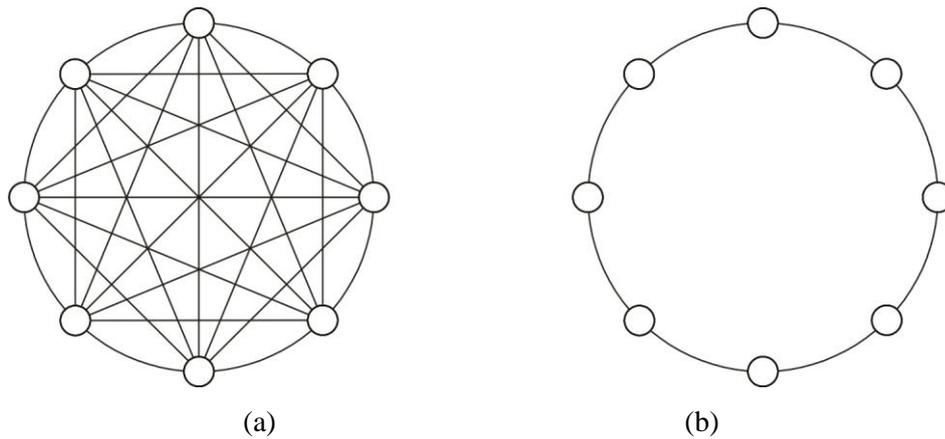
### 3.4.2 Topologia das partículas

No PSO, cada partícula do enxame se comunica de forma específica com as demais partículas. Essa comunicação é denominada de topologia de vizinhança. Há diversos tipos de topologias citadas na literatura, que influenciam diretamente na convergência e no desempenho do algoritmo PSO. As Topologias Local e Global são as topologias mais conhecidas e adotadas.

Na Figura 3, apresenta-se o esquema de comunicação (representado por linhas) entre oito partículas nas Topologias Global (Figura 3a) e Local (Figura 3b). Na Topologia Global, a informação da melhor posição é disseminada rapidamente entre todas as partículas, diferentemente da Local que a troca de informação é mais lenta, pois o enxame é organizado na forma de anel e cada partícula possui geralmente dois vizinhos.

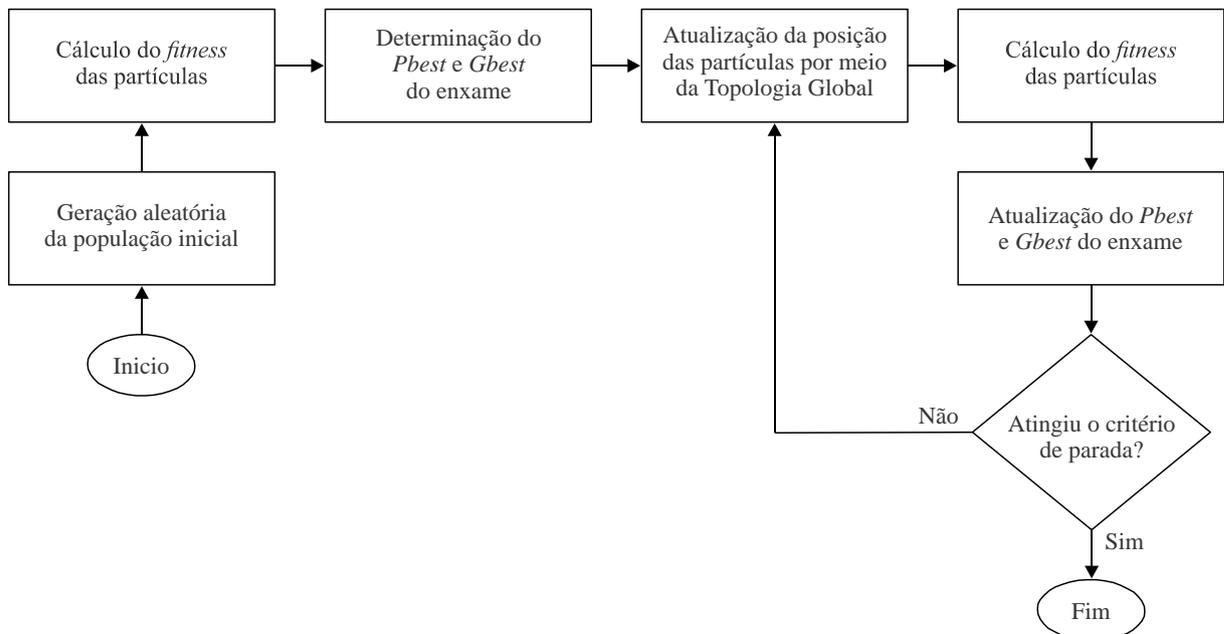
A Topologia Global foi a primeira a ser proposta e a Equação 10 representa sua formulação. Nesta topologia cada partícula está conectada com todas as outras do enxame, logo uma partícula é influenciada por todo o enxame, pois esta está recebendo informações através de *Gbest*. Uma das vantagens dessa topologia é a sua utilização em problemas com funções unimodais, pois as partículas encontram rapidamente uma solução aceitável, que em problemas multimodais pode acarretar uma desvantagem, pois podem convergir prematuramente para mínimos locais (KENNEDY; EBERHART, 1995). No fluxograma 1 está presente o os passos do algoritmo PSO com Topologia Global (PSO-TG).

Figura 3 – Topologias (a) Global e (b) Local.



Fonte: Autor.

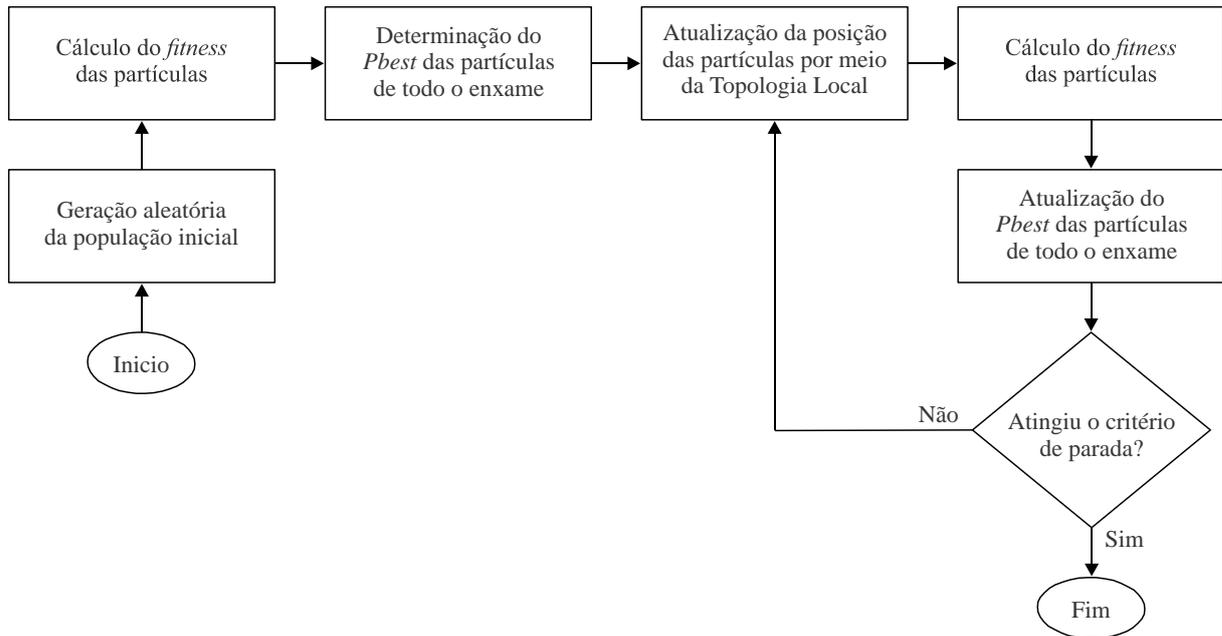
Fluxograma 1 – Fluxograma básico para o algoritmo PSO com Topologia Global.



Fonte: Autor.

Na topologia local, as partículas se comunicam somente com sua vizinhança mais próxima, substituindo o *Gbest* por *Pbest* da partícula vizinha de melhor resultado na Equação 10. Embora a troca de informação entre as partícula seja mais lenta do que a Global, a grande vantagem dessa topologia é sua utilização em problemas com funções multimodais, pois as partículas aumentam seu campo de busca, provendo uma melhor qualidade de soluções, fugindo de mínimos locais (KENNEDY; EBERHART, 1995). O fluxograma dessa topologia é apresentado no Fluxograma 2 (PSO-TL).

Fluxograma 2 – Fluxograma básico para o algoritmo PSO com Topologia Local.



Fonte: Autor.

### 3.5 SIMULADOR HIDRÁULICO (EPANET 2.0 BRASIL)

Em muitos projetos de sistemas de distribuição de água, simuladores hidráulicos vêm ganhando espaço e estando cada vez mais presentes no dia a dia dos projetistas, pois são ferramentas capazes de simular sistemas complexos, se tornando uma ferramenta indispensável para os engenheiros e técnicos do setor.

As avaliações hidráulicas constituem parte essencial no cômputo das funções objetivo dos problemas de otimização. É imprescindível, na maioria dos casos, a incorporação de um simulador hidráulico à rotina computacional que quantifica os objetivos estabelecidos. O simulador desempenha o papel de avaliador das variáveis de estado (pressões e vazões) do sistema (CHEUNG, 2004).

Atualmente, um dos simuladores mais utilizados no mundo é o EPANET (ROSSMAN, 2000), desenvolvido por Lewis A. Rossman da Agência de Proteção Ambiental dos Estados Unidos (*Environmental Protection Agency*). Agência responsável pela proteção dos recursos terrestres, aéreos e hídricos da nação, que utiliza o programa como suporte técnico para soluções de problemas ambientais e para entender como os poluentes afetam a saúde e para a prevenção de eventuais riscos ambientais futuros. O programa rastreia o fluxo de água em cada tubo, a pressão em cada nó, a altura da água em cada tanque e a

concentração de uma espécie química em toda a rede. Além das espécies químicas, a idade da água e o rastreamento de fontes também podem ser simulados (ROSSMAN, 2000).

O EPANET 2 foi escolhido como simulador, pois é amplamente aceito como o padrão mundial na modelagem hidráulica e de qualidade da água de sistemas de distribuição de água. A maioria dos sistemas existentes foi modelada no EPANET 2 (BISCOS *et al.*, 2003), sendo o simulador hidráulico mais adotado pela comunidade científica e técnica no mundo para cálculo e avaliação de sistemas de distribuição de água. Diversos pesquisadores adotam o algoritmo de cálculo do EPANET na resolução de seus problemas de otimização (EUSUFF; LANSEY, 2003; COSTA; CASTRO; ARAÚJO, 2006; VASAN; SLOBODAN, 2010; MURANHO *et al.*, 2012; CHANG; PONGSANONE; ERNEST, 2014; PINNTO *et al.*, 2017; ISHIHARA *et al.*, 2017; ROLAM *et al.*, 2017; QUESADA *et al.*, 2017).

O EPANET é livre e foi desenvolvido em duas linguagens, a linguagem C, que permite a implementação de uma biblioteca de funções hidráulicas, e a Delphi 7, que facilita a interação máquina-usuário, através de janelas, menus, gráficos, entre outros, além de permitir ao usuário a construção de uma rede de distribuição, simulando seu comportamento estático e dinâmico (SALVINO, 2009).

### 3.6 ESTADO DA ARTE

Diversos são os métodos de dimensionamento das tubulações em redes de distribuição de água. Os métodos tradicionais levam em consideração apenas o balanceamento hidráulico da rede, de forma a atender às condições impostas pelas equações da conservação de massa nos nós e conservação de energia nos anéis. No entanto, estes métodos não possuem critérios de dimensionamento visando à minimização dos custos envolvidos. Dentre os métodos tradicionais, o método de Hardy-Cross é amplamente adotado no dimensionamento de redes hidráulicas.

Com o desenvolvimento das cidades e, conseqüentemente, o crescimento populacional, aumenta-se a necessidade da verticalização urbana, ou seja, há uma grande concentração de edificações em centros urbanos. Diante disso, as redes de distribuição de água têm adquirido maior complexidade e sofisticação na medida em que um maior número de aspectos devem ser considerados para a concepção destes, além das necessidades impostas pela operação desses sistemas. A relevância adquirida por este problema é ainda maior, uma vez que se destinava a se obter projetos com o menor custo econômico possível e que pudessem satisfazer os requisitos necessários para que o sistema ofereça uma operação

adequada. Um evento que foi realizado na cidade de Nova York, em 1985, contribuiu significativamente para o desenvolvimento de técnicas de otimização. O evento contou com uma sequência de conferências denominadas “*The Battle of the Networks Models*”, diversos participantes tinham que apresentar soluções para uma rede hipotética. A rede deveria ser ampliada e essa ampliação deveria ser economicamente dimensionada (WALSKI, 1987). Esse problema ainda hoje é utilizado por diversos pesquisadores e cientistas como exemplo de referência na contratação da eficiência e eficácia de diversos métodos de otimização de sistemas de distribuição de água, conhecido como *New York Tunnels Problem*.

O crescimento da computação possibilitou o desenvolvimento de vários estudos na área de otimização de sistemas de distribuição de água, possibilitando o surgimento de novas técnicas. Diante de uma análise dos últimos trabalhos publicados, observa-se a grande variedade de modelos e métodos de dimensionamento, desde a enumeração exaustiva até algoritmos mais complexos e robustos. A enumeração exaustiva é uma técnica que simula todas as combinações possíveis, para os diâmetros comerciais de tubos, onde é identificada a melhor solução. A principal desvantagem que esta técnica apresenta é a grande quantidade de cálculos envolvidos, pois mesmo em pequenas dimensões como problemas com apenas 20 diâmetros, há um número enorme de soluções. A técnica do Gradiente de Programação Linear (GPL), que têm como algoritmo a programação linear e o método do gradiente, foi um das mais importantes métodos para o avanço do dimensionamento ótimo de redes (BHAVE; SONAK, 1992).

O GLP foi proposto por Alperovits & Shamir (1977) e seu processo de solução foi dividido em duas etapas: Primeiramente, os autores assumiram algumas vazões que obedeceram as equações de continuidade nos nós e calcularam o valor ótimo dos diâmetros usando programação linear. Em seguida, a vazão foi modificada usando o método do gradiente, sendo a solução dos diâmetros novamente calculada após cada modificação dessa vazão. Esta pesquisa trouxe os primeiros conceitos direcionados à otimização de redes hidráulicas, além disso, os autores consideraram diferentes estados de carga hidráulica nos seus projetos e enfatizaram que as decisões (dimensionamento de elementos) não podiam ser separadas das decisões operacionais.

Após Alperovits & Shamir (1977), diversos pesquisadores empregaram Programação Linear (PL) com o objetivo de tenta superar as deficiências de trabalhos anteriores, buscando redes mais econômicas (GESSLER, 1982; TUNG, 1985; QUINDRY; EBRILL; LIEBMAN, 1981; MORGAN; GOULTER, 1985, LANSEY; MAYS, 1989). Gessler (1982) tentou resolver o problema do alto número de combinações de diâmetros encontrado no GLP,

definindo grupos de tubos que teriam igual dimensionamento. Em seu trabalho, foi reconhecido que a maneira de agrupar tubos pode ser um fator determinante nos resultados obtidos. Então, uma boa escolha no conjunto de diâmetros que integrariam um determinado trecho seria o fator chave para obter bons resultados. Gessler (1982) fez menção à solução do bem conhecido problema da *New York Tunnels problem* (SCHAAKE; LAI, 1969) e comparou seus resultados com outras soluções obtidas usando o método de gradiente.

Em 1997, Silva (1997) utilizou o método da Programação Não Linear (PNL) como alternativa de algoritmo aplicado no dimensionamento de redes ramificadas destinada a aumentar a confiabilidade do sistema e melhorar a performance computacional, neste algoritmo, a função objetivo utiliza uma ou mais funções de restrição. Estas últimas podem ser lineares e/ou não lineares.

No início do século, Gomes & Formiga (2001) apresentaram o PNL2000, formulado e programado através da ferramenta Solver da planilha eletrônica Excel<sup>®</sup> da Microsoft. A metodologia de dimensionamento utiliza o modelo matemático da Programação Não Linear e divide-se em duas etapas. Na primeira, faz-se um pré-dimensionamento do sistema, tendo como variáveis a serem determinadas a altura manométrica de cabeceira, os diâmetros e as vazões dos trechos. Em seguida, com os resultados obtidos, realiza-se uma segunda etapa, no objetivo de corrigir os valores dos diâmetros encontrados anteriormente fazendo coincidir as bitolas encontradas com as nominais disponíveis no mercado. Este método aplica-se a redes ramificadas ou malhadas com cota piezométrica de cabeceira fixa ou variável.

Gomes & Bezerra (2005) propuseram uma metodologia fundamentada no Método Granados (GRANADOS, 1990). O método estabelece uma solução inicial composta pelos diâmetros mínimos que, por meio de um processo iterativo, são modificados à medida que a cota piezométrica de cabeceira diminui, obtendo um novo custo para o projeto da rede de distribuição. O processo iterativo é concluído quando o custo de intervenção nos trechos superar o custo energético. No seu processo iterativo, o método utiliza-se do conceito do Gradiente de Câmbio (GRANADOS, 1990).

Costa, Castro & Araújo (2006) desenvolveram um modelo, que adotou a programação linear (método simplex) associada ao EPANET 2, para minimizar os custos de uma rede de distribuição de água. O algoritmo aumenta o diâmetro dos trechos conectados em nós com déficit de pressão e diminui o diâmetro dos trechos conectados em nós com excesso de pressão. Todos os cálculos hidráulicos são executados no EPANET 2 e o algoritmo só finaliza quando não são solicitadas mudanças nos trechos. Em seguida, Gomes *et al.* (2009) desenvolveram um algoritmo iterativo que busca otimizar utilizando os conceitos de gradiente

energético e gradiente de pressão, a metodologia apresentou bons resultados de dimensionamento, entretanto não considerava as variáveis de estado (pressão e velocidade da água) durante o processo iterativo.

Mesmo fazendo-se uso de uma maior capacidade de processamento dos computadores atuais, ainda seria muito difícil conseguir a solução ideal do dimensionamento de redes utilizando apenas métodos de modelagem tradicionais em um problema de tamanho significativo. Para realizar a análise dos diferentes cenários, para que seja encontrada uma solução ideal para o problema, é necessário usar um método que faça uma seleção dos cenários avaliados, sendo este subconjunto selecionado consideravelmente menor do que o conjunto total de possibilidades. Resolver esta situação tem sido um dos elementos iniciais que promoveu o uso de algoritmos evolucionários na busca de soluções para o problema de otimização de sistemas de distribuição de água.

Os algoritmos evolucionários são ferramentas de busca estocástica fundamentados na inteligência coletiva proveniente da auto-organização e do comportamento adaptativo da sociedade de certos animais e vêm apresentando bons resultados para o dimensionamento de sistemas de distribuição de água. O *Genetic Algorithm* (GA), em português Algoritmo Genético, é o mais conhecido dessa classe e tem sido amplamente utilizados na análise dos diversos problemas inerentes às redes de abastecimento de água, sua descrição e funcionamento foram retratados no item 3.3.1. Simpson, Dandy & Murphy (1994) aplicaram esta técnica de otimização ao projeto de redes hidráulicas com resultados melhores que as pesquisas anteriores. Em seguida, muitas outras pesquisas apresentaram a incorporação de algumas melhorias à técnica com a finalidade de melhorar o desempenho computacional e precisão na busca do ótimo (DANDY; SIMPSON; MURPHY, 1996; SAVIC; WALTERS, 1997; MONTESINOS; GARCÍA-GUZMÁN; AYUSO, 1999; MATÍAS, 2003; MOTA, 2007; MONTALVO *et al.*, 2008; PINNTO, *et al.*, 2017).

Sousa & Cunha (1998) aplicam o *Simulated Annealing* (SA), em português Reconhecimento Simulado. As redes *Hanoi Network* e a *The New York Tunnels Problem* foram usadas como casos de estudo pelos autores, de modo que os resultados puderam ser comparados com outros métodos para resolver os mesmos problemas. Essas duas redes são problemas clássicos aplicados ao projeto ideal e serão discutidos com mais detalhes mais adiante. Em Cunha & Sousa (1999), o método também foi aplicado à rede tradicional de Alperovits & Shamir (1977).

Eusuff & Lansey (2003) mostram o projeto de redes de distribuição de água a partir do uso de um algoritmo evolutivo chamado "*Shuffled Frog Leaping*". Este algoritmo foi

projetado para trabalhar com variáveis discretas e tem alguns pontos em comum com o funcionamento do *Particle Swarm Optimization* (KENNEDY; EBERHART, 1995) e a *Shuffled Complex Evolution* (DUAN; SOROOSHIAN; GUPTA, 1992). Durante a busca de soluções, o EPANET (ROSSMAN, 2000) é usado para realizar a análise de soluções potenciais. O problema de otimização foi levantado sem consideração de elementos relacionados à confiabilidade das redes. Apenas o dimensionamento dos tubos foi considerado e o projeto de outros elementos do sistema de distribuição não foi contemplado. Como casos de estudo, a *Hanoi Network* foi utilizada, uma das redes apresentada em Alperovits & Shamir (1977) e a *New York Tunnels Problem*. Várias comparações foram feitas com os resultados obtidos em outras pesquisas. A partir deles, pode inferir-se que o algoritmo tenha tido bons resultados na busca de soluções.

Wu & Simpson (2002) usaram um *Genetic Algorithm* modificado e apresenta uma maneira do fator de penalidade evoluir dentro do mesmo esquema do algoritmo. Os pesquisadores mostraram, para o caso da *New York Tunnels Problem*, as vantagens de usar um fator de penalidade adaptativo em vez de um fixo. Os valores muito pequenos do fator de penalidade levou a pesquisa ainda mais a regiões inviáveis do espaço da solução, enquanto o uso de altos valores do fator de penalidade restringiu a busca demais ao espaço viável, limitando a possibilidade para encontrar soluções próximas da fronteira com a região que não é viável.

Outro algoritmo evolutivo empregado no projeto de otimização de sistemas de distribuição de água tem sido a otimização da colônia de formigas (ACO). Diferentes trabalhos utilizaram esta proposta com bons resultados (MAIER *et al.*, 2003; ZECCHIN *et al.*, 2006; MONTALVO *et al.*, 2008), porém estes não aplicaram esta técnica em redes de grande porte. Os algoritmos ACO são inspirados na organização social das formigas (DORIGO; MANIEZZO; COLORNI, 1996), sua descrição e funcionamento foram retratados no item 3.3.3. Abebe & Solomatine (1998) apresentaram modelos de otimização, *Adaptive Cluster Covering with Local Search* (ACCOL) e GA, ativaram a escolha entre precisão e tempo de processamento computacional. Liong & Atiquzzaman (2004) aplicaram um poderoso algoritmo de otimização, *Shuffled Complex Evolution* (SCE), para a busca de soluções com baixo tempo de processamento. Gomes, Bezerra e Srinivasan (2008) propõe um método iterativo, com relativamente baixo tempo de processamento, para a otimização do custo total para a expansão e reabilitação de Redes de Distribuição de Água.

Reca & Martínez (2008) apresentaram uma comparação entre quatro algoritmos evolutivos na otimização de redes de distribuição de água: *Genetic Algorithm*, *Simulated*

*Annealing*, *Iterated Local Search* com *Simulated Annealing* e, finalmente, o último mescla *Simulated Annealing* e *Tabu Search*. Somente o custo do investimento inicial em tubos e o cumprimento das restrições de projeto foram considerados na pesquisa. Não foi empregada nenhuma medida da confiabilidade das soluções, uma vez que o trabalho visava apenas a comparação dos algoritmos mencionados. Duas redes foram usadas como exemplos: a *Hanoi Network*, que foi executada dez vezes e a *Balerma Network*, que é uma rede de irrigação alimentada por 4 reservatórios, com 443 nós de demanda, 454 tubos e 8 malhas (RECA; MARTÍNEZ, 2006), utilizada, também, neste trabalho de pesquisa. Um número fixo de iterações foi estabelecido para cada algoritmo para colocá-los em condições iguais. Os resultados mostraram que, para a *Hanoi Network*, o *Genetic Algorithm* obteve a melhor solução, no entanto, a média das 10 soluções obtidas mostrou seu pior valor também no caso de *Genetic Algorithm*. Para a *Balerma Network*, que foi consideravelmente maior, a melhor solução foi obtida através da combinação de *Simulated Annealing* e *Tabu Search*.

Bragalli *et al.* (2015) apresentaram uma nova abordagem para aumentar a eficiência dos métodos heurísticos aplicados ao projeto ótimo de sistemas de distribuição de água. A abordagem baseia-se na redução do espaço de pesquisa limitando os diâmetros que podem ser usados para cada canal de rede. Para reduzir o espaço de busca, dois cenários opostos de distribuição de vazão são analisados juntamente com restrições de velocidade nos tubos. O primeiro cenário produz a distribuição de vazão mais uniforme na rede. O cenário oposto é representado pela rede com máxima vazão. Ambas as distribuições de vazão são calculadas resolvendo um problema de programação quadrática, que é um procedimento muito robusto e eficiente. Esta abordagem foi acoplada a um *Genetic Algorithm*. O GA possui um esquema de codificação de números inteiros e um número variável de alelos, dependendo do número de diâmetros compreendidos dentro das restrições de velocidade. A metodologia foi aplicada a várias redes de referência e seu desempenho foi comparado a uma formulação clássica do Algoritmo Genético.

Choi *et al.* (2017) propôs cinco métodos para melhorar a qualidade de soluções de problemas de otimização de rede de distribuição de água: três *Warm Initial Solution Methods*, um *Postoptimization Method*, em português Método de Pós-otimização e um *Guided-Search Method*. Os cinco métodos foram demonstrados por meio de um estudo de resiliência da *Hanoi Network*. O *Guided-Search Method* foi aplicado em redes de referência bem conhecidos (ou seja, *Two-Loop Network*, *Hanoi Network*, *Balerma Network* e *P-city Network*), e considerando o intervalo razoável de variáveis de decisão, foi identificado como o melhor método em relação a não organização e diversidade das soluções obtidas, quando

comparado com cinco algoritmos de otimização multiobjetivo amplamente usados na comunidade científica em projetos de otimização de redes de distribuição de água.

As soluções propostas para a otimização de sistemas de distribuição de água ainda estão sendo desenvolvidas, principalmente, porque não existe uma metodologia completamente aceita pela comunidade científica e técnicos do setor. Existem várias tentativas feitas com base em princípios semelhantes, mas com alcances e objetivos diferentes. Apesar da variedade, existem pontos em comum na maioria deles. É generalizado e determinante o uso de computadores para realizar o processo de solução. As soluções são obtidas por meio de métodos iterativos, nos quais algumas vezes intervêm vários estágios que subdividem o problema original e interagem uns com os outros.

Do ponto de vista dos algoritmos de otimização, deve-se mencionar que este trabalho baseou-se no algoritmo conhecido como *Particle Swarm Optimization*, desenvolvido por Kennedy & Eberhart em 1995. O PSO é um algoritmo evolucionário que utiliza a inteligência do enxame para alcançar o objetivo de otimizar uma determinada função objetivo. A busca de soluções a partir do uso do PSO oferece uma alta flexibilidade para a abordagem da função objetivo do problema de otimização com o qual é trabalhado. Isto representa uma grande vantagem para poder enriquecer a forma como os modelos de sistemas de distribuição de água podem ser avaliados ou economicamente quantificados.

Durante o desenvolvimento desta pesquisa, foi feita uma alteração do comportamento de comunicação entre as partículas presentes no PSO. A proposta do novo algoritmo foi chamada de *Particle Swarm Optimization* de Topologia Local-Global (PSO-TLG), precisamente porque interfere no tipo de topologia que está intrinsecamente ligada à comunicação entre as partículas de todo enxame, com a finalidade de se obter bons resultados ótimos em um tempo computacional aceitável.

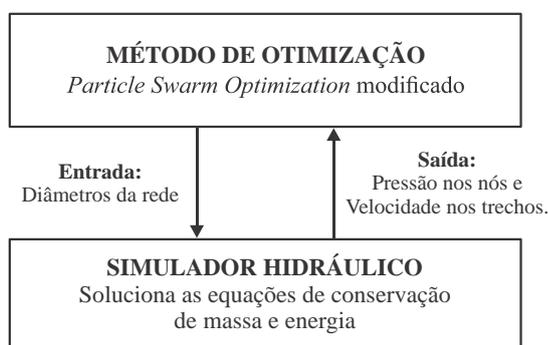
## 4 METODOLOGIA

A pesquisa objetivou o desenvolvimento de um modelo fundamentado na técnica de otimização *Particle Swarm Optimization* (PSO). O algoritmo foi desenvolvido e implementado no *software* Matlab<sup>1</sup>, visando a minimização dos custos do projeto e o aperfeiçoamento da performance computacional, por meio da redução da aleatoriedade nos procedimentos de cálculo.

O modelo foi desenvolvido no Matlab, com o EPANET 2.00.12 sendo adotado para determinar os parâmetros hidráulicos dos sistemas de distribuição de água por meio da biblioteca executável Epanet2.dll. Este arquivo é do tipo DLL (*Dynamic-Link Library* – Biblioteca de Vínculo Dinâmico), e é disponibilizado pela Agência de Proteção Ambiental (*Environment Protection Agency*) dos Estados Unidos. A “comunicação” entre os programas se realiza através de arquivos do tipo “inp” (formato disponível de salvamento da rede no EPANET).

O processo iterativo funciona da seguinte forma: O modelo de otimização gera as soluções (conjuntos de diâmetros) que são avaliadas pelo modelo de simulação hidráulica (EPANET), o qual processa a informação e resolve as equações de conservação de massa e energia, determinando os valores de pressões em cada nó e a velocidade em cada trecho da rede. Em seguida esses valores retornam ao modelo de otimização, dando continuidade ao processo de cálculo da função objetivo e, conseqüentemente, ao processo de otimização. Este processo é representado, de maneira simplificada, na Figura 4.

Figura 4 – Processo iterativo entre o modelo de otimização e o simulador hidráulico.



Fonte: Autor.

<sup>1</sup> O Matlab (*Matrix Laboratory*) é um programa de cálculo científico de grande versatilidade que rapidamente se difundiu junto da comunidade científica e acadêmica devido à facilidade de execução de operações matemáticas envolvendo matrizes, sendo hoje uma aplicação informática amplamente utilizada (ALMEIDA, 2010). Este programa dispõe de uma linguagem de programação própria semelhante a outras como o Fortran ou o Microsoft Visual C++ (ALMEIDA, 2010).

A fim de demonstrar a eficácia do modelo desenvolvido, este será aplicado a três redes de distribuição de água referências da literatura: *Hanoi Network problem* (FUJIWARA; KHANG, 1990), *New York Tunnels problem* (SCHAAKE; LAI, 1969), como o projeto de uma rede real e complexa: *Balerna Network* (RECA; MARTÍNEZ, 2006).

Após a análise do método aqui desenvolvido, os resultados (dimensionamentos ótimos) das redes foram comparados com os obtidos por outros métodos apresentados na literatura. O modelo foi avaliado e alguns dos seus parâmetros foram ajustados por meio de avaliações heurísticas, considerando além do custo mínimo, outros fatores, como, por exemplo, a obtenção de boas soluções com um menor número de iterações e/ou tempo computacional, além da determinação de um índice de eficiência que considere critérios de qualidade para as soluções.

No EPANET, a equação de perda de carga pode ser dada pela equação de Darcy-Weisbach ou a de Hazen-Williams. A escolha de qual equação será utilizada dependerá das informações disponíveis em cada problema avaliado, mantendo assim os dados de entrada das redes de distribuição de água para a devida comparação dos resultados. Todas as análises foram realizadas em um notebook com processador Intel i5 com 2,53 GHz e 4 GB de memória RAM.

#### 4.1 FORMULAÇÃO NUMÉRICA E PENALIZAÇÃO

O custo de implantação da tubulação de um sistema de distribuição de água é expresso pela expressão matemática que melhor relaciona o custo de implantação unitário (que inclui o custo do tubo, das peças de conexão, e as despesas com escavação e montagem) com o diâmetro interno do tubo. Nesta pesquisa, a otimização da rede consiste em achar os diâmetros que compõem o melhor custo.

Diante disso, as soluções do dimensionamento, que representam um conjunto de diâmetros, são definidas no espaço de soluções e avaliadas por meio da função objetivo (por exemplo, segundo a Equação 2). À medida que se altera um diâmetro da rede, todos os parâmetros hidráulicos se modificam e, geralmente, a composição da rede que possui todos os trechos com tubulações de diâmetros mínimos disponíveis não satisfarão as restrições de dimensionamento impostas nos projetos.

Com isso, para um bom funcionamento da rede de distribuição, pressões mínimas devem ser satisfeitas e a função objetivo deve levar em consideração tais pressões, evitando assim a adoção de diâmetros que não proporcionam o valor mínimo de pressão requerida.

Para isso, a função objetivo deverá atribuir uma penalização a cada nó que não satisfaça a pressão mínima especificada, fazendo com que a partícula penalizada se torne inviável ou infactível. Como é expresso na Equação 16.

$$f(D_1, D_2, \dots, D_m) = \sum_{i=1}^m C(D_i, L_i) + \sum_{k=1}^n (p_{k,min} - p_k) \quad (16)$$

onde  $p_{k,min}$  é a pressão mínima requerida no nó  $k$  em mca;  $p_k$  é a pressão no nó  $k$  em mca; e  $n$  é o total de nós na rede.

#### 4.2 PRÉ-SELEÇÃO DE PARTÍCULAS

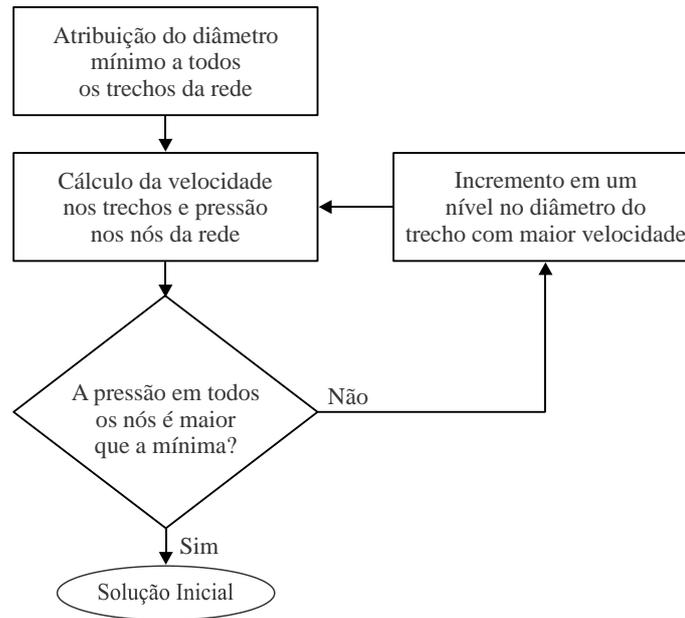
No PSO padrão, o processo de otimização inicia-se de modo não criterioso. As partículas apresentam um conjunto de diâmetros que foram selecionados aleatoriamente no espaço de busca das variáveis de decisão. Nesta seleção, diversas soluções são infactíveis e apresentam custos elevados devido à alta penalização sofrida pelo não cumprimento da restrição de pressão.

A aleatoriedade presente na seleção inicial da população de partículas pode se tornar um fator crítico na eficiência e eficácia do método. Isto é, especialmente, verdadeiro para problemas com um grande número de variáveis de decisão (CUNG *et al.*, 1996).

O modelo desenvolvido nesta pesquisa faz uma pré-seleção desses diâmetros, eliminando combinações não factíveis, objetivando a minimização do custo computacional decorrente da aleatoriedade. O Fluxograma 3 descreve a metodologia sugerida nesta pesquisa para encontrar os diâmetros da solução inicial, que será a base para a geração da população inicial (conjunto inicial de soluções).

O processo funciona da seguinte forma: Primeiramente, é atribuído o menor diâmetro disponível a todos os trechos da rede. Em seguida, é calculada a velocidade em cada trecho e a pressão em cada nó da rede. Se algum nó não atingir o limite de pressão estabelecido, o diâmetro do trecho de maior velocidade é aumentado para o subsequente diâmetro disponível. Esse processo é repetido até que todos os nós da rede estiverem com pressão maior ou igual à mínima pré-definida.

Fluxograma 3 – Composição da solução inicial.



Fonte: Autor.

Uma vez que a atualização dos diâmetros é concluída e todas as pressões estejam acima do valor mínimo, o conjunto se torna factível e será utilizado como solução base, que dará origem as populações avaliadas pelo método de otimização. O espaço de busca será composto pelas soluções cujos diâmetros são iguais ou superiores aos da solução base em todos os trechos, simultaneamente.

Ainda haverá uma pequena aleatoriedade na obtenção dos diâmetros em cada partícula das populações, porém com restrições, por exemplo, a seleção do diâmetro de cada trecho é feita de forma aleatória tendo como restrição de valor mínimo o diâmetro obtido na solução base, garantindo que as demais partículas sejam factíveis. Esta abordagem ajuda a diminuir o tempo de processamento computacional do modelo, de modo a melhorar a convergência do processo de busca.

#### 4.3 PSO DE TOPOLOGIA LOCAL-GLOBAL (PSO-TLG)

Este tópico visa apresentar a Topologia Local-Global proposta para o modelo de otimização por enxame de partículas. São detalhados conceitos teóricos, propriedades específicas e a estrutura relacionada a essa nova Topologia.

### 4.3.1 Estrutura da Topologia Local-Global

A nova topologia proposta neste trabalho para o PSO é denominada de Topologia Local-Global (PSO-TLG). O PSO-TLG é inspirado na hibridização das topologias adotadas separadamente no PSO “padrão”, as Topologias Local e Global. Esta nova topologia consiste na combinação dessas duas, havendo uma distinção Topológica entre as partículas de todo enxame.

Cada partícula do enxame poderá estar sob Topologia Local ou Global, isto é, algumas partículas selecionadas sequencialmente estarão sob Topologia Global e suas posições serão influenciadas por todo enxame, e as demais estarão sob Topologia Local, havendo somente influencia de seus vizinhos diretos. Este híbrido unirá aspectos relevantes presentes nas duas topologias, fazendo com que a capacidade de exploração de todo enxame melhore, e que ao mesmo tempo forneça maior qualidade à solução final obtida pelo algoritmo.

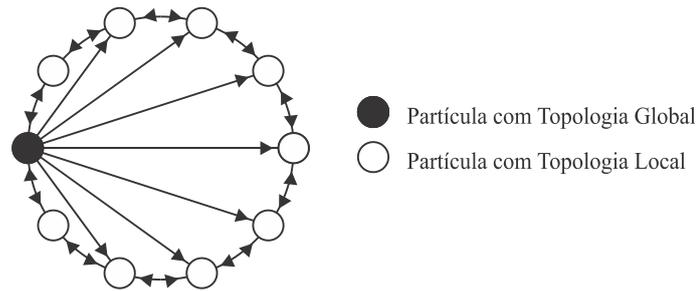
O PSO-TLG proposto tende a superar as desvantagens do PSO “padrão”, evitando ótimos locais e acelerando a velocidade de convergência, combinando as buscas locais e globais. O algoritmo deve explorar novos espaços para evitar a captura de soluções em um ótimo local nas etapas iniciais do modelo.

### 4.3.2 Comunicação da Topologia

Um dos grandes problemas enfrentados pelo PSO de Topologia Global na busca da melhor solução é a prematura convergência em mínimos locais. Em problemas multimodais não lineares, que possuem como característica as regiões com mínimos locais, o enxame tende a convergir rapidamente e com isso tende a crescer a probabilidade do enxame ficar preso em um mínimo local (SHI; EBERHART, 1998a). No que se refere à Topologia Local, esta apresenta bons resultados na busca de ótimo global devido ao aumento da exploração que é proporcionado a busca, porém, essa exploração aumenta o tempo de iteração e consequentemente o custo computacional, apresentando assim desvantagens significativas.

Segue na Figura 5 o esquema de comunicação (representado por linhas) da Topologia Local-Global entre dez partículas. Neste esquema, 10% das partículas (1 partícula dentre 10) estão sob Topologia Global, e as demais estão sob Topologia Local. As posições das partículas sob Topologia Global são influenciadas pela melhor solução encontrada no enxame. Estas partículas ajudam a disseminar esta informação, guiando às demais partículas para a região que possui o ótimo global, fazendo com que partículas sob Topologia Local explorem a região mais efetivamente.

Figura 5 – Comunicação ente partículas na Topologia Local-Global.



Fonte: Autor

### 4.3.3 Algoritmo PSO com a Topologia Local-Global

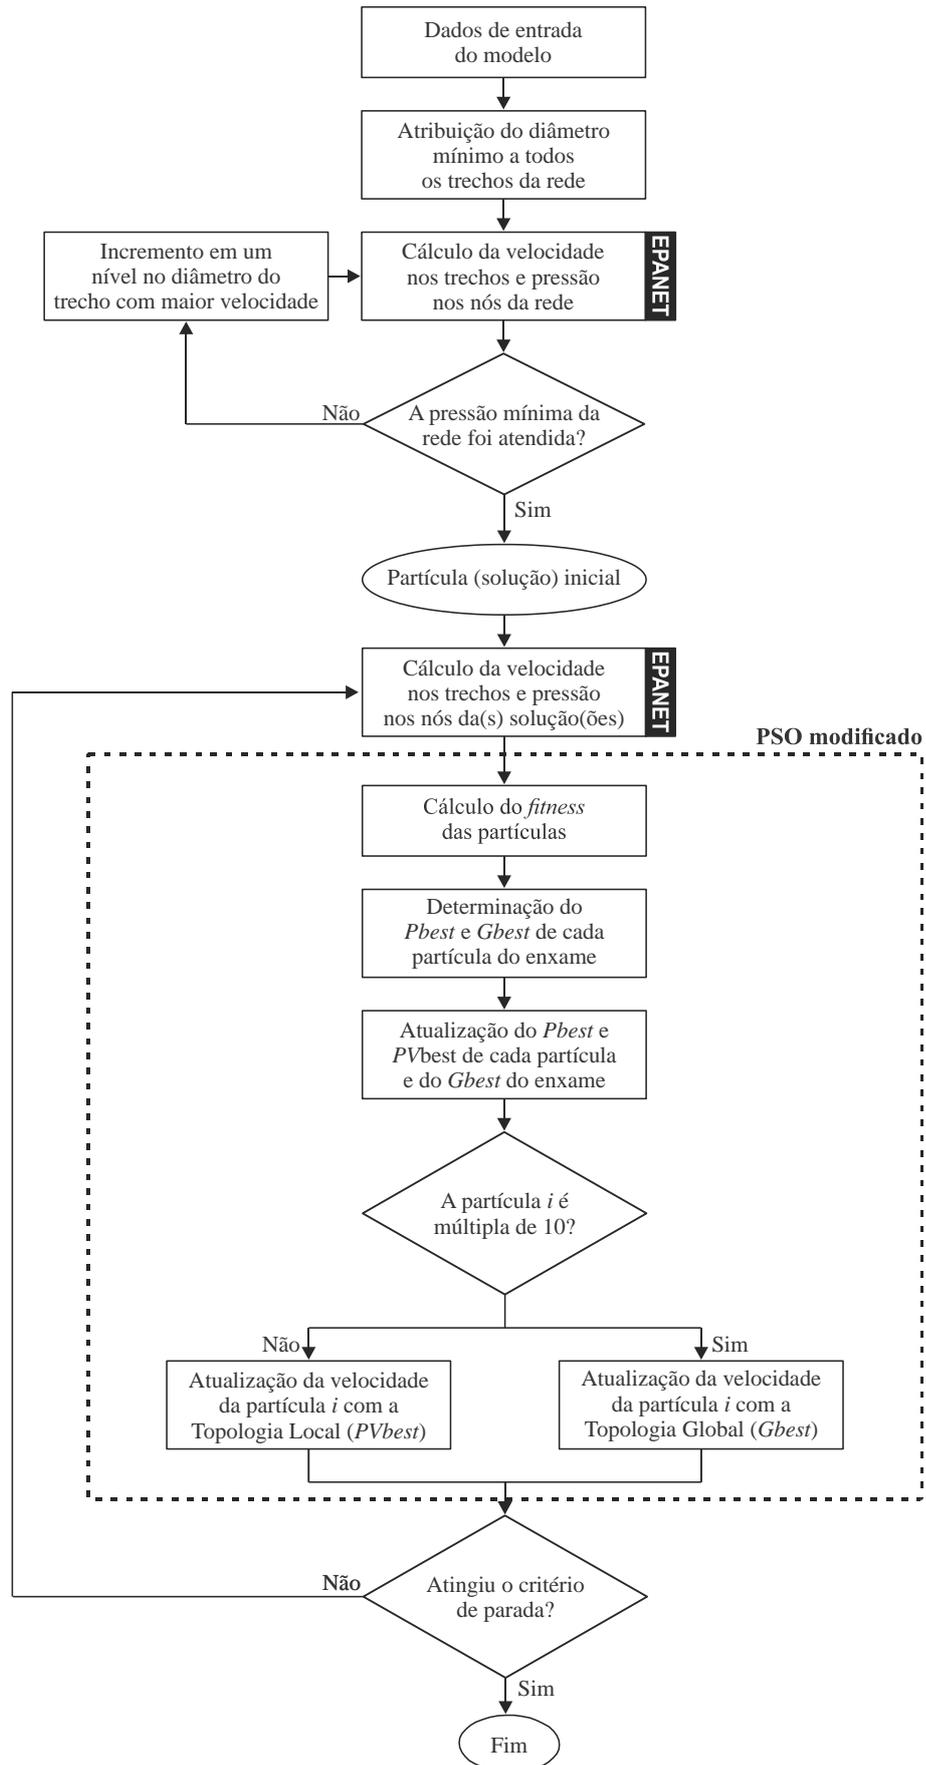
O algoritmo de otimização por enxame de partículas sofre algumas modificações com o esquema de comunicação proposto pela Topologia Local-Global. Diferente das topologias global e local separadamente, em que as partículas são agrupadas em uma única estrutura, a nova topologia seleciona as partículas direcionando-as a alguma Topologia específica (Local ou Global).

No PSO básico de Topologia Global, uma destas etapas é a definição do *Pbest* e *Gbest* inicial, que representam a melhor posição encontrada pela partícula e pelo enxame, respectivamente. A maneira como é realizada a escolha e atualização do *Pbest* não é influenciada com o uso do PSO-TLG, visto que como se trata do conhecimento individual da partícula, todas as partículas do enxame definem o *Pbest* de forma semelhante, ao contrário do *Gbest*, que no PSO-TLG é o termo variante. Para as partículas sob Topologia Global o conceito do *Gbest* permanece intacto (definido como a melhor posição encontrada por todo enxame), enquanto que para as partículas sob topologia Local, o *Gbest* é substituído *PVbest*, que é definido como sendo a melhor posição entre seus vizinhos diretos.

O PSO “padrão” aplica, geralmente, as Topologias Global ou Local na busca de soluções ótimas por serem mais conhecidas e utilizadas. No processo de busca do PSO-TLG, uma determinada porcentagem de partículas estará sob Topologia Global e as demais sob Topologia Local. As partículas sob Topologia Global conduzirão as demais a extrapolar mais rápido o campo de busca, e nessa extrapolação as partículas de Topologia Local varreram melhor o local, diminuindo as chances de uma prematura convergência em um ótimo local, ou seja, fugindo dos ótimos locais, melhorando assim a precisão da busca.

O Fluxograma 4 apresenta a metodologia do PSO-TLG, onde se observa o processo da definição e atualização do *Gbest* durante a execução do algoritmo (10% das partículas estão sob Topologia Global e 90% sob Topologia Local).

Fluxograma 4 – fluxograma básico do algoritmo PSO-TLG.



Fonte: Autor

O modelo terá como critério de parada o número máximo de iterações e uma tolerância que é contabilizada a partir do momento que há uma repetitividade do resultado, apontando assim a convergência do algoritmo, como é mostrado na Equação 17.

$$Tolerância = \frac{N^{rep}}{N^{total}} \quad (17)$$

onde  $N^{rep}$  é o número de vezes que determinado valor se repete e  $N^{total}$  é o número máximo de iteração pré-determinada. Os critérios de parada são definidos com o objetivo de obter o menor custo da rede de distribuição levando em consideração o tempo computacional despendido, ou seja, em um tempo aceitável.

## 5 RESULTADOS E DISCUSSÕES

O algoritmo de otimização *Particle Swarm Optimization* TLG, que incluem as modificações propostas neste documento, foi aplicado a três casos de sistemas de distribuição de água. Duas redes exemplos correspondem à *Hanoi Network problem* (FUJIWARA; KHANG, 1990) e *New York Tunnels problem* (SCHAAKE; LAI, 1969), que são clássicos na literatura científica relacionada ao projeto ótimo. O último estudo de caso é um projeto real e complexo: *Balerna Network* (RECA; MARTÍNEZ, 2006).

Como os algoritmos evolutivos não são determinísticos, uma vez que eles possuem componentes aleatórios que nem sempre obtêm a mesma solução para o mesmo problema, uma avaliação de sensibilidade foi realizada no *Hanoi Network problem*. Os resultados deste estudo permitiram estimar o quantitativo da população de partículas e a melhor configuração para o PSO-TLG. A adoção de parâmetros específicos para cada rede exemplo apresentaria melhores resultados, porém, optou-se pela definição de uma configuração “*default*” para o algoritmo, a fim de estabelecer uma configuração típica para quaisquer redes. Posteriormente, os resultados obtidos entre as Topologias de partículas existentes e a proposta neste trabalho ao algoritmo PSO são comparados.

### 5.1 HANOI NETWORK PROBLEM

A *Hanoi Network Problem* (Figura 6), em português Rede de Distribuição de Água de Hanoi, foi originalmente proposta por Fujiwara & Khang (1990) e, posteriormente, adotada por inúmeros pesquisadores (CUNHA; SOUSA, 1999; EUSUFF; LANSEY, 2003; LIONG; ATIQUZZAMAN, 2004; SURIBABU; NEELAKANTAN, 2006; ZECCHIN *et al.*, 2006; BRAGALLI *et al.*, 2015; CHOI *et al.*, 2017; SURIBABU, 2017).

A rede é composta por 3 anéis, 34 trechos, 32 nós e 1 reservatório de nível fixo com cota piezométrica de 100 mca. A pressão mínima exigida é de 30 mca em todos os nós. A fórmula de Hazen-Williams, com o valor da constante numérica de conversão  $\omega$  de 10,6792 adotado pelo EPANET 2.00.12, e o coeficiente de rugosidade de 130 foram adotados para o cálculo de perda de carga em todos os trechos.

Para resolver o problema, existem 6 possíveis diâmetros disponíveis e, embora aparentemente seja uma rede simples, existe neste caso  $6^{34} \approx 2,8 \times 10^{26}$  soluções potenciais. Analisar cada uma dessas soluções seria inviável na prática, e é por isso que é vantajoso explorar este grande espaço de soluções através do uso de algoritmos evolucionários.



Tabela 1 – Dados referentes a *Hanoi Network Problem*.

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

Fonte: Fujiwara & Khang (1990).

Os diâmetros mínimo e máximo considerados nessa rede exemplo são respectivamente de 12 e 40 polegadas. Na Tabela 2 são apresentados os diâmetros disponíveis e seus respectivos custos em (\$) por metro de tubulação (FUJIWARA; KHANG, 1990).

Tabela 2 – Custo das tubulações para a *Hanoi Network problem*.

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

Fonte: Fujiwara & Khang (1990).

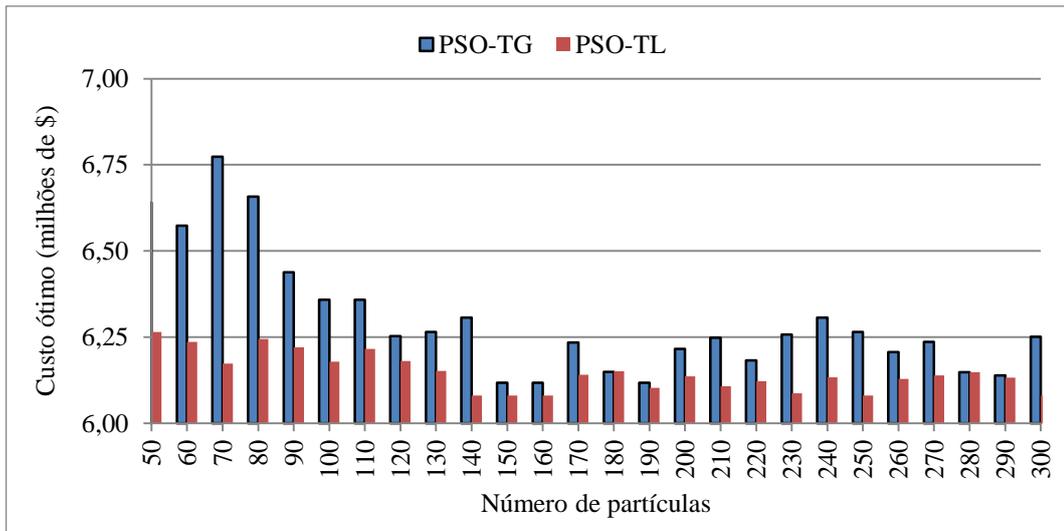
Inicialmente, o problema foi resolvido usando o algoritmo PSO padrão, contemplando as duas Topologias separadamente, e o algoritmo PSO-TLG, mas sem considerar a pré-seleção de partículas como descrito no item 4.2. A seleção dos parâmetros do algoritmo foi realizada a partir da avaliação de pesquisas publicadas por diversos autores, que foram direcionados a diferentes problemas de otimização usando PSO (por exemplo, JIN *et al.*, 2007; LIAO; TSENG; LUARN, 2007; SHI *et al.*, 2007). Os parâmetros com os quais os cálculos foram realizados são:

- $c_1=2$ ;
- $c_2=2$ ;
- $N^{\text{total}}=200$ ;
- Tolerância= 1/3;
- Fator de inércia ( $w$ ) calculado segundo a Equação 13;

Após a definição dos parâmetros citados, foram realizadas simulações para definir o número total de partículas do enxame. Para definir esse número, foram realizadas uma sequência de simulações com incremento de 10 partículas nas Topologias Global e Local (ver Gráfico 1), onde se definiu a quantidade de 150 partículas.

Além da definição do quantitativo de partículas do enxame, outras informações podem ser vistas ao analisar a Gráfico 1. Nota-se que as partículas com Topologia Local, quando comparado com a Topologia Global, atingiram valores próximos ao valor mínimo de  $\approx$  \$ 6,081 milhões encontrado na literatura, em todas as simulações, estando esse valor presente entre os números de 125 e 150 partículas. O custo total com Topologia Global foi de \$ 6,581 milhões, que corresponde a um acréscimo de 8,21% em relação à Topologia Local.

Gráfico 1 – Análise da influência do número de partículas no custo ótimo.



Fonte: Autor.

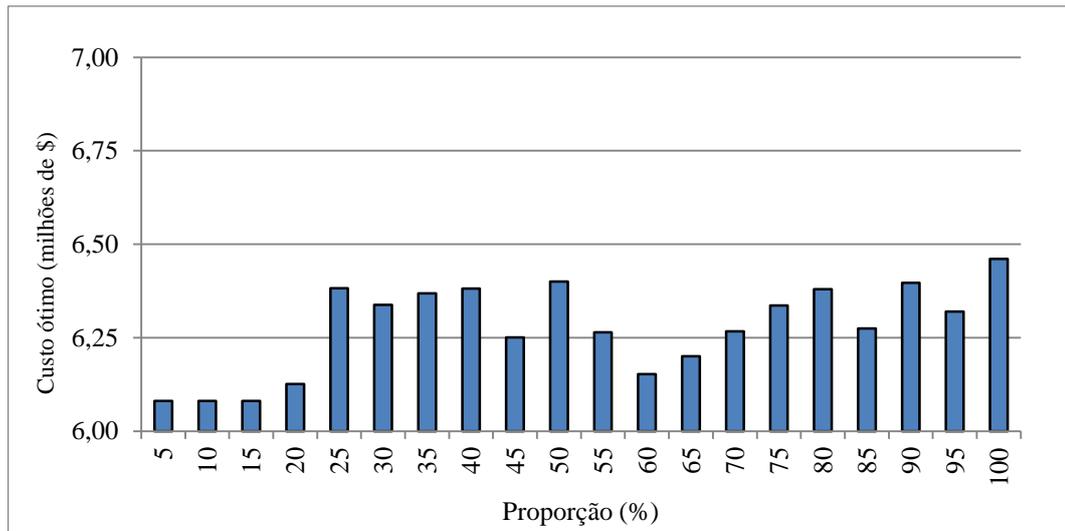
Como mencionado no item 3.4.2, a grande vantagem da Topologia Local é sua utilização em problemas com inúmeros mínimos locais, evitando convergências prematuras a ótimos locais, enquanto a maior desvantagem é o desempenho computacional, pois para a iteração de 150 partículas o PSO-TL executou em 2 minutos, enquanto que o PSO-TG foi em 0,5 minuto, uma diferença de 75% no tempo de processamento.

Para a definição da melhor configuração do PSO-TLG e sua influência na obtenção da solução ótima, foi realizada uma análise de sensibilidade para avaliar a proporção do número de partículas que serão avaliadas pelas Topologias Global e Local. Para isto, foram realizadas 20 simulações variando-se a proporção, presente na Equação 18, de 5 a 100%, com incremento de 5% entre as topologias Local e Global. O resultado deste processo é mostrado no Gráfico 2.

$$Prop(\%) = \frac{N^{PSO-TG}}{N^{PSO-TL}} \quad (18)$$

onde  $N^{PSO-TG}$  é o número de partículas, do total do enxame, sob topologia Global; e  $N^{PSO-TL}$  é o número de partículas, do total do enxame, sob topologia local.

Gráfico 2 – Análise de proporção entre o número de partículas sob topologias Local e Global.



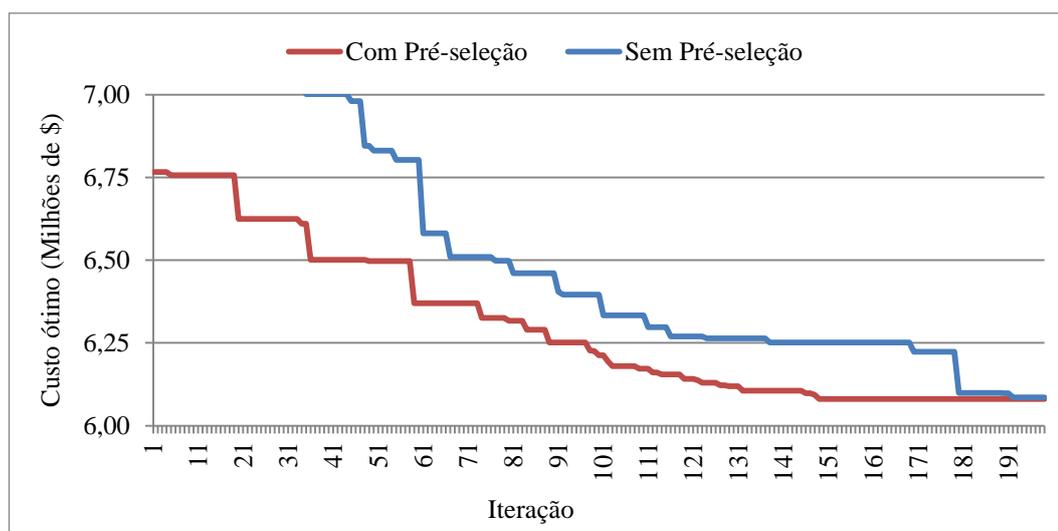
Fonte: Autor.

Ao analisar o Gráfico 2, percebe-se que o menor valor encontrado,  $\approx \$ 6,081$ , está presente no intervalo onde 5 a 15% das partículas são globais. Para a aplicação do PSO-TLG adotou-se o valor de 10%, tendo em vista que com um número maior de partículas sob a topologia Global haverá um favorecimento ao desempenho computacional, diminuindo o tempo de execução do algoritmo. Para 10% de partículas sob Topologia Global o tempo foi de 1,2 minutos.

É interessante notar que a medida que se aumenta o número de partículas sob Topologia Global há uma tendência ao aumento no valor do custo ótimo. Porém, a análise do comportamento destas simulações indicou que a inserção correta de partículas sob Topologia Global no processo de otimização não distorce a característica da Topologia Local, mas ajuda a guiar as soluções para regiões que contenham o mínimo Global, e assim elas possam fazer a varredura com maior precisão e rapidez.

O PSO-TLG foi executado com e sem a pré-seleção, mantendo um número de 150 partículas e o limite máximo de 200 iterações (valores fixados nas demais simulações), determinados inicialmente. Segue no Gráfico 3 o comportamento do custo ótimo ao longo do processo de otimização do PSO-TLG sem e com pré-seleção de diâmetros.

Gráfico 3 – Evolução do custo ao longo do processo de otimização com e sem pré-seleção.



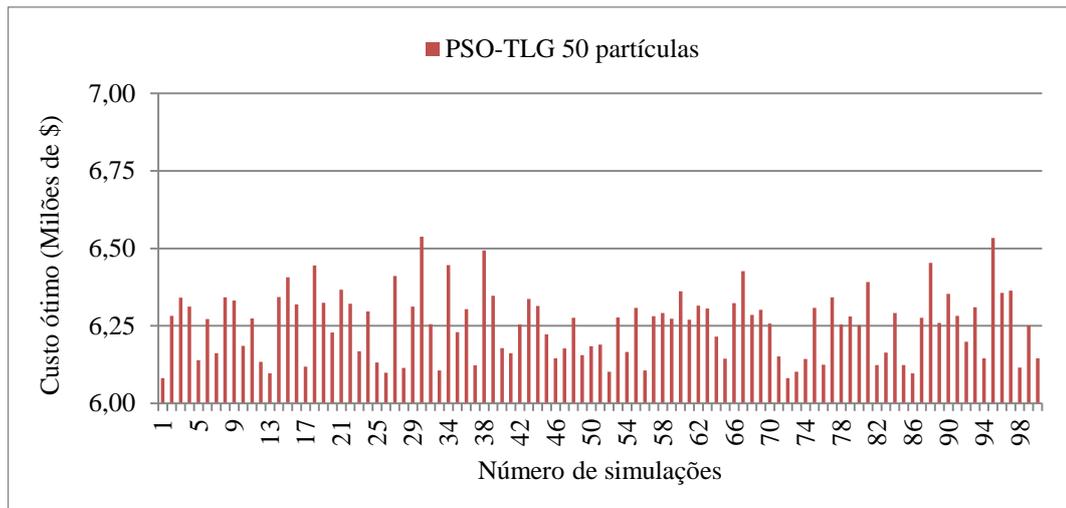
Fonte: Autor.

O resultado de aproximadamente \$ 6,081 milhões foi obtido com e sem pré-seleção de diâmetros, porém com a pré-seleção o tempo de processamento foi reduzido, chegando a 0,83 min ou 50 segundos. Uma redução de, aproximadamente, 69%, quando comparado ao valor de 1,2 min da execução do PSO-TLG sem pré-seleção de partículas.

Um maior número de partículas inseridas no campo de busca trará consigo uma melhor varredura por toda a área factível, entretanto como consequência haverá um aumento no tempo de execução, pois quanto mais partículas são inseridas, mais cálculos e análises o algoritmo terá que fazer. O PSO-TLG com pré-seleção mostrou eficiência na busca do custo ótimo, reduzindo o tempo de execução para a obtenção do valor ótimo. Diante disso, faz-se necessário a análise do PSO-TLG para diferentes números de partículas, verificando se o modelo permanece eficiente com essa determinada variação.

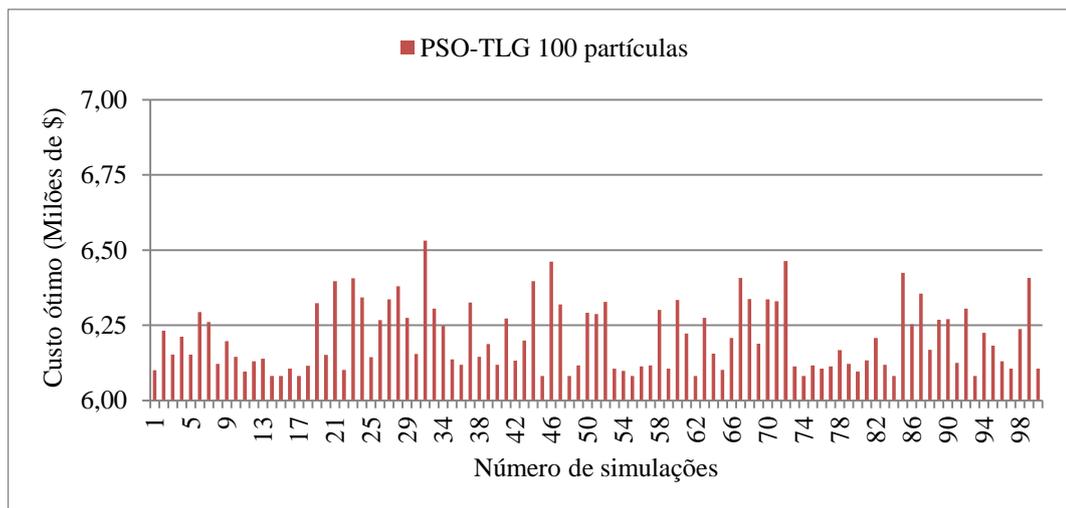
A análise foi realizada variando-se de 5 a 200 partículas com incremento de 5 partículas. As quantidades que apresentaram bons resultados foram próximas aos valores de 50, 100 e 150 partículas. Diante disso, 100 simulações foram realizadas com o PSO-TLG incorporando a pré-seleção de diâmetros proposta no item 4.2 para um número de 50 (Gráfico 4), 100 (Gráfico 5) e 150 (Gráfico 6) partículas separadamente, a fim de analisar a repetitividade do processo de cálculo do modelo.

Gráfico 4 – Resultado de 100 execuções do algoritmo PSO-TLG com pré-seleção e população de 50 partículas.



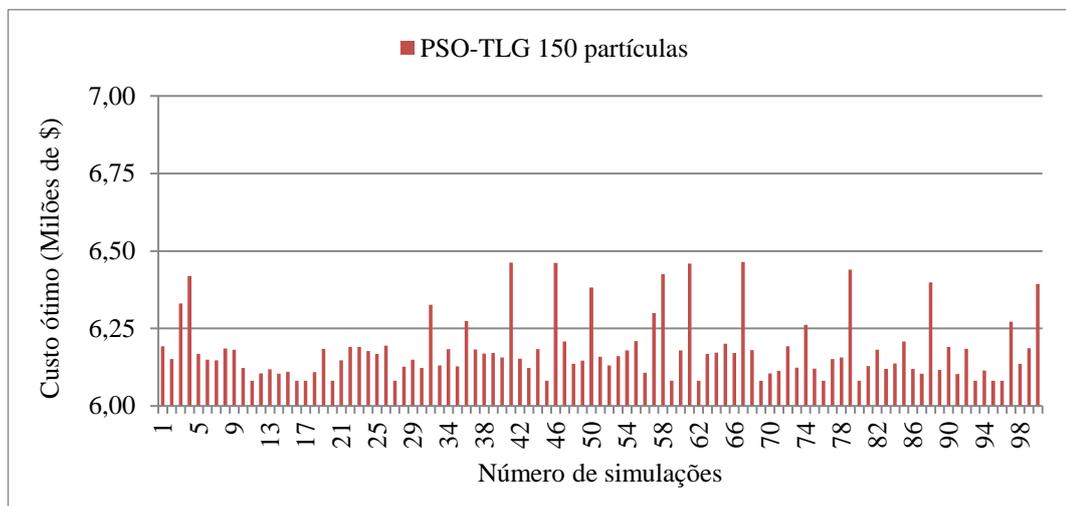
Fonte: Autor.

Gráfico 5 – Resultado de 100 execuções do algoritmo PSO-TLG com pré-seleção e população de 100 partículas.



Fonte: Autor.

Gráfico 6 – Resultado de 100 execuções do algoritmo PSO-TLG com pré-seleção e população de 150 partículas.



Fonte: Autor.

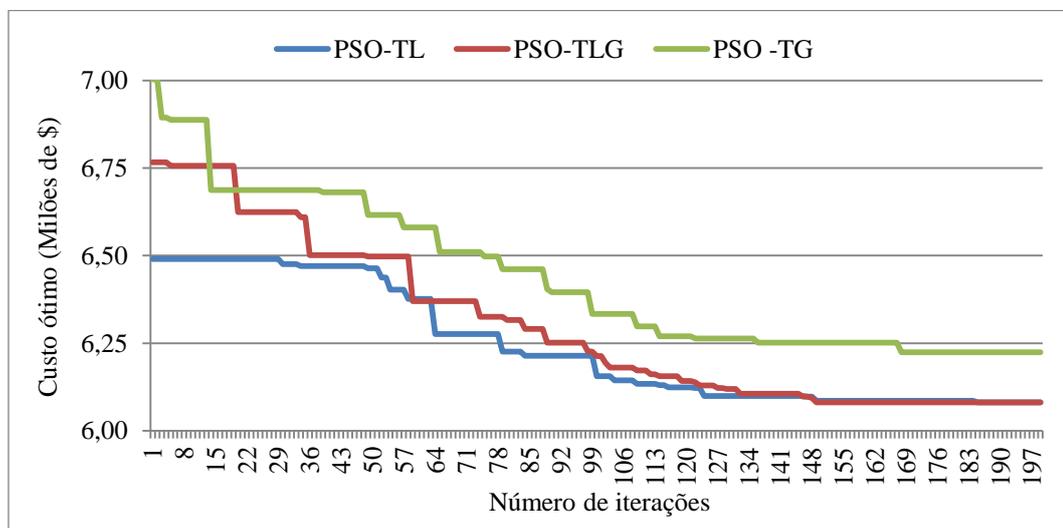
Ao analisar as Figuras 14-16, observa-se nitidamente que a quantidade de partículas influencia na repetitividade de boas soluções. O quantitativo de 150 partículas apresentou uma melhor estabilidade em torno da solução ótima, ou seja, em torno de 4,5 vezes o número de variáveis que problema possui (34 tubos), mantendo a proporção (Equação 19) em 10%.

Diante das análises realizadas, foram definidos os parâmetros e a configuração para o dimensionamento ótimo de sistemas de distribuição de água:

- $c_1=2$ ;
- $c_2=2$ ;
- $N^{total} = 200$ ;
- Tolerância= 1/3;
- População de partículas = 95 (4,5 vezes o número de variáveis); e
- Proporção entre topologias – Prop(%) = 10% (Equação 19);
- Com pré-seleção de partículas.

Em resumo, a solução obtida neste trabalho resultou em um custo ótimo de aproximadamente \$ 6,081 milhões. Esta solução foi obtida pelo PSO-TL e pelo o PSO-TLG, que por sua vez o PSO-TLG apresentou ganho significativo no tempo de execução. Este resultado corresponde ao valor ótimo apresentado na literatura. No Gráfico 7, tem-se a representação gráfica da evolução do PSO-TG, PSO-TL e o PSO-TLG. O PSO-TLG apresentou o mesmo resultado (ótimo) do PSO-TL, porém com uma redução média no tempo de processamento de, aproximadamente, 35% das simulações realizadas nesta pesquisa.

Gráfico 7 – Evolução do custo ao longo do processo de otimização (comparativo entre topologias).



Fonte: Autor.

A metodologia apresentada neste trabalho visa substituir o processo convencional de tentativa e erro de projetos de redes de distribuição de água por uma técnica que satisfaça as demandas e as pressões mínimas com um custo mínimo. Ademais, o algoritmo *Particle Swarm Optimization* TLG mostra-se particularmente efetivo ao oferecer ao projetista um conjunto de soluções sub-ótimas, uma vez que a cada simulação, têm-se como resultado um conjunto de soluções de baixo custo. Desta forma, o tomador de decisões pode escolher entre as alternativas com similaridade de preço, utilizando na análise outros critérios de avaliação para a escolha da solução, tais como possibilidades de ampliação, flexibilidade e facilidade de operação e critérios de confiabilidade.

Para ilustrar esta possibilidade, é apresentado na Tabela 3 um conjunto de configurações contendo a solução “ótima” obtida nesta pesquisa, pela Topologia Local e a Local-Global e uma solução sub-ótima obtida pela Topologia Global. Estas soluções sub-ótimas, quando comparadas aos resultados publicados na literatura, demonstram resultados satisfatórios, principalmente quando comparados aos resultados obtidos por Liong & Atiquzzaman (2004) e Gomes *et al.* (2009).

Tabela 3 – Resultados do dimensionamento ótimo da *Hanoi Network problem* (Diâm.).

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

Fonte: Autor.

Os resultados obtidos por outros pesquisadores da *Hanoi Network problem* foram utilizados como parâmetro de comparação das soluções obtidas neste trabalho. Na Tabela 4 são apresentados os resultados mais significativos para esta rede exemplo.

Tabela 4 – Comparação de dimensionamentos ótimos da literatura – Custos.

Referência	Método	Custo (10 <sup>6</sup> \$)	Pressão mínima (mca)
Cunha & Sousa (1999)	SA <sup>1</sup>	6,056*	29,59
Liong & Atiquzzaman (2004)	SCE <sup>2</sup>	6,220	30,05
Zecchin <i>et al.</i> (2006)	ACO	6,134	30,29
Gomes <i>et al.</i> (2009)	Lenhsnet	6,962	31,51
Bragalli <i>et al.</i> (2015)	GA-B <sup>3</sup>	6,081	30,13
Choi <i>et al.</i> (2017)	GS <sup>4</sup>	6,081	-
PSO-TLG		6,081	30,13

<sup>1</sup> *Simulated Annealing.*

<sup>2</sup> *Shuffled Complex Evolution.*

<sup>3</sup> *Genetic Algorithm* com redução do espaço de busca

<sup>4</sup> *Guided-Search*

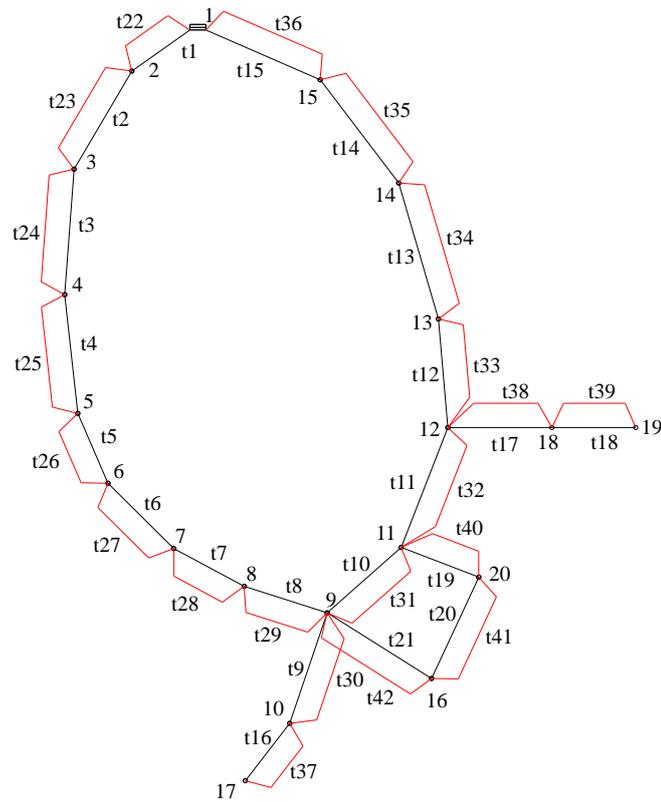
\*Foi adotado um  $\omega$ , Eq. 9, diferente do valor do EPANET 2.00.12.

O trabalho apresentado por Cunha & Sousa (1999) adotou o coeficiente  $\omega$  da fórmula de Hazen-williams igual a 10,5088, o que possibilitou aos autores um dimensionamento atendendo a restrição de pressão mínima igual a 30 mca.

## 5.2 NEW YORK TUNNELS PROBLEM

Na busca de economia no desenvolvimento de projetos de redes de distribuição de água, tanto para novas redes, como também para a expansão das existentes, um evento foi realizado na cidade de Nova York-EUA, em 1985, onde diversos participantes tinham que apresentar soluções “econômicas” de expansão da rede de distribuição de água da cidade de Nova York (WALSKI, 1987 *apud* SALVINO, 2009). Desde então, este estudo de caso conhecido por *New York Tunnels Problem* foi adotado por inúmeros pesquisadores (MAIER *et al.*, 2003; MONTALVO, *et al.*, 2008; SEDKI; OUZAR, 2012; MARCHI *et al.*, 2012).

O *New York Tunnels Problem*, Figura 7, foi apresentado por Schaake & Lai (1969). Essa rede é composta por 21 trechos, 19 nós e 1 reservatório de cota piezométrica de 91,440m. A pressão mínima admitida para a maioria de seus nós é de 77,724 mca. Para solucionar o problema de ampliação dessa rede, serão traçados trecho paralelos (t22-t42) aos existentes na rede para assim dimensioná-los utilizando o PSO-TLG.

Figura 7 – Layout do *New York Tunnels problem*.

Fonte: Autor.

Uma particularidade para implementação do algoritmo proposto nesta rede é a imposição de pressão mínima diferente para os nós 16 e 17, cujos valores são 79,248 mca e 82,906 mca, respectivamente. Esses nós possuem pressões mínimas maiores devido à previsão, no projeto original, que seriam pontos de futuras ampliações. Para o processo de otimização, a diferença de pressão pré-estabelecida será acrescida à cota geométrica. Todos os demais nós permanecem com cota zero. Assim é possível modelar pressões mínimas em diversos nós, com o artifício de incrementar a diferença de pressão em sua cota. O coeficiente de rugosidade de Hazen-Williams é igual a 100 para todas as tubulações. As demandas, as cotas geométricas e os diâmetros existentes na rede são apresentados na Tabela 5. Na Tabela 6 são apresentados os custos originais das tubulações, por metro, em função dos diâmetros adotados na *New York Tunnels problem*.

Tabela 5 – Dados referentes à *New York Tunnels problem*.

Nó	Demanda (L/s)	Cota (m)	Trecho	Comprimento (m)	Diâmetro (pol.)
1 (Res.)	-	91,44	t1	3535,68	180
2	2616,477	0	t2	6035,04	180
3	2616,477	0	t3	2225,04	180
4	2497,546	0	t4	2529,84	180
5	2497,546	0	t5	2621,28	180
6	2497,546	0	t6	5821,68	180
7	2497,546	0	t7	2926,08	132
8	2497,546	0	t8	3810,00	132
9	4813,864	0	t9	2926,08	180
10	2616,477	0	t10	3413,76	204
11	28,317	0	t11	4419,60	204
12	4813,864	0	t12	3718,56	204
13	3315,903	0	t13	7345,68	204
14	3315,903	0	t14	6431,28	204
15	2616,477	0	t15	4724,40	204
16	4813,864	1,524*	t16	8046,72	72
17	1628,219	5,425*	t17	9509,76	72
18	3315,903	0	t18	7315,20	60
19	3315,903	0	t19	4389,12	60
20	4813,864	0	t20	11704,32	60
			t21	8046,72	72

\*Nós com pressões diferentes, onde o incremento foi na cota geométrica.

Fonte: Dandy, Simpson & Murphy (1996).

Tabela 6 – Custo das tubulações para a rede *New York Tunnels problem*.

Diâmetro (pol)	Custo (\$/m)
36	306,76
48	439,63
60	577,43
72	725,07
84	875,98
96	1036,75
108	1197,51
120	1368,11
132	1538,71
144	1712,60
156	1893,04
168	2073,49
180	2260,50
192	2447,51
204	2637,80

Fonte: Dandy, Simpson & Murphy (1996).

Outro fator importante é a não alteração dos diâmetros existentes da rede na otimização, para isto o programa foi configurado para só considerar no cálculo de dimensionamento ótimo trechos específicos, eliminando os trechos t1-t21 do processo.

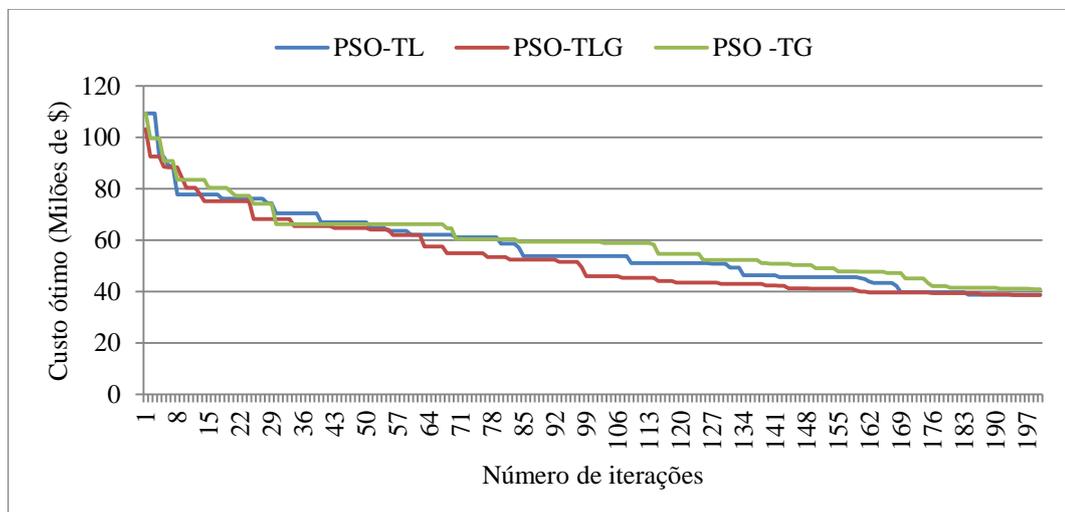
Nesta expansão da rede existente, talvez não seja necessário que haja modificação do trecho existente, ou seja, talvez não seja preciso a existência do trecho em paralelo, assim foi adicionado um tubo com custo zero e diâmetro 1 nestes trechos, e só será modificado se realmente for necessário para atender as condições hidráulicas e econômicas da rede.

A definição dos parâmetros do PSO modificado respeitam os mesmos critérios adotados e determinados no primeiro exemplo (item 5.1). Segue um resumo dos parâmetros:

- $c_1 = c_2 = 2$ ;
- $N^{total} = 200$ ;
- Tolerância = 1/3;
- Fator de inércia ( $w$ ) calculado segundo a Equação 13;
- Com Pré-seleção de partículas;
- População de partículas = 95 (4,5 vezes o número de variáveis); e
- Proporção entre topologias – Prop(%) = 10% (Equação 18);
- Com pré-seleção de partículas.

