

Análise Comparativa Entre RNA, AG e Migha na Determinação de Rugosidades Através de Calibração de Redes Hidráulicas

Valder Adriano Gomes de Matos Rocha¹, John Kenedy Araújo², Marco Aurélio Holanda de Castro²,
Magno Gonçalves da Costa³, Luis Henrique Magalhães Costa⁴

gomesdematos@hotmail.com

Recebido: 24/06/11 – revisado: 18/09/11 – aceito: 06/10/12

RESUMO

Este trabalho realiza uma análise comparativa entre três métodos de estimativa de rugosidades de redes de abastecimento de água mediante a calibração de redes hidráulicas. No primeiro método, a rede neural artificial (RNA) foi a ferramenta de otimização adotada, enquanto o balanceamento hidráulico é obtido por meio de biblioteca dinâmica do EPANET. O segundo, conhecido como método iterativo de gradiente hidráulico alternativo (MIGHA), inicialmente desenvolvido para estimar parâmetros hidrodinâmicos, foi adaptado neste trabalho. A terceira ferramenta de otimização é o já consagrado algoritmo genético. O procedimento correto seria adquirir, por medições de campo, dados de variação temporal da carga de pressão e, utilizando-os, resolver o problema inverso por intermédio de um confronto entre as cargas de pressão observadas e estimadas. A metodologia de estimação utilizará dados adquiridos por meio de uma rede hipotética.

Palavras-chave: Calibração de rugosidades. Redes Neurais Artificiais (RNA). MIGHA. Algoritmo Genético (AG). EPANET.

INTRODUÇÃO

Segundo Silva (2006), calibração é o processo de identificação de parâmetros necessários para que a simulação hidráulica de redes de distribuição de água represente com fidelidade o comportamento do sistema.

A de calibração é importante porque as equações de condições de equilíbrio hidráulico dependem de vários fatores, como características do fluido transportado, geografia local e aspectos físicos das peças do sistema, traduzindo-se, portanto, em uma grande quantidade de variáveis envolvidas e, o uso adequado e preciso tanto quanto possível dessas variáveis se traduzirá na confiabilidade dos modelos hidráulicos.

As técnicas utilizadas para estimativa de rugosidades de redes de distribuição via calibração desenvolvem-se desde a década de 1970 e podem ser

divididas em três classes: (1) procedimentos de tentativa e erro por meio de equações analíticas (BHAVE, 1988; WALSKI, 1983); (2) métodos explícitos ou simulação hidráulica (BOULOS; WOOD, 1990; ORMSBEE; WOOD, 1986) e (3) métodos implícitos ou otimização.

Nos métodos explícitos, os parâmetros componentes do cálculo do equilíbrio hidráulico da rede podem ser obtidos de forma explícita, mediante a resolução analítica do sistema de equações não lineares. Para isso o número de medidas de pressões e/ou vazões deve ser igual ao quantitativo de parâmetros desconhecidos.

Entende-se por métodos implícitos aqueles que consistem na minimização de uma função objetivo que, geralmente, é o módulo da diferença entre os valores de dados observados e calculados de pressão e/ou vazão do sistema. Há vários trabalhos utilizando estes métodos. Ormsbee (1989) ajustou as rugosidades para diversas condições de carga em regime permanente utilizando um algoritmo de otimização não-linear. Lansey e Basnet (1991) incorporaram um modelo de simulação hidráulica ao algoritmo de programação não linear para a estimativa de coeficientes de rugosidades, aberturas de válvulas e demandas nodais por calibração. Araújo (2003) utilizou o método transiente inverso para propor uma técnica a fim de estimar vários parâme-

¹ Departamento de Ciências Ambientais e Tecnológicas da Universidade Federal Rural do Semiárido

² Departamento de Engenharia Hidráulica e Ambiental da Universidade Federal do Ceará

³ Universidade Federal do Ceará

⁴ Universidade Federal da Bahia

tros com base em cargas de pressão transientes na calibração de modelos hidráulicos.

METODOLOGIA

Os métodos apresentados neste trabalho estimam as rugosidades das tubulações de uma rede hipotética de distribuição de água que, com o balanceamento hidráulico, resultam em pressões calculadas bastante próximas das observadas. O MIGHA e os algoritmos genéticos (AG) utilizam uma função objetivo que, por meio de iterações com o simulador hidráulico EPANET (ROSSMAN, 2000), ajustam continuamente as rugosidades até que a função objetivo atinja um valor mínimo, enquanto a RNA treina a rede com dados fornecidos e, com base nisso, estima as rugosidades.

Dentre as linguagens de programação disponíveis, para efetuar as modelagens dos métodos, escolheu-se a linguagem DELPHI 7.0, para o *software* do MIGHA e também para o do AG, em função de sua facilidade de uso e, principalmente, por proporcionar recursos numéricos e gráficos, que oferecem um tratamento adequado à modelagem numérica, além do fornecimento de elementos importantes para a visualização e a interpretação dos resultados.

Embora seja um programa de uso livre, o EPANET (ROSSMAN, 2000) mostra-se bastante robusto e eficaz como auxílio ao projetista de redes de distribuição de água. A fusão das rotinas de otimização e do cálculo hidráulico é possível em razão da capacidade que o EPANET possui de ser incorporado a outros programas e ser utilizado conforme as necessidades do usuário, pois as rotinas de cálculo estão dispostas em uma biblioteca (Epanet2.dll), possibilitando a implementação de programas específicos.

Redes Neurais Artificiais - RNA

Neurônio Artificial

As RNA's foram concebidas com o intuito de se obter um mecanismo artificial capaz de simular o sistema de aprendizado do cérebro.

Da mesma forma que uma rede neural biológica, uma RNA é composta de um massivo conjunto de unidades paralelas de processamento, porém em uma escala bem menor.

Estas unidades, chamadas de neurônios, em ambos os casos, são responsáveis por armazenar e utilizar as informações aprendidas; contudo, os neu-

rônios artificiais possuem estruturas muito mais simples do que os biológicos.

Os neurônios artificiais são compostos por três partes principais:

- dendrito / terminal de entrada;
- corpo celular / função de ativação;
- axônio / terminal de saída.

Em analogia ao neurônio biológico, no neurônio artificial, as ligações que conectam um neurônio a outro, assim como o aprendizado, ