

CMN 2017

Congress on Numerical Methods in Engineering

July 3 - 5, Valencia, Spain

Edited by: Irene Arias, Jesús María Blanco, Stephane Clain, Paulo Flores,
Paulo Lourenço, Juan José Ródenas and Manuel Tur



Congress on Numerical Methods in Engineering

CMN 2017

**July 3 - 5
Valencia, Spain**

AVALIAÇÃO DE FUNÇÕES DE PENALIZAÇÃO PARA O DIMENSIONAMENTO OTIMIZADO DE REDES DE DISTRIBUIÇÃO DE ÁGUA

Isabela Niedo Marchiori¹, Gustavo Meirelles Lima², Bruno Melo Brentan³, Edevar
Luvizotto Junior⁴, Joaquín Izquierdo⁵

^{1,2,3,4}Laboratório de Hidráulica Computacional (LHC)
Universidade Estadual de Campinas
Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Campinas, Brazil
e-mail: ¹isaniedo@gmail.com, ²limameirelles@gmail.com, ³brunocivil08@gmail.com,
⁴edevlar@fec.unicamp.com, web page: lhchidraulica.wix.com/grupoaguas

⁵ FluIng-IMM
Universitat Politècnica de València
Cno. de Vera, s/n, 46022, Valencia, Spain
email: jizquier@upv.es, web page: fluing.upv.es

Palavras-chave: otimização, redes de abastecimento de água, modelagem hidráulica.

Resumo: Redes de distribuição representam o maior investimento de um sistema de abastecimento de água. Desta forma, é necessário reduzir seus custos de implantação, escolhendo o melhor traçado e os menores diâmetros possíveis para as tubulações, respeitando os limites operacionais de velocidade e pressão. Técnicas de otimização meta-heurísticas têm sido amplamente utilizadas para a solução deste problema de dimensionamento. Entretanto, por serem métodos irrestritos, para que a solução se mantenha dentro das restrições do problema, pode-se utilizar funções de penalização, adicionando um valor à função objetivo toda vez que uma restrição é violada. Assim, a função de penalização exerce uma grande influência na eficiência da otimização, pois, caso seja muito rígida, o espaço de busca não será amplamente explorado, e, quando a penalização é muito branda, a solução obtida pode ser inviável. Além disso, observa-se uma grande aleatoriedade nos diâmetros obtidos, sendo comum a mudança brusca entre tubulações subsequentes, o que não retrata a realidade. Assim, este trabalho utiliza os métodos de otimização Algoritmo Genético e *Particle Swarm Optimization* para avaliar a performance de oito diferentes funções de penalização. Utilizando a melhor função encontrada, uma nova forma de penalização, que considera a redução gradual do diâmetro das tubulações adjacentes será desenvolvida. Por fim, os resultados obtidos com esta nova formulação serão comparados com os obtidos previamente.

1. INTRODUÇÃO

Considerando que grande parte dos custos de implantação de sistemas de abastecimento de água é oriunda de suas redes, o dimensionamento é crucial para que o projeto se torne economicamente viável. Assim, busca-se o melhor traçado e os diâmetros ideais das tubulações a serem empregadas para que o abastecimento seja feito com qualidade e custos reduzido [1]. Além disso, a escolha correta da tubulação garante um melhor desempenho das operações cotidianas.

O jogo entre o custo das tubulações e o atendimento das condições operacionais requeridas por norma, tornam o problema de dimensionamento complexo, propiciando então o desenvolvimento de pesquisas com o olhar no dimensionamento ótimo. Porém, a otimização das redes de abastecimento envolve um grande número de variáveis, levando à grande esforço computacional. Esta otimização consiste em minimizar uma função objetivo, que normalmente relaciona o custo das tubulações e seus diâmetros, variáveis do problema. Em redes onde existem estações elevatórias, o problema torna-se ainda mais complexo, uma vez que, para reduzir os custos da função objetivo, deve-se comparar os custos fixos de implantação das tubulações, com custos variáveis decorrentes da operação dos conjuntos motobomba [2].

Embora o problema do dimensionamento das redes seja de natureza não linear por conta das equações hidráulicas envolvidas, alguns autores desenvolveram técnicas de linearização, diminuindo então sua complexidade [3]. Atualmente, métodos de otimização meta-heurísticos, em conjunto com modelos de simulação hidráulica, destacam-se no dimensionamento dos sistemas de abastecimento de água [4], mesmo não garantindo a obtenção do ótimo global do problema. Dentre os métodos meta-heurísticos, destacam-se os bio-inspirados, que utilizam uma analogia com comportamentos relacionados a fenômenos biológicos, tais como o comportamento de uma colônia de formigas [5], um enxame de abelhas [6] e até mesmo no comportamento humano, com a relação observada entre músicos de jazz [7].