O Gráfico 8 mostra a evolução do dimensionamento do *New York Tunnels problem* para os métodos PSO-TG, PSO-TL e PSO-TLG. Apesar dos valores ótimos estarem bem próximos, o PSO-TLG apresentou o melhor resultado que as demais topologias, além de uma redução no tempo de execução de, aproximadamente, 62% quando comparado com o de maior tempo, conforme a Tabela 7.

Gráfico 8 – Evolução do custo ao longo do processo de otimização (comparativo entre topologias).



Fonte: Autor.

Tabela 7 – Tempo médio do processo de otimização.

Topologia	Tempo (min)
PSO-TG	1,3
PSO-TL	2,6
PSO-TLG	1,6

Fonte: Autor.

No dimensionamento do *New York Tunnels problem* pelo PSO-TG, PSO-TL e o PSO-TLG, alguns trechos foram modificados e outros não, sugerindo apenas a implantação dos trechos necessários como é mostrado na Tabela 8, e suas respectivas pressões nodais na Tabela 9.

Tabela 8 – Resultados do dimensionamento ótimo da *New York Tunnels problem*.

ID Trecho	Diâmetro (pol.)		
	Topologia Global	Topologia Local	Topologia Local-Global
22	0	0	0
23	0	0	0
24	0	36	0
25	36	0	0
26	36	0	0
27	0	0	0
28	132	132	144
29	0	0	0
30	0	0	0
31	0	0	0
32	0	0	0
33	36	0	0
34	0	0	0
35	0	0	0
36	0	0	0
37	96	96	96
38	96	96	96
39	84	84	84
40	72	72	72
41	0	0	0
42	72	72	72
Custo ótimo (\$)	40.849.756	38.811.448	38.637.708

Fonte: Autor.

Tabela 9 – Resultados das pressões resultantes nos nós da *New York Tunnels problem*.

ID Nós	Pressão (mca)		
	Topologia Global	Topologia Local	Topologia Local-Global
2	89,68	89,68	89,67
3	87,23	87,23	87,22
4	86,53	86,53	86,50
5	85,89	85,89	85,86
6	85,40	85,40	85,37
7	84,63	84,63	84,59
8	84,30	84,30	84,31
9	83,43	83,43	83,45
10	83,42	83,42	83,44
11	83,46	83,46	83,47
12	83,85	83,85	83,86
13	84,75	84,75	84,77
14	87,03	87,03	87,04
15	89,40	89,40	89,40
16	79,25	79,25	79,27
17	83,15	83,15	83,17
18	79,59	79,59	79,61
19	77,72	77,72	77,74
20	79,45	79,45	79,47

Fonte: Autor.

Os resultados obtidos por outros pesquisadores da *New York Tunnels problem* foram utilizados como parâmetro de comparação das soluções obtidas neste trabalho. Na Tabela 10 foram resumidos os resultados mais significativos obtidos em simulações utilizando esta rede exemplo.

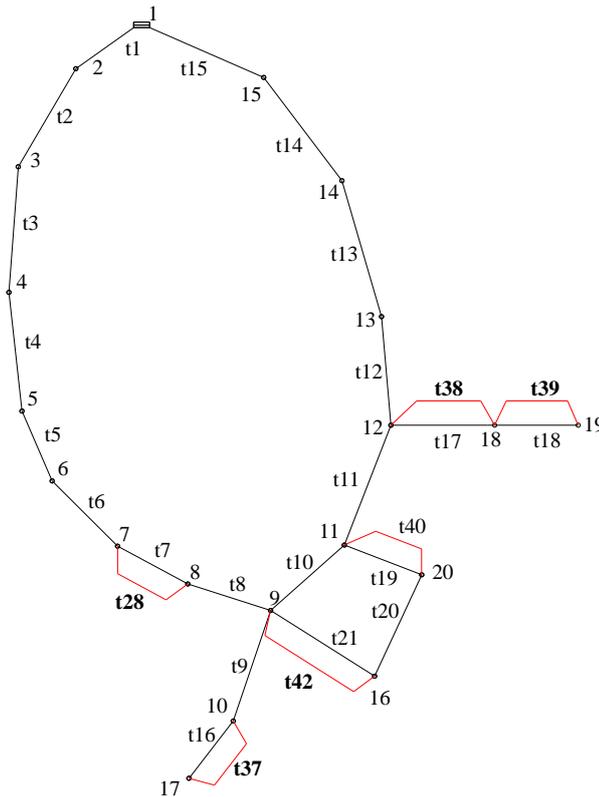
Tabela 10 – Comparação de dimensionamentos ótimos da literatura – Custos.

Referência	Método	Custo ( $10^6$ \$)
Dandy, Simpson & Murphy (1996)	GA	38,80
Savic & Walters (1997)	GA	37,13*
Eusuff & Lansey (2003)	SFLA	38,80
Maier <i>et al.</i> (2003)	ACO	38,64
Matias (2003)	GA	38,64
Zecchin <i>et al.</i> (2006)	ACO	38,64
Gomes, Bezerra e Srinivasan (2008)	HM	37,23
Montalvo <i>et al.</i> (2008)	PSO	38,64
Gomes <i>et al.</i> (2009)	Lenhsnet	41,24
	PSO-TLG	38,64

\* A pesquisa de Savic & Walters (1997) apresenta os resultados obtidos utilizando o coeficiente  $\omega = 10,51$ .

É possível ver na Figura 8 o resultado ótimo do dimensionamento feito pelo PSO-TLG que resultou em uma configuração de diâmetros para esta rede com custo total aproximado de \$ 38,64 milhões. Com base nos resultados da literatura, espera-se que este valor corresponda ao ótimo global.

Figura 8 – *New York Tunnels problem* Dimensionada (Ampliação)



Fonte: Autor.

### 5.3 *BALERMA NETWORK*

A fim de verificar o desempenho do PSO-TLG com pré-seleção de partículas, quando aplicado a sistemas de distribuição de água reais e complexos, uma nova rede de referência, destinada a novos projetos, é agora proposta. A *Balerma Network* é uma rede de distribuição de água de grande porte para irrigação localizada em *Balerma*, na província de Almeria (Espanha), foi apresentada originalmente por Reca & Martínez (2006) e é constituída de 4 reservatórios com as elevações 112, 117, 122 e 127 m, 8 anéis, 454 tubos e 443 nós de demanda. O *layout* da rede é mostrado na Figura 9

Um total de 10 tubos comerciais de PVC com diâmetros nominais de 125 a 600 mm estão disponíveis para o dimensionamento desta rede. Diante disso, o espaço de busca é

significativamente maior do que a *Hanoi Network problem*. A equação de Darcy-Weisbach foi adotada para calcular as perdas de carga, e todos os tubos são assumidos com rugosidade de 0,025 mm e pressão mínima de 20 mca. Os dados de entrada da rede e o banco de dados da tubulação são fornecidos por Bi, Dandy & Maier (2015).

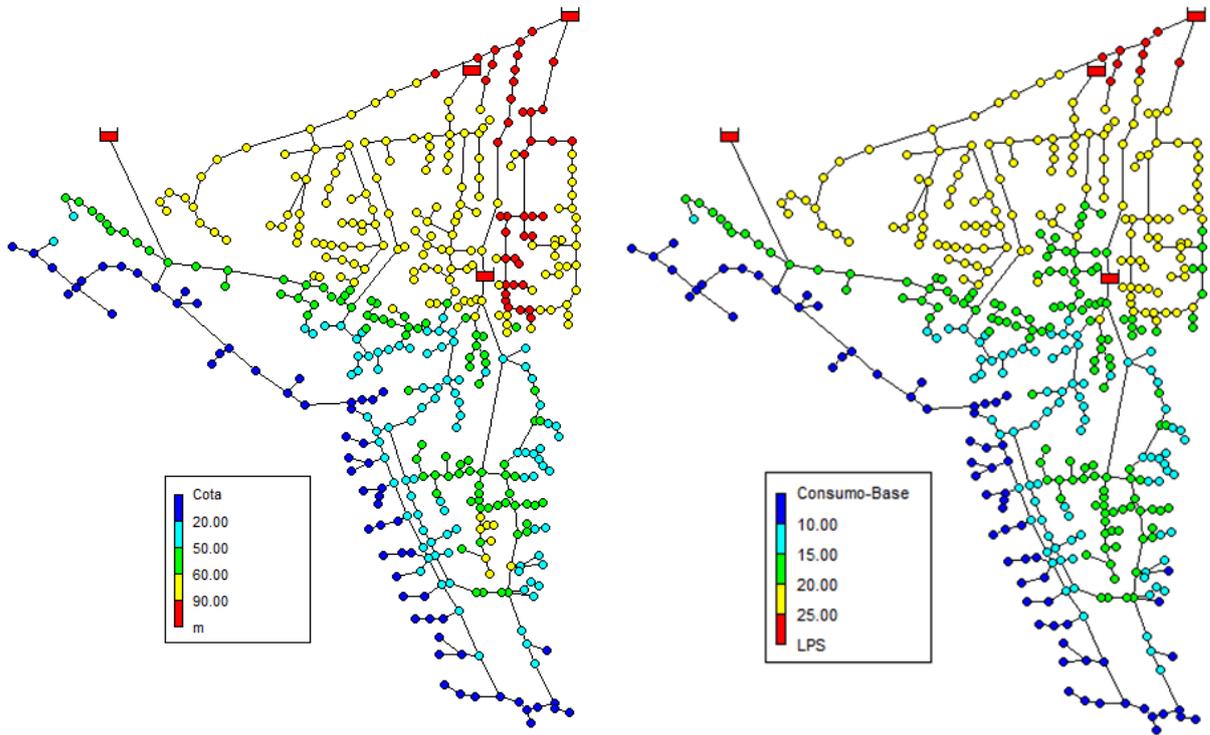
Figura 9 – *Balerna Network*.



Fonte: Reca & Martínez (2006).

As demandas e as cotas geométricas, da rede são apresentadas na Figura 10. Na Tabela 11 são apresentados os custos das tubulações por metro, em função dos diâmetros adotados na *Balerna Network*, a moeda utilizada no projeto original é o euro (€).

Figura 10 – Cotas e Demandas nodais na Balerma Network.



Fonte: Autor.

Tabela 11 – Custo para a Balerma Network.

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

Fonte: Reça &amp; Martínez (2006).

Mais uma vez, com base nos resultados da análise de sensibilidade realizada na *Hanoi Network problem* (item 5.1), segue um resumo dos parâmetros utilizados:

- $c_1=2$ ;
- $c_2=2$ ;
- $N^{total}=200$ ;
- *Tolerância*= 1/3;

- Fator de inércia ( $w$ ) calculado segundo a Equação 13;
- Com Pré-seleção de partículas;
- População de partículas = 2043 (4,5 vezes o número de variáveis); e
- Proporção entre topologias – Prop(%) = 10% (Equação 19);
- Com pré-seleção de partículas.

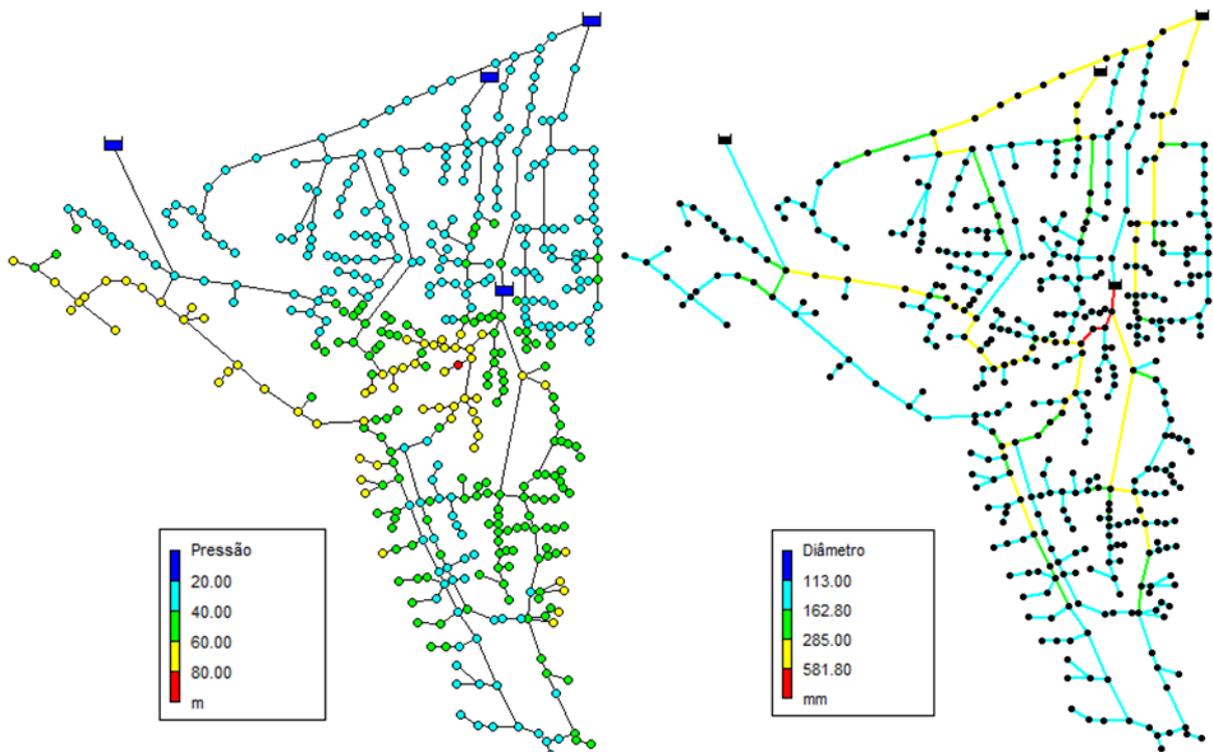
Segue na Tabela 12 um resumo do resultado obtido do dimensionamento do *Balerma Network* com os algoritmos do PSO-TG, PSO-TL e PSO-TLG. Apesar dos valores ótimos estarem bem próximos, o PSO-TLG modificou o melhor resultado que as demais topologias, além de uma redução no tempo de execução de aproximadamente 39% quando comparado com o de maior valor. As Figuras 11 a 13 representam o resultado do dimensionamento entre Topologias.

Tabela 12 – Comparação entre topologias – Custos e tempo médio de execução.

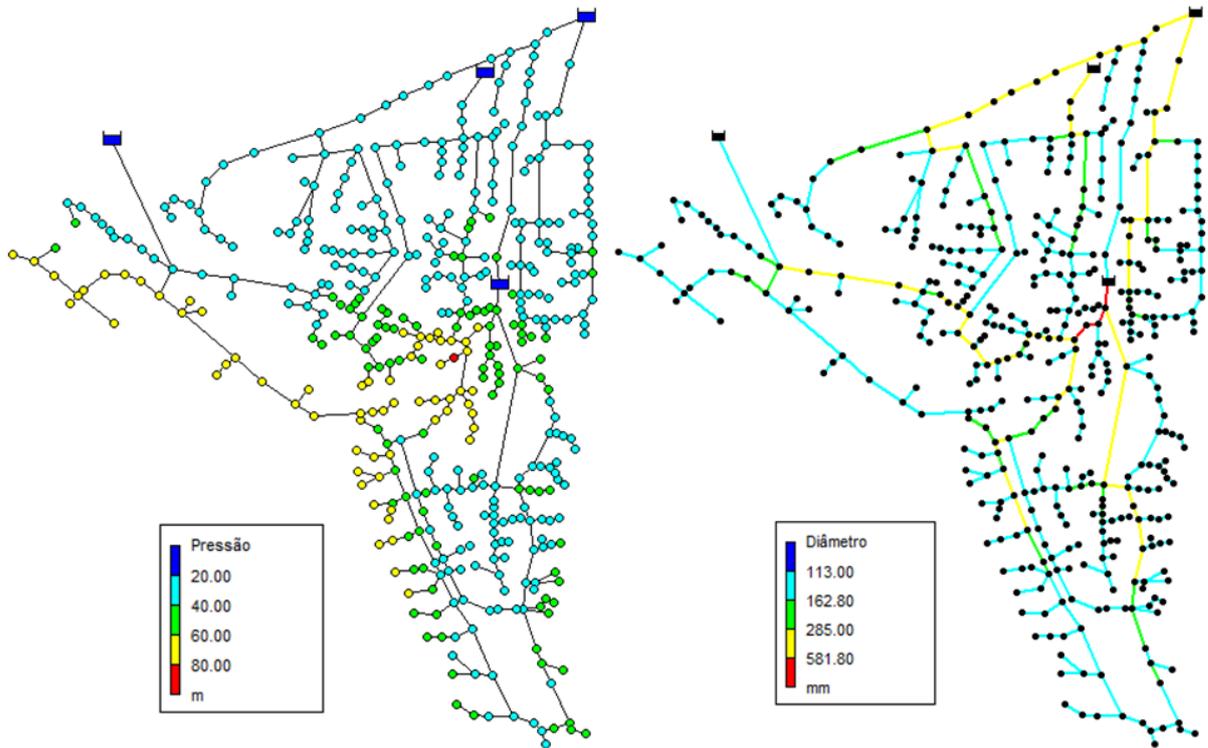
Topologia	Custo ótimo (€)	Tempo (min)
PSO-TG	2.538.062	43
PSO-TL	2.012.654	76
PSO-TLG	2.225.221	48

Fonte: Autor.