Apesar de diversos estudos indicarem a eficiência do Algoritmo Genético (AG) na solução de problemas relacionados a sistemas de abastecimento de água, ainda faltam estudos que demonstrem a superioridade de algum dos métodos de otimização [8]. Somado a isso, os estudos de caso realizados normalmente são feitos em redes simples, que na maior parte das vezes não reflete a realidade, mostrando que este problema, apesar dos inúmeros esforços, ainda não foi resolvido de forma definitiva e satisfatória.

Todavia, uma das dificuldades de emprego dos métodos meta-heurísticos é sua natureza irrestrita, ou seja, não contemplam diretamente em sua formulação as restrições do problema de otimização. No caso de dimensionamento de redes de abastecimento, as restrições estão relacionadas a padrões operacionais estabelecidos por normas técnicas, como o limite das velocidades de escoamento e as pressões de serviço. Como forma de solucionar esta dificuldade, inerente a estes métodos, é usual que funções de penalização sejam adicionadas à função objetivo do problema. Assim as penalizações incrementam o custo de uma solução caso os limites normativos de velocidade e/ou pressão não sejam atendidos. No entanto, [9] ressalta que altas penalizações criam barreiras no espaço de busca, enquanto que

penalizações brandas resultam em soluções não-factíveis.

Na literatura existem várias propostas de funções de penalização entre as quais destacam-se as funções aditivas, que somam diretamente um custo à função objetivo, as multiplicativas, em que a função objetivo é multiplicada por um coeficiente, as estatísticas, que adicionam um valor de acordo com o nível de violação, as fatais, onde as soluções inviáveis são descartadas, e as dinâmicas, que alteram o fator de penalização de acordo com o grau de penalização e o número de iterações [10].

Tendo em conta a necessidade das funções de penalização para o uso de algoritmos meta-heurísticos, em particular os bio-inspirados, no dimensionamento econômico de redes de abastecimento e, considerando a dificuldade de escolher tais funções, uma vez que essas alteram a topologia do espaço de busca, o presente trabalho avalia o desempenho de oito diferentes funções de penalizações para a solução do dimensionamento de duas redes *benchmark* da literatura: Two-Loop e Hanoi. Para verificar a relação entre as funções de penalização e o método de otimização aplicado, o AG e PSO (*Particle Swarm Optimization*) foram utilizados para a solução do problema de dimensionamento. Para cada caso, 100 simulações foram realizadas, permitindo avaliar o número de vezes em que houve penalização, o valor médio da função objetivo não-penalizada, o valor mínimo encontrado e a média do número de avaliações da função objetivo. Com base nestes parâmetros, a melhor função de penalização foi escolhida para que uma nova função seja desenvolvida, onde a variação brusca dos diâmetros de tubulações adjacentes também deverá ser penalizada, possibilitando o projeto de redes mais uniformes e condizentes com os aspectos operacionais.

2. DIMENSIONAMENTO OTIMIZADO

2.1. Formulação do Problema

O problema de dimensionamento de redes de abastecimento de água resume-se a determinar o diâmetro das tubulações que satisfaçam os limites operacionais de velocidade e pressão. Assim, o problema possui inúmeras soluções. Entretanto, do ponto de vista econômico, é interessante que a solução obtida tenha um baixo custo, de tal modo que um problema de otimização para determinação dos diâmetros ótimos pode ser expresso pela função objetivo apresentada na Eq. (1).

$$FO = \min \left(\sum_{i=1}^{NT} CT_{D_i} \cdot L_i + pen \right) \quad (1)$$

em que:

FO [\$] - função objetivo;

NT [-] - número de tubulações da rede;

CT_{D_i} [\$/m] - custo unitário da tubulação associado ao seu diâmetro;

L_i [m] - comprimento da tubulação;

pen [\$] – penalização associada às restrições do problema.

Os limites operacionais são inseridos no problema como restrições. Tendo em conta as redes de estudo utilizadas nesse trabalho, apenas a pressão mínima será considerada, conforme Eq. (2).

$$p_{min} \leq p_j \quad (2)$$

onde:

p_{min} [m] - pressão mínima permitida na rede;
 p_j [m] - pressão do nó j .

2.2. Particle Swarm Optimization (PSO)

O PSO baseia-se no comportamento de grupos, como por exemplo pássaros ou enxames, que iniciam a busca por alimento de forma aleatória, mas que se organizam rapidamente para criar um padrão de busca coletivo [11]. Dada sua robustez e velocidade de processamento, diversos autores tem empregado o PSO como ferramenta de otimização em problemas de análise de redes de abastecimento [12-14]. O método é baseado no comportamento de grupos de pássaros. Desta forma, a posição ocupada por cada partícula representa uma possível solução, X . Inicialmente, esta posição, assim como a velocidade de cada partícula, V , são determinadas aleatoriamente. A cada passo de tempo (iteração), a qualidade da posição de cada uma das partículas é avaliada de acordo com a função objetivo, e uma nova velocidade é calculada a partir de três parâmetros: sua inércia, sua melhor posição já ocupada (parcela cognitiva), P , e a melhor posição já encontrada pelo enxame (parcela social), G , conforme mostra a Eq. (3). Em seguida, a posição das partículas é atualizada conforme a Eq. (4). Assim, garante-se aleatoriedade no processo de busca, além de considerar a performance individual de cada partícula e a performance global do grupo, o que torna o método rápido e eficiente.

$$V_i^{k+1} = \omega \cdot V_i^k + c_1 \cdot rand_1 \cdot \frac{(P_i^k - X_i^k)}{\Delta t} + c_2 \cdot rand_2 \cdot \frac{(G - X_i^k)}{\Delta t} \quad (3)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1} \cdot \Delta t \quad (4)$$

em que:

V [-] - velocidade da partícula;
 X [-] - posição da partícula;
 P [-] - melhor posição ocupada pela partícula;
 G [-] - melhor posição ocupada pelo grupo;
 Δt [-] - iteração

Cada um dos termos da Eq. (3) é ponderado de acordo com um coeficiente adimensional:

o coeficiente de inércia, ω , indica a capacidade da partícula em manter sua atual trajetória; o coeficiente cognitivo c_1 representa a memória da partícula, fazendo com que esta retorne aos melhores locais já visitados; e o coeficiente social c_2 demonstra a influência do grupo na trajetória da partícula, direcionando seu deslocamento para o melhor local já ocupado pelo grupo. A Figura 1 resume o processo de otimização utilizando o PSO.

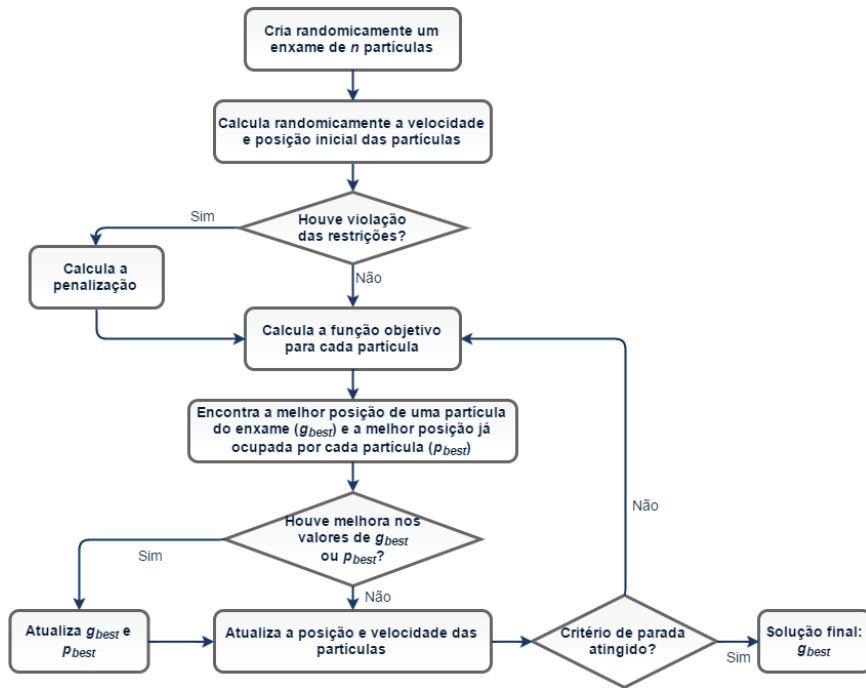


Figura 1. Fluxograma do processo de otimização utilizando PSO.

2.3. Algoritmo Genético (AG)

O algoritmo genético (AG) foi a primeira técnica de otimização bio-inspirada aplicada para solucionar o problema de dimensionamento de redes de abastecimento de água [15]. Desenvolvido por [16] e adaptado por [17], baseia-se no processo de seleção natural de Darwin, onde, devido às alterações do ambiente, apenas os indivíduos com melhor adaptação às novas condições sobrevivem. Assim, cada indivíduo x da população representa uma possível solução, e o valor da função objetivo associado ao indivíduo determina sua probabilidade de permanecer na próxima geração, conforme Eq. (5).

$$p(x_i) = \frac{FO(x_i)}{\sum_{j=1}^n s(d(x_i, x_j))} \quad (5)$$

em que $p(x_i)$ representa a probabilidade do indivíduo i se reproduzir ou permanecer na

população, FO é a função objetivo, $d(x_i, x_j)$ é a distância entre os indivíduos i e j , e s é uma função de compartilhamento, utilizada para reduzir a probabilidade de indivíduos similares se reproduzirem, garantindo maior diversidade à população.