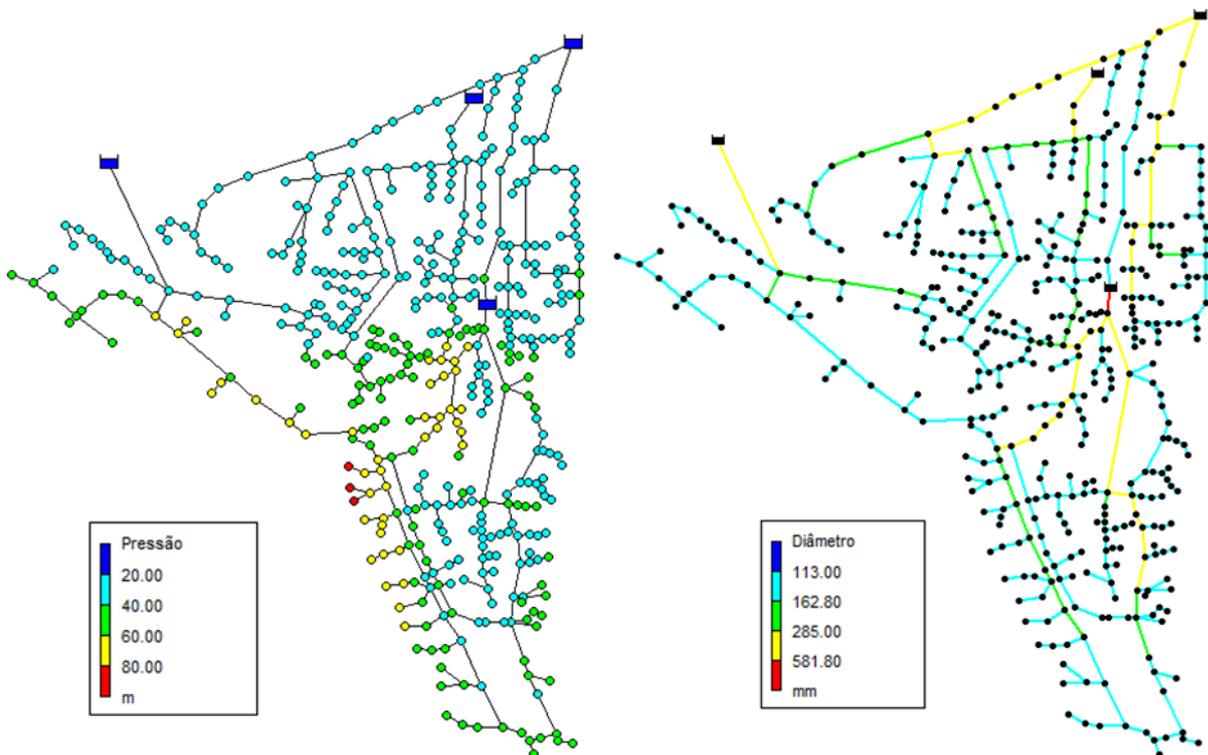
Figura 11 – Diâmetros e pressões nodais da *Balerma Network* pelo PSO-TG.



Fonte: Autor.

Figura 12 – Diâmetros e pressões nodais da Balerma *network* pelo PSO-TL.

Fonte: Autor.

Figura 13 – Diâmetros e pressões nodais da Balerma *network* pelo PSO-TLG.

Fonte: Autor.

A diferença de tamanho da população e do número de iterações entre as redes exemplos é motivada pelo grande aumento no espaço de busca da *Balerna Network*. Zheng, Zecchin & Simpson (2015) encontraram a solução de menor custo para essa rede com um tamanho populacional de 500 indivíduos. Conforme se observa na Tabela 13, o valor de custo mínimo reportado na literatura para a *Balerna Network* é de € 1,923 milhão (SADOLLAH; YOO; KIM, 2015; ZHENG; SIMPSON; ZECCHIN, 2011).

Como parte da abordagem, argumenta-se que, para problemas grandes e reais, o foco principal e imprescindível deva ser encontrar a melhor solução possível dentro de um tempo computacional razoável, ao invés de tentar encontrar a solução ótima. O algoritmo PSO-TLG encontrou uma solução de 2,005 milhões, compatível com as soluções ótimas da literatura, e um tempo de processamento, relativamente, baixo, em torno de 1 hora, e utilizando a pré-seleção de partículas esse tempo diminuiu para 52 min.

Tabela 13 – Comparação de dimensionamentos ótimos da literatura – Custos.

Referência	Método	Custo (10 <sup>6</sup> €)
Reca & Martinez (2006)	GA	2,302
Tolson <i>et al.</i> (2009)	HD-DDS <sup>1</sup>	1,941
Zheng, Zecchin & Simpson (2015)	PNL+DE <sup>3</sup>	1,923
Sadollah, Yoo & Kim (2015)	MBA <sup>4</sup>	1,923
PSO-TLG		2,005

<sup>1</sup> *Hybrid Discrete Dynamically Dimensioned Search.*

<sup>2</sup> *Genetic Heritage Evolution by Stochastic Transmission.*

<sup>3</sup> Programação Não Linear + Algoritmo de Evolução Diferencial precedido pela Teoria dos Grafos.

<sup>4</sup> *Mine Blast Algorithm.*

## 6 CONCLUSÕES E RECOMENDAÇÕES

A disponibilidade atual de microcomputadores mais modernos e potentes tem possibilitado o desenvolvimento de novas técnicas de otimização para o projeto ótimo de sistemas de distribuição de água. Verifica-se na literatura especializada, que ainda não existe um método de otimização que resolva eficientemente todos os tipos de problemas, e é por isso que, ao longo dos últimos anos, pesquisadores têm desenvolvido várias técnicas de busca com diversos algoritmos matemáticos.

Esta pesquisa apresenta um modelo para otimização de projetos de redes de distribuição de água fundamentado na técnica *Particle Swarm Optimization* (PSO). Teve como objetivos desenvolver e aplicar um algoritmo PSO para o dimensionamento de mínimo custo, avaliando o comportamento do processo de cálculo em função da população de partículas e da diminuição do espaço de busca. Esta pesquisa propôs uma nova topologia ao método – *Particle Swarm Optimization* com a Topologia Local-Global (PSO-TLG) – sendo esta avaliada quanto ao tempo de processamento computacional e ao valor ótimo obtido, comparado com as principais Topologias existentes para a técnica adotada.

A técnica *Particle Swarm Optimization* mostrou ser apropriada para o dimensionamento de redes de distribuição de água, colaborando com os resultados anteriores da literatura. As inúmeras simulações e configurações realizadas no primeiro estudo de caso serviram de base para a determinação de critérios para a definição dos parâmetros do modelo para quaisquer redes. Estes foram obtidos por meio de análises de sensibilidade, apresentando resultados semelhantes aos melhores obtidos por outros pesquisadores. As análises determinaram a quantidade de partículas para certo número de variáveis e a configuração do método topológico proposto neste trabalho.

A fim de testar a eficiência do modelo proposto em projetos de redes com critérios de dimensionamento utilizados na prática, este foi aplicado em mais duas redes exemplos. A técnica PSO-TLG permitiu obter, considerando um quantitativo fixo de partículas, a solução de mínimo custo com um tempo de processamento aceitável. A metodologia desenvolvida também faz uma pré-seleção dos diâmetros, eliminando combinações não factíveis para reduzir o espaço de busca. Houve uma diminuição do tempo de processamento, quando comparado com o PSO com Topologia Local, de 35% a 68% nos estudos de caso avaliados. Essa abordagem também pode ser acoplada a outras metaheurísticas. Ademais, o modelo pode disponibilizar um conjunto de soluções diferentes da “ótima” para o tomador de

decisões, que tem a possibilidade de escolher, com base em outros critérios, outra solução com custo similar.

Como recomendação para pesquisas futuras, indica-se o desenvolvimento de estudos que incluam aspectos de confiabilidade, qualidade de água e reabilitação no projeto ótimo de sistemas de distribuição de água.

## REFERÊNCIAS

- ABBASS, H. A. *A pleometrosis MBO approach to satisfiability*. Proceeding of International Conference on Computational Intelligence for Modeling, Control and Automation, CIMCA2001, Las Vegas, USA, 2001.
- ABEBE, A. J.; SOLOMATINE, D. P. *Application of global optimization to the design of pipe networks*. In: Proc. 3rd International Conference on Hydroinformatics, Copenhagen. p. 989-996, 1998.
- AGHDAM, K. M.; MIRZAEI, I.; POURMAHMOOD, N.; AGHABABA, M. P. *Design of water distribution networks using accelerated momentum particle swarm optimisation technique*. Journal of Experimental e Theoretical Artificial Intelligence, 26(4), 459-475, 2014.
- ALINAGHIAN, M.; GHAZANFARI, M.; NOROUZI, N.; NOURALIZADEH, H. *A Novel Model for the Time Dependent Competitive Vehicle Routing Problem: Modified Random Topology Particle Swarm Optimization*. Networks and Spatial Economics, p. 1-27, 2017.
- ALMEIDA, P. L. C. *Optimização da operação de uma estação elevatória: minimização do custo da energia respeitando critérios de qualidade da água*. Mestrado Integrado em Engenharia Civil – Departamento de Engenharia Civil, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal, 2010.
- ALPEROVITS, E.; SHAMIR, U. *Design of optimal water distribution systems*. Water Resources Research, 13(6), 885-900, 1977.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. *Projeto de rede de distribuição de água para abastecimento público. Norma Brasileira Regulamentadora 12218*. Rio de Janeiro, 2017.
- BEHESHTI, Z.; SHAMSUDDIN, S. M.; SULAIMAN, S. *Fusion global-local-topology particle swarm optimization for global optimization problems*. Mathematical Problems in Engineering, 2014.
- BEZERRA, S. T. M.; SILVA, S. A.; GOMES, H. P. . *Operational optimisation of water supply networks using a fuzzy system*. Water S.A., v. 38, p. 565-572, 2012.
- BHAVE, P. R.; SONAK, V. V. *A critical study of the linear programming gradient method for optimal design of water supply networks*. Water Resources Research, v. 28, n. 6, p. 1577-1584. New York, NY, USA, 1992.

- BI, W.; DANDY, G. C.; MAIER, H. R. *Improved genetic algorithm optimization of water distribution system design by incorporating domain knowledge*. Environmental Modelling e Software, 69, 370-381, 2015.
- BISCOS, C.; MULHOLLAND, M.; LE LANN, M.; VBUCKLEY, C. A; BROUCKAERT C. J. *Optimal operation of water distribution networks by predictive control using MINLP*. Water Sa 29, n. 4: 393-404, 2003.
- BRAGALLI, C.; D'AMBROSIO, C.; LEE, J.; LODI, A.; TOTH, P. *Optimizing the design of water distribution networks using mathematical optimization*. In: Case studies in operations research. Springer, New York, NY, p. 183-198, 2015.
- CHANG, N. B.; PONGSANONE, N. P.; ERNEST, A. *Comparisons between a rule-based expert system and optimization models for sensor deployment in a small drinking water network*. Expert systems with applications, 38(8), 10685-10695, 2014.
- CHATTERJEE, A.; SARKAR, S.; HORE, S.; DEY, N.; ASHOUR, A. S.; BALAS, V. E. *Particle swarm optimization trained neural network for structural failure prediction of multistoried RC buildings*. Neural Computing and Applications, 28(8), 2005-2016, 2017.
- CHATTERJEE, A.; SIARRY, P. *Nonlinear inertia weight variation for dynamics adaptation in particle swarm optimization*, Computers & Operations Research, v. 33, n. 3, p. 859-871, 2006.
- CHEUNG, P. B. *Análise de reabilitação de redes de distribuição de água para abastecimento via algoritmos genéticos multiobjetivo*. Tese de Doutorado. Departamento de Hidráulica e Saneamento – Universidade de São Paulo, São Carlos, São Paulo, 2004.
- CHOI, J. H.; LEE, J. D.; YOO, H. M; KIM D. G. *Improving the Quality of Pareto Optimal Solutions in Water Distribution Network Design*. Journal of Water Resources Planning and Management, v. 143, n. 8, p. 04017036, 2017.
- CLERC, M.; KENNEDY, J. *The particle swarm-explosion, stability, and convergence in a multidimensional complex space*. Evolutionary Computation, IEEE Transactions on, v. 6, n. 1, p. 58-73, 2002.
- COSTA FILHO, P. A.; POPPI, R. J. *Algoritmo genético em química*. Química Nova, v. 22, n. 3, p. 405, 1999.
- COSTA, L.H.M.; CASTRO, M.A.H.; ARAÚJO, J.K. *Dimensionamento econômico de redes de abastecimento de água utilizando o EPANET e a linguagem Delphi*. In: VI Seminário

Iberoamericano sobre Sistemas de Abastecimento Urbano de Água, João Pessoa, Brasil, Junho, 2006.

CUNG, V. D.; MAUTOR, T.; MICHELON, P.; TAVARES, A. *A Scatter Search based approach for the Quadratic Assignment problem*. In T. Bäck, Z.; Michalewicz, X. Yao (eds.), Proceedings of ICEC'97, IEEE Press, p.165-170, 1996.

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

DANDY, G. C.; SIMPSON A. R.; MURPHY L. J. *An improved genetic algorithm for pipe network optimization*, Water Resour. Res., 32(2), 449–457, doi:10.1029/95WR02917, 1996.

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

DORIGO, M. *Optimization, learning and natural algorithms*. 1992. Tese (Doutorado). Politecnico di Milano, Itália, 1992.

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

DUAN, Q.; SOROOSHIAN S.; GUPTA V. *Effective and efficient global optimization for conceptual rainfall-runoff models*. Water Resources Research 28(4): 1015-1031, 1992.

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

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

EUSUFF, M.; LANSEY, K.; PASHA, F. *Shuffled frog leaping algorithm: a memetic metaheuristic for combinatorial optimization*. Engineering Optimization, v. 38, n. 2, p. 129-154, 2006.

- FUJIWARA, O.; KHANG, B. *A two-phase decomposition method for optimal design of looped water distribution networks*. Water resources research, v. 26, n. 4, p. 539-549, 1990.
- GESSLER, J. *Optimization of pipe networks*. International Symposium on Urban Hydrology, Hydraulics and Sediment Control, University of Kentucky, Lexington, Kentucky, 1982.
- GLOVER, F. *Heuristics for integer programming using surrogate constraints*. Decision Sciences, 8(1), p. 156-166, 1977.
- GOMES H.; FORMIGA K. T. M. *PNL2000: Método prático de dimensionamento econômico de água*. Revista Brasileira de Recursos Hídricos. Porto Alegre: ABRH 6 (4) 91-108, 2001.
- GOMES, H. P.; BEZERRA, S. T. M. *Reabilitação de redes coletivas de sistemas pressurizados de irrigação*. Rev. Bras. Eng. Agríc. Ambient., v. 9, n. 4, p. 457-463, 2005.
- GOMES, H. P.; BEZERRA, S. T. M.; CARVALHO, P. S. O.; SALVINO, M. M. *Optimal Dimensioning Model of Water Distribution Systems*. Water S. A., v. 35, p. 421-432, 2009.
- GOMES, H. P.; BEZERRA, S. T. M.; SRINIVASAN, V. S. *An iterative optimisation procedure for the rehabilitation of water-supply pipe networks*. Water S.A., v. 34, p. 225-235, 2008.
- GRANADOS, A. *Infraestructuras de regadíos – redes colectivas de riego a presión*. Servicio de Publicación de E. T. S. I. de Caminos de La Universidad Politécnica de Madrid, España, 1990.
- GUO, Q.; TANG, L. *An improved scatter search algorithm for the single machine total weighted tardiness scheduling problem with sequence-dependent setup times*. Applied Soft Computing, v. 29, p. 184-195, 2015.
- GUO, X.; LIU, S.; ZHOU, M.; TIAN, G. *Dual-Objective Program and Scatter Search for the Optimization of Disassembly Sequences Subject to Multiresource Constraints*. IEEE Transactions on Automation Science and Engineering, 2017.
- HADDAD, O. B.; AFSHAR, A.; MARINO M. A. *Honey Bee Mating Optimization Algorithm (HBMO); Honey-Bees Mating Optimization (HBMO) Algorithm: A new heuristic approach for water resources optimization*. Water Resources Management (In Press), 2006.
- HADDAD, O. B.; GHAJARNIA, N.; SOLGI, M.; LOÁICIGA, H. A.; MARIÑO, M. *A DSS-based honeybee mating optimization (HBMO) algorithm for single-and multi-objective design*

*of water distribution networks*". In *Metaheuristics and optimization in civil engineering* (p. 199-233). Springer International Publishing, 2016.