A evolução da população é garantida através dos processos de cruzamento e mutação. No cruzamento, as características de dois indivíduos são utilizadas para formar um novo indivíduo, como no processo de reprodução. A mutação garante a diversidade (aleatoriedade) da população, pois altera apenas uma característica de alguns indivíduos. A Figura 2 apresenta o fluxograma do processo de otimização utilizando AG.

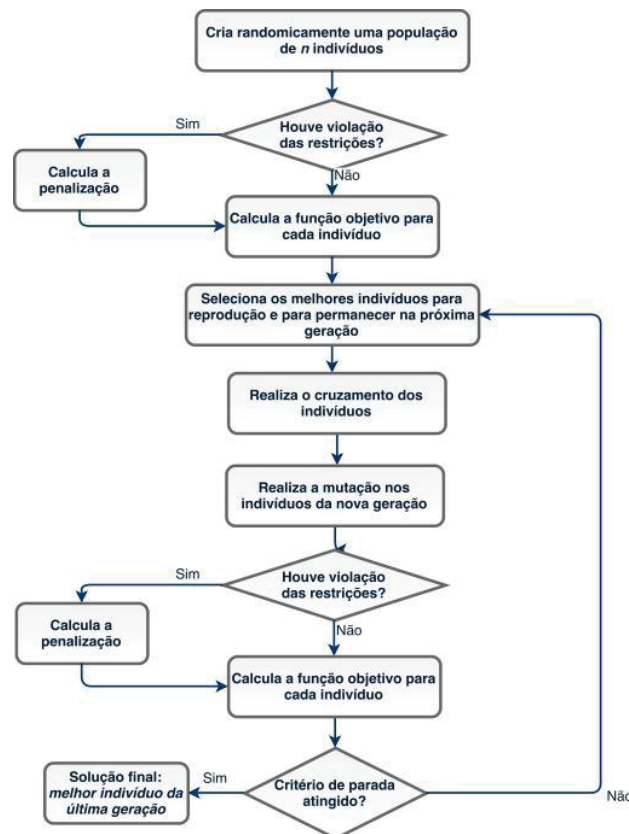


Figura 2. Fluxograma do processo de otimização utilizando AG.

2.4. Funções de Penalização

Como mencionado anteriormente, o processo de busca pelo valor ótimo da função objetivo feito pelos métodos meta-heurísticos é irrestrito. Desta forma, é necessário adicionar uma penalização à esta, de forma que, quando a restrição é violada, há um aumento no valor da função objetivo, indicando que a solução não é um ponto de mínimo. Entretanto, atribuir um valor a esta penalização não é simples. De acordo com [9], altas penalizações criam barreiras na exploração do espaço, enquanto que penalizações brandas

resultam em soluções não-factíveis. Assim, para que seja possível encontrar uma solução factível, próxima do mínimo global, e com um baixo custo computacional, as oito funções de penalização apresentadas na Tabela 1 foram avaliadas.

Autor	Função de Penalização
Wu e Simpson (2002) [9]	$\begin{aligned} & \text{Se: } pop_{pen} > 0.8 \cdot pop & \text{Se: } pop_{pen} < 0.2 \cdot pop \\ & \begin{cases} \alpha_{max} = 1,2 \cdot \alpha_{max} \\ \alpha_{min} = 1,2 \cdot \alpha_{min} \end{cases} & \begin{cases} \alpha_{max} = 0,8 \cdot \alpha_{max} \\ \alpha_{min} = 0,8 \cdot \alpha_{min} \end{cases} \\ & \alpha = \alpha_{min} + rand \cdot (\alpha_{max} - \alpha_{min}) \\ & Pen = \alpha \cdot \sum_{j=1}^{NN} p_{min} - p_j \end{aligned}$
Haddad (2007) [18]	$Pen = \frac{t}{t_{max}} \cdot 10^6 \cdot \sum_{j=1}^{NN} p_{min} - p_j $
Van Dijk et al (2008) [19]	$\begin{cases} b = \sum_{i=1}^{NT} \alpha \cdot \left[\frac{p_{min} + (p_{min} - p_{jus})}{p_{min}} \right] \cdot \left(\frac{Q_i}{dem_{jus}} \right), & \text{se } 0 \leq p_{jus} < p_{min} \\ b = 5, & \text{se } p_{jus} < 0 \end{cases}$ $Pen = \sum_{i=1}^{NT} CT_{D_i}^b \cdot L_i$
Djebedjian et al (2010) [20]	$Pen = \frac{CT}{NN} \cdot \sum_{j=1}^{NN} p_{min} - p_j $
Arora (2013) [21]	$\begin{cases} Pen = 0.004 \cdot CT_{max} \cdot p_{min} - p_j , & \text{se } 0 < p_j < p_{min} \\ Pen = 2 \cdot 0.004 \cdot CT_{max} - 2 \cdot CT, & \text{se } p_j \leq 0 \end{cases}$
Johns (2013) [22]	$Pen = 10^6 \cdot \sum_{j=1}^{NN} p_{min} - p_j + Pen_D$ $Pen_D = 10^6 \cdot \sum_{j=1}^{NN} D_{j,jus} - D_{j,mon} , \text{ se } D_{j,jus} > D_{j,mon}$
Sheikholeslami ^a (2014) [23]	$Pen = CT \cdot \sum_{j=1}^{NN} \frac{ p_{min} - p_j }{p_{min}}$
Sheikholeslami ^b (2014) [23]	$Pen = CT \cdot \sum_{j=1}^{NN} \left(\frac{ p_{min} - p_j }{p_{min}} \right)^\epsilon$

Tabela 1. Funções de penalização.

em que:

- Pen [\$] - penalidade à ser adicionada à função objetivo
- CT [\$] - custo total das tubulações;
- NN [-] - número de nós da rede;
- pop_{pen} [-] - número de partículas que violaram as restrições;
- t [-] - iteração atual;
- t_{max} [-] número máximo de iterações permitida;
- CT_{max} [\$] - custo total utilizando tubulações com o maior diâmetro disponível;
- Q_i [m³/s] - vazão no tubo i ;
- p_{jus} [m] - pressão no nó abastecido pelo tubo i ;
- dem_{jus} [m] - demanda do nó abastecido pelo tubo i ;
- ε [-] - coeficiente que varia linearmente entre 1.05 e 1.20;
- Pen_D [\$] - penalização referente à variação de diâmetro;
- $D_{j,jus}$ [mm] - diâmetro da tubulação à jusante do nó j ;
- $D_{j,mon}$ [mm] - diâmetro da tubulação à montante do nó j ;

2.5. Redução Gradual de Diâmetros

Para adequar os resultados obtidos com dimensionamento otimizado à realidade, a redução do diâmetro em tubulações subsequentes não pode ocorrer de forma brusca, uma vez que isto pode causar uma perda de carga localizada elevada, além de não ser uma prática comum. Assim, o conceito definido por [22] e [24], onde as tubulações de jusante não podem apresentar diâmetros maiores que as tubulações de montante, uma vez que a vazão máxima nesta tubulação é menor ou igual à observada na tubulação conectada a montante, é adotado, adicionado-se a restrição de que a tubulação a jusante não pode sofrer uma redução maior que dois diâmetros comerciais disponíveis. Assim, a função de penalização dos diâmetros, apresentada pela Eq. (6) deverá ser adicionada à melhor função de penalização de pressões encontrada.

$$Pen_D = \alpha \cdot \sum_{j=1}^{NT} |D_{j,jus} - D_{j,mon}|, \text{ se } D_{j,jus} > D_{j,mon} \text{ e } 2 \cdot ID_{D_{j,jus}} < ID_{D_{j,mon}} \quad (6)$$

3. RESULTADOS

3.1. Two-loop

A rede *Two-Loop* é amplamente utilizada para avaliar a eficácia de métodos de otimização para o dimensionamento econômico de suas tubulações, sendo [3] os primeiros a estudá-la. Esta é uma rede pequena, que possui oito tubulações, seis nós e um reservatório de nível fixo, conforme ilustra a Figura 3.




Figura 3. Esquema da rede Two-Loop

Buscando o menor custo, tanto o PSO quanto o AG foram configurados com 16 partículas/população, número máximo de iterações/gerações igual a 1000 e como critério de parada uma tolerância para a variação da função objetivo de 10^{-12} . Além disso, para o AG considerou-se uma taxa de elitismo de 12 %. A Figura 4 apresenta os resultados obtidos. Observa-se que, com exceção da função proposta por Djebedjian et al (2010) e por Arora et al (2013), apenas para o AG, todas as outras foram capazes de encontrar o valor mínimo para o problema. Além de não alcançarem o valor *benchmark*, estas duas funções apresentaram uma alta taxa de penalização, assim como a proposta por Sheikholeslami^a (2014), Haddad (2007) quando o PSO é utilizado e Van Dijk *et al* (2008) quando o AG é utilizado. Observando o valor médio da função objetivo, os melhores resultados foram obtidos com as funções propostas por Sheikholeslami^b (2014) e Johns *et al* (2013). Entretanto, em algumas simulações feitas com a primeira não houve convergência, resultando em um elevado número de iterações.