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

ILONEN, J.; KAMARAINEN, J. K.; LAMPINEN, J. *Differential evolution training algorithm for feed-forward neural networks*. *Neural Process. Lett.*, v. 7, n. 1, p. 93-105, 2003.

ISHIHARA, J. H.; FERNANDES, L. L.; LIMA, A. C. M.; DUARTE, A. A. M., FARIAS, M. *Avaliação de métodos de dimensionamento de rede de abastecimento de água e estudo das condições de saneamento do bairro novo horizonte em Barcarena-PA*. *Revista Traços*, 11(24), 2017.

JACOBY, S. L. S. *Design of Optimal Hydraulic Network*. *Journal Hydraulic Division American Society Civil Engineering*, v. 94, n. HY3, p. 641-661, 1968.

JAHANSHAHI, G.; HADDAD, O. B. *Honey-bee mating optimization (HBMO) algorithm for optimal design of water distribution systems*. In *World Environmental and Water Resources Congress 2008: Ahupua'A* (p. 1-16), 2008.

JIN, Y. X.; CHENG, H. Z.; YAN J. Y.; ZHANG L. *New discrete method for particle swarm optimization and its application in transmission network expansion planning*. *Electric Power Systems Research* 77(3-4): 227-233, 2007.

JOHNS, M. B.; KEEDWELL, E.; SAVIC, D. *Adaptive locally constrained genetic algorithm for least-cost water distribution network design*. *Journal of Hydroinformatics*, 16(2), 288-301, 2014.

JOSHI, R.; SANDERSON, A. C. *Minimal representation multisensor fusion using differential evolution*. *IEEE Trans. Syst. Man Cybern. A, Syst. Humans*, v. 29, n. 1, p. 63-76, 1999.

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

KARPELLI, D.; GADISH, Y.; MEYERS, S. *Design of Optimal Water Distribution Networks*. *Journal of Pipeline Division, ASCE*, v. 94, n. 10, p. 1-10, 1968.

- KAUR, P.; MEHTA, S. *Resource provisioning and work flow scheduling in clouds using augmented Shuffled Frog Leaping Algorithm*. Journal of Parallel and Distributed Computing, v. 101, p. 41-50, 2017.
- KENNEDY, J. *The behavior of particles*. In: *Evolutionary programming VII*, p. 579-589, 1998.
- KENNEDY, J.; EBERHART, R. C. *Particle Swam Optimization*. In: IEEE International Conference on Neural Networks, IEEE Service Center, Piscataway, NJ, N: 1942-1948, Path, Australia, 1995.
- KENNEDY, J.; MENDES, R. *Neighborhood topologies in fully informed and best-of-neighborhood particle swarms*. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 36(4), 515-519, 2006.
- KRIPKA, M.; MEDEIROS, G. F. *Cross-sectional optimization of reinforced concrete columns considering both economical and environmental costs*. In Applied Mechanics and Materials (V. 193, p. 1086-1089). Trans Tech Publications, 2012.
- LANSEY, K. E.; MAYS, L. W. *Optimization model for water distribution system design*. Journal of Hydraulic Engineering, 115(10): 1401-1418, 1989.
- LIANG, T. *Design Conduit System by Dynamic Programming*. Journal of the Hydraulics Division, v. 97, n. HY3, p. 383-393, 1971.
- LIAO, C. J.; TSENG, C. T.; LUARN P. *A discrete version of particle swarm optimization for flowshop scheduling problems*. Computers and Operations Research 34(10): 3099-3111, 2007.
- LIN, M. D.; LIU, Y. H.; LIU, G. F.; CHU, C. W. *Scatter search heuristic for least-cost design of water distribution networks*. Engineering Optimization, 39(7), 857-876, 2007.
- LIONG, S. Y.; ATIQUZZAMAN, M. *Optimal design of water distribution network using shuffled complex evolution*. Journal of the Institution of Engineers, Singapore, 44(1), 93-107, 2004.
- LUO, Q.; YI, D. *A co-evolving framework for robust particle swarm optimization*. Applied Mathematics and Computation, 199(2), 611-622, 2008.
- MAIER, H. R.; KAPELAN, Z.; KASPRZYK, J.; KOLLAT, J.; MATOTT, L. S.; CUNHA, M. C.; OSTFELD, A. *Evolutionary algorithms and other metaheuristics in water resources:*

*Current status, research challenges and future directions*. Environmental Modelling e Software, 62, 271-299, 2014.

MAIER, H. R.; SIMPSON, A. R.; ZECCHIN, A. C.; FOONG, W. K., PHANG, K. Y., SEAH, H. Y.; TAN, C. L. *Ant colony optimization for design of water distribution systems*. Journal of water resources planning and management ASCE, 129(3), 200-209, 2003.

MANDAL, D.; CHATTERJEE, A.; MAITRA, M. *Particle Swarm Optimization Based Fast Chan-Vese Algorithm for Medical Image Segmentation*. In: Metaheuristics for Medicine and Biology. Springer, Berlin, Heidelberg, p. 49-74, 2017.

MANJARRES, D.; LANDA-TORRES, I.; GIL-LOPEZ, S.; DEL SER, J.; BILBAO, M. N.; SALCEDO-SANZ, S.; GEEM, Z. W. *A survey on applications of the harmony search algorithm*. Engineering Applications of Artificial Intelligence, 26(8), 1818-1831, 2013.

MARCHI, A.; DANDY, G.; WILKINS, A.; ROHRLACH, H. *Methodology for comparing evolutionary algorithms for optimization of water distribution systems*. Journal of water resources planning and management, v. 140, n. 1, p. 22-31, 2012.

MATIAS, A. S. *Diseño de redes de distribución de agua contemplando la fiabilidad, mediante Algoritmos Genéticos*. Departamento de Ingeniería Hidráulica y Medio Ambiente. Universidad Politécnica de Valencia. Tesis doctoral, 2003.

MIN, Y.; JIAYUE, Z.; DAMIN, Z. *Immunization strategy based on discrete particle swarm optimization algorithm in BBV network*. In: 11th International Conference on Intelligent Systems and Control (ISCO) (p. 208-211). IEEE, 2017.

MONTALVO, I.; IZQUIERDO, J.; PÉREZ, R.; TUNG, M.M. *Particle Swarm Optimization applied to the design of water supply systems*. Computers and Mathematics with Applications, 56(3) 777-784, 2008.

MONTALVO, I.; IZQUIERDO, J.; PÉREZ-GARCÍA, R.; HERRERA, M. *Water Distribution System Computer-Aided Design by Agent Swarm Optimization*. Computer-Aided Civil and Infrastructure Engineering, 29(6), 433-448, 2014.

MONTESINOS, P.; GARCÍA-GUZMÁN, A.; AYUSO J. L. *Water distribution network optimization using a modified genetic algorithm*. Water Resources Research 35(11): 3467-3473, 1999.

MORA-MELIA, D.; IGLESIAS-REY, P. L.; MARTINEZ-SOLANO, F. J.; BALLESTEROS-PÉREZ, P. *Efficiency of evolutionary algorithms in water network pipe sizing*. Water resources management, 29(13), 4817-4831, 2015.

MORGAN, D. R.; GOULTER, I. C. *Optimal urban water distribution design*. Water Resources Research 21(5): 642-652, 1985.

MOTA, H. J. S. *Dimensionamento econômico de sistemas de abastecimento de água aplicando algoritmo genético*. Fortaleza, 267p. Dissertação de Mestrado – Universidade Federal do Ceará, Fortaleza, 2007.

MURANHO, J.; FERREIRA, A.; SOUSA, J.; GOMES, A.; MARQUES, A. S. *WaterNetGen: an EPANET extension for automatic water distribution network models generation and pipe sizing*. Water science and technology: water supply12, n. 1: 117-123, 2012.

NAWAYSEH, N.; JARNDAL, A.; HAMDAN, S. *Optimizing the parameters of a biodynamic responses to vibration model using Particle Swarm and Genetic Algorithms*. In Modeling, Simulation, and Applied Optimization (ICMSAO), 2017 7th International Conference on (p. 1-6). IEEE, 2017.

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

PINNTO, M. R.; CASTRO, M. A. H. D.; BARBOSA, J. M. C.; JÚNIOR, M.; FARIAS, J. V. *Optimum economic sizing of water distribution network considering maintenance cost*. Engenharia Sanitaria e Ambiental, v. 22, n. 1, p. 145-153, 2017.

QUESADA, T. A.; MARTÍNEZ, F.; YOHELVIS, A.; RAMOS ARZOLA, L. C. *La simulación en el diseño de los sistemas hidráulicos navales*. Ingeniería Hidráulica y Ambiental, v. 38, n. 2, p. 29-43, 2017.

QUINDRY, G; EBRILL, E. D.; LIEBMAN, J. C. *Optimization of looped water distribution systems*. American Society of Civil Engineers, Journal of the Environmental Engineering Division 107(4): 665-679, 1981.

RATNAWEERA, A.; HALGAMUGE, S. K.; WATSON, H. C. *Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients*. Evolutionary Computation, IEEE Transactions on, v. 8, n. 3, p. 240-255, 2004.

RECA, J.; MARTINEZ J. *Application of Several Meta-Heuristic Techniques to the Optimization of Real Looped Water Distribution Networks*. Water Resources Management 22(10): 1367-1379, 2008.

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

ROGALSKY, T.; DERKSEN, R. W.; KOCABIYIK, S. *Differential evolution in aerodynamic optimization*. In Proc. 46th Annu. Conf. of Can. Aeronaut. Space Inst., Montreal, QC, Canada, p. 29-3, 1999.

ROLAM, M. E.; OLIVEIRA NETO, A. G.; BREDA, G. T.; FERREIRA, J. A. M.; WAGNER, L. F. *Redução do consumo energético em sistemas de pressurização de água, com variação de velocidade no conjunto moto-bomba*. Revista Techno, 1(13), 2017.

ROQUE, C. M. C.; MARTINS, P. A. L. S. *Maximization of fundamental frequency of layered composites using differential evolution optimization*. Composite Structures, v. 183, p. 77-83, 2018.

ROSSMAN L. A. *EPANET 2*. Users Manual. Environmental Protection Agency, 2000.

SADOLLAH, A.; YOO, D. G.; KIM, J. H. *Improved mine blast algorithm for optimal cost design of water distribution systems*. Engineering Optimization, 47(12), 1602-1618, 2015.

SALVINO, M. *Método de dimensionamento e controle operacional otimizado para redes de distribuição de água*. Tese de Doutorado. Dissertação de Mestrado em Engenharia Mecânica, Programa de Pós Graduação em Engenharia Mecânica, Universidade Federal da Paraíba, 2009.

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

SCHAAKE J.; LAI D. *Linear programming and dynamic programming applications to water distribution network design*, Research Report N. 116, Department of Civil Engineering, Massachusetts Institute of Technology, USA, 1969.

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

- SHEN, P.; ZHAO, Z.; ZHAN, X.; LI, J. *Particle swarm optimization of driving torque demand decision based on fuel economy for plug-in hybrid electric vehicle*. Energy, 123, 89-107, 2017.
- SHI, Y.; EBERHART, R. C. *A modified particle swarm optimizer*. In: Evolutionary Computation Proceedings, 1998. In: The 1998 IEEE International Conference on IEEE World Congress on Computational Intelligence, p. 69-73, 1998a.
- SHI, Y.; EBERHART, R. C. *Parameter selection in particle swarm optimization*. In: Evolutionary Programming VII, p. 591-600, 1998b.
- SHI, Y.; LIANG, C.; LEE, H.; LU, P.C.; WANG Q. X. *Particle swarm optimization-based algorithms for TSP and generalized TSP*. Information Processing Letters 103(5): 169-176, 2007.
- SHOURIAN, M.; MOUSAVI, S. J. *Performance Assessment of a Coupled Particle Swarm Optimization and Network Flow Programming Model for Optimum Water Allocation*. Water Resources Management, v. 31, n. 15, p. 4835-4853, 2017.
- SILVA, R. C. A. *Otimização de redes ramificadas através do método da programação não linear*. Dissertação de Mestrado. Universidade Federal da Paraíba. Campina Grande, PB, 1997.
- SIMPSON, A. R.; DANDY, G. C.; MURPHY, L. J. *Genetic algorithms compared to other techniques for pipe optimization*. Journal of Water Resources Planning and Management, 120(4), 423-443, 1994.
- SOLGI, M.; BOZORG-HADDAD, O.; LOÁICIGA, H. A. *The enhanced honey-bee mating optimization algorithm for water resources optimization*. Water Resources Management, v. 31, n. 3, p. 885-901, 2017.
- SOUSA, J.; CUNHA, M. C. *Dimensionamento otimizado de redes malhadas de distribuição de água*. 4º Congresso da Água, "A Água como Recurso Estruturante do Desenvolvimento" Lisboa, 1998.
- STENDER, M.; YAN, Y.; KARAYAKA, H. B., TAY, P.; ADAMS, R. *Simulating micro-robots to find a point of interest under noise and with limited communication using Particle Swarm Optimization*. In Southeast Con, 2017 (p. 1-8). IEEE, 2017.
- STORN, R. *On the usage of differential evolution for function optimization*. In Proc. Biennial Conf. North Amer. Fuzzy Inf. Process. Soc., Berkeley, CA, p. 519–523, 1997.

- STORN, R.; PRICE, K. V.; *Differential evolution-A simple and efficient heuristic for global optimization over continuous Spaces*. J. Global Optim., v. 11, p. 341–359, 1997.
- SURIBABU, C. R. *Differential evolution algorithm for optimal design of water distribution networks*. Journal of Hydroinformatics, 12(1), 66-82, 2010.
- SURIBABU, C. R. *Resilience-based optimal design of water distribution network*. Applied Water Science, v. 7, n. 7, p. 4055-4066, 2017.
- SURIBABU, C. R.; NEELAKANTAN, T. R. *Design of water distribution networks using particle swarm optimization*. Urban Water Journal, 3(2), 111-120, 2006.
- TOLSON, B. A.; ASADZADEH, M.; MAIER, H. R.; ZECCHIN, A. *Hybrid discrete dynamically dimensioned search (HD-DDS) algorithm for water distribution system design optimization*. Water Resources Research, 45(12), 2009.
- TUNG, Y. K. *Evaluation of water distribution network reliability*. Hydraulics and hydrology in the small computer age, Lake Buena Vista, Florida, USA, 1985.
- VALDEZ, F.; VAZQUEZ, J. C.; MELIN, P.; CASTILLO, O. *Comparative study of the use of fuzzy logic in improving particle swarm optimization variants for mathematical functions using co-evolution*. Applied Soft Computing, 52, 1070-1083, 2017.
- VASAN, A.; SLOBODAN P. S. *Optimization of water distribution network design using differential evolution*. Journal of Water Resources Planning and Management 136, n. 2, 279-287, 2010.
- WALSKI, T. M. *Battle of the network models: epilogue*. Journal of Water Resources Planning and Management, ASCE, v. 113, n.2, p. 191-203. New York, NY, USA, 1987.
- WONG, L.; MOIN, N. H. *Ant Colony Optimization For Split Delivery Inventory Routing Problem*. Malaysian Journal of Computer Science, v. 30, n. 4, p. 333-348, 2017.
- WU, Z. Y.; SIMPSON, A. R. *A self-adaptive boundary search genetic algorithm and its application to water distribution systems*. Journal of hydraulic research 40(2): 191-203, 2002.
- YOSHIDA, H.; FUKUYAMA, Y. *Dependable parallel multi-population differential evolutionary particle swarm optimization for voltage and reactive power control in electric power systems*. In: 2017 IEEE 10th International Workshop on Computational Intelligence and Applications (IWCIA), IEEE, p. 19-24, 2017.

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

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

ZHENG, F.; ZECCHIN, A. C.; SIMPSON, A. R. *Investigating the run-time searching behavior of the differential evolution algorithm applied to water distribution system optimization*. *Environmental Modelling Software*, 69, 292-307, 2015.

ZHOU, Y.; LI, X.; GAO, L. *A differential evolution algorithm with intersect mutation operator*. *Applied Soft Computing*, 13(1), 390-401, 2013.