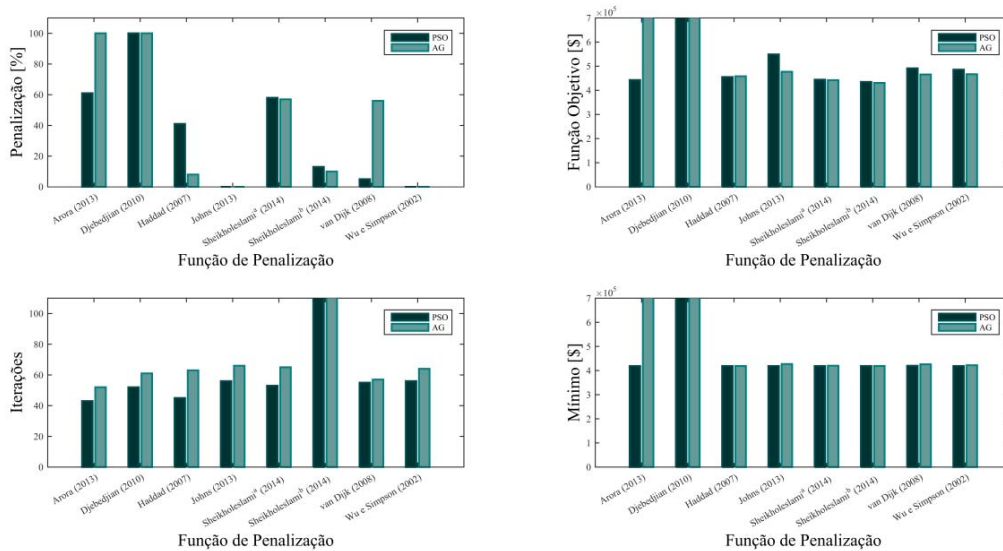


Figura 4. Comparação das funções de penalização no dimensionamento econômico da rede Two-Loop.

3.2. Hanoi

Assim como a rede Two-Loop, a rede Hanoi também é utilizada como benchmark em estudos de dimensionamento econômico. Apesar de ainda ser uma rede pequena, com 34 tubos e 31 nós (Figura 5), sua complexidade hidráulica dificulta a obtenção de um valor ótimo.




Figura 5. Esquema da rede Hanoi

Neste caso, o PSO e o AG foram configurados para empregar 68 partículas/população. O número máximo de iterações/gerações, critério de parada e a taxa de elitismo do AG foram mantidas iguais ao caso anterior, ou seja, com 1000, 10^{-12} e 12% respectivamente. A Figura 6 apresenta os resultados obtidos. Observa-se um comportamento similar das funções. Com exceção da proposta por Van Dijk et al (2008) e Wu e Simpson (2002), pois foram incapazes de obterem um valor mínimo próximo ao *benchmark* quando o PSO é utilizado, além de apresentarem uma elevada taxa de penalização.

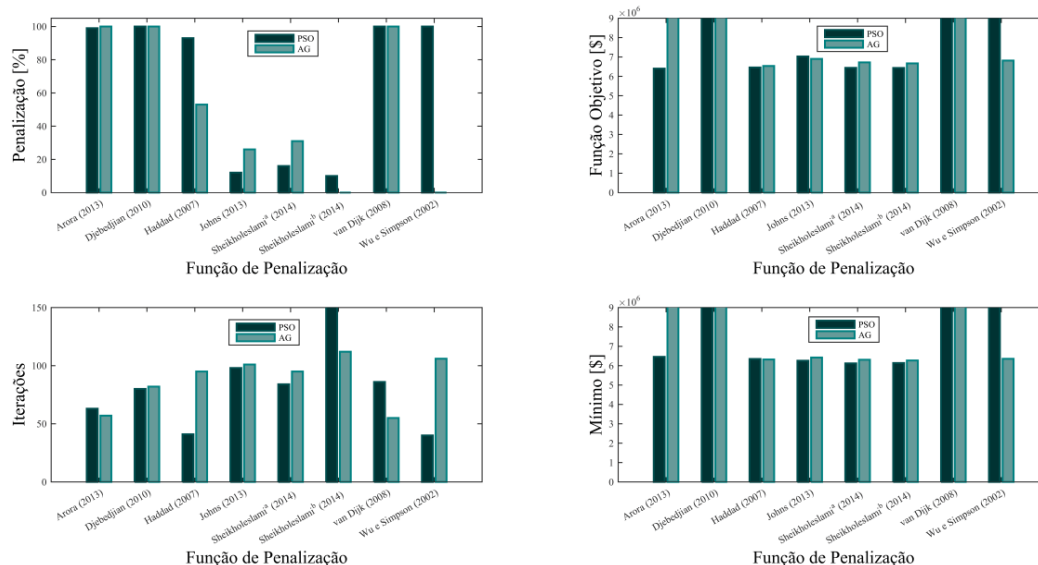


Figura 6. Comparação das funções de penalização no dimensionamento econômico da rede Hanoi

3.3. Redução Gradual de Diâmetros

Considerando os resultados obtidos nos dois estudos de caso, observou-se que o melhor desempenho foi obtido com a função proposta por Sheikholeslami^b (2014), apesar de em alguns casos não convergir. Assim, optou-se pela sua utilização para penalização da restrição de pressão mínima em conjunto com a penalização para a redução gradual dos diâmetros apresentada na Eq. (6). Assim, o dimensionamento das duas redes foi feito novamente com esta nova metodologia, utilizando as mesmas configurações para o PSO e AG. A Figura 7 apresenta os resultados obtidos. Para todos os casos, houve um aumento no número de soluções penalizadas. Apesar disso, não houve problemas de convergência como observado na função proposta por Sheikholeslami^b (2014), apesar do aumento no número de iterações necessárias.




Figura 7. Desempenho da função de penalização para redução gradual dos diâmetros: a) Two-Loop; b) Hanoi

Ao observar o valor mínimo da função objetivo, nota-se que a redução gradual gerou um investimento adicional de 13.4 % para a rede Two-Loop, enquanto que para a rede Hanoi este aumento variou entre 5.9 %, quando o PSO foi utilizado, e 10.4 %, utilizando o AG. Do ponto de vista hidráulico, para a rede Two-Loop, houve um aumento médio da pressão de 12.2 % e da resiliência de 102.2 %, enquanto que para a rede Hanoi, o aumento médio de pressão foi de 11.4 % e da resiliência de 33.3 %, confirmando a maior flexibilidade da rede para possíveis expansões. As Figuras 8 e 9 apresentam uma comparação dos diâmetros das tubulações e o campo de pressões para cada um dos casos.




Figura 8. Comparação dos resultados entre o dimensionamento padrão e com redução gradual para a rede Two-Loop: a) Comparação dos diâmetros; b) Campo de pressões para o dimensionamento padrão; c) Campo de pressões para o dimensionamento com redução gradual.




Figura 9. Comparação dos resultados entre o dimensionamento padrão e com redução gradual para a rede Hanoi: a) Comparação dos diâmetros; b) Campo de pressões para o dimensionamento padrão; c) Campo de pressões para o dimensionamento com redução gradual.

4. CONCLUSÕES

O trabalho avaliou a performance de oito diferentes funções de penalização, utilizando os métodos meta-heurísticos de otimização PSO e AG, para a solução do problema de dimensionamento econômico. Ao avaliar os resultados para as redes benchmark Two-Loop e Hanoi, observou-se que as funções propostas por Johns et al (2013) e Sheikholeslami^b (2014), além de apresentarem as melhores performances, também mantiveram maior consistência quanto ao método de otimização utilizado e a rede em análise. Assim, para o estudo da redução gradual dos diâmetros, optou-se por utilizar a função proposta por Sheikholeslami^b (2014) para penalizar a restrição de pressão mínima. Com esta nova metodologia, houve uma queda de performance no número de soluções penalizadas e na quantidade de iterações necessárias, apesar de não ter ocorrido problemas de convergência como observado anteriormente. Com relação aos custos, para a rede Two-Loop o investimento adicional foi de 13.4 %, enquanto que para a rede Hanoi este aumento variou entre 5.9 %, quando o PSO foi utilizado, e 10.4 %, utilizando o AG. Considerando-se a maior facilidade para implantação das tubulações, melhores condições para manutenção e maior facilidade para expansão da rede, este custo adicional pode ser recuperado durante a vida útil do sistema, sendo uma alternativa que justifica-se para o dimensionamento de novas redes.

5. REFERÊNCIAS

- [1] Coelho, B., Campos, A. A. "Efficiency achievement in water supply systems-A review", *Renewable and Sustainable Energy Reviews*, Vol. 30, pp. 59–84, 2014.
- [2] D'Ambrosio C., Lodi A., Wiese S., Bragalli C., "Mathematical Programming techniques in Water Network Optimization". *European Journal of Operational Research*, Vol. 3, No. 6, pp. 774-788, 2014.
- [3] Alperovits, E., Shamir, U. "Design of optimal water distribution systems". *Water Resources Research*, Vol. 13, No 6, pp. 885-900, 1977.

- [4] Mora-Melia, D., Iglesias-Rey, P. L., Martínez-Solano, F. J., Ballesteros-Pérez, P. (2015). "Efficiency of Evolutionary Algorithms in Water Network Pipe Sizing". *Water Resources Management*, Vol. 29, No. 13, pp. 4817–4831.
- [5] Maier, H.R., Simpson, A.R., Zecchin, A.C., Foong, W.K., Phang, K.Y., Seah, H.Y. & Tan, C.L. (2003). "Ant colony optimization for design of water distribution systems". *Journal of Water Resources Planning and Management*, 139(3), 200-209.
- [6] Karaboga, D., Basturk., B. (2007). "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm". *Journal of Global Optimization*. Vol. 39, pp. 459-471.
- [7] Geem, Z. W., Kim, J. H. & Loganathan, G. V. (2001). "A New Heuristic Optimization Algorithm: Harmony Search", *Simulation*, 76(2), 60-68.
- [8] Maier H. R. "Thematic issue on Evolutionary Algorithms in Water Resources" *Environmental Modelling & Software*, Vol. 69, pp. 222-225, 2015.
- [9] Wu, Z. Y., Simpson, A. R. "A self-adaptive boundary search genetic algorithm and its application to water distribution systems", *Journal of Hydraulic Research*, Vol. 40, No. 2, pp. 191-203, (2002).
- [10] Yeniay O. "Penalty function methods for constrained optimization with genetic algorithms". *Mathematical and Computational Applications*, Vol 10, No. 1, pp 45-56, 2005.
- [11] Eberhart, R. C., Kennedy, J. "A new optimizer using particle swarm theory". In: *Proceedings of the sixth international symposium on micro machine and human science* (1995), Vol. 1, pp. 39-43.
- [12] Brentan B. M., Luvizotto Júnior, E. "PSO applied to reduce the cost of energy in water supply networks". *Applied Mechanics and Materials*, No. 409–410, pp. 703–706, (2013).
- [13] 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*, Vol. 29, No. 6, pp. 433-448, (2014).
- [14] Vassiljev, A., Koor, M., & Koppel, T. "Real-time demands and calibration of water distribution systems". *Advances in Engineering Software*, Vol.89, pp. 108-113, (2015).
- [15] Walters, G. A., Savic, D. A. "Optimal design of water systems using Genetic Algorithms and other Evolution Programs". *Transactions on Ecology and the Environment*, Vol. 7, (1994).
- [16] Holland, J.H. "Adaptation in Natural and Artificial Systems". *University of Michigan Press*, (1975).
- [17] Goldberg, D.E. "Genetic Algorithms in Search", *Optimization and Machine Learning*, Addison Wesley, (1989).
- [18] Haddad, O. B., Mariño, M. A. "Dinamic penalty function as a strategy in solving water resources combinatorial optimization problems with honey-bee mating optimization algorithm." *Journal of hydroinformatics*, Vol. 9, No. 3, pp. 233-250, (2007).
- [19] Van Dijk, M., Van Vuuren, S. J., Van Zyl, J. E. "Optimising water distribution systems using a weighted penalty in a genetic algorithm", *Water SA*, Vol. 34, No. 5, pp. 537-548, (2008).

- [20] Djebedjian, B., Yaseen, A., Rayan, M. A. "Optimization of large water distribution network design using genetic algorithms." *Tenth international water technology conference* (2006), pp. 447-477
- [21] Arora, S. Jaiswal, A. "Optimal cost of irrigation network design using epanet." *International journal of computer applications*, Vol. 68, No.21, pp. 41-44, (2013).
- [22] Johns, M. B. Keedwell, E. Savic, D. "Pipe smoothing genetic algorithm for least cost water distribution network design." In: *Proceedings of the 15th annual conference on Genetic and evolutionary computation*. ACM, (2013), pp. 1309-1316.
- [23] Sheikholeslami, R. Kaveh, A. Tahershamsi, A. Talatahari, S. "Application of charged system search algorithm to water distribution networks optimization." *International journal of optimization in civil engineering*, Vol. 4, pp. 41-58, (2014).
- [24] Montalvo, I. "Diseño óptimo de sistemas de distribución de água mediante Particle Swarm Optimization. Tese de Doutorado (em Espanhol). Universitat Politècnica de València, (2008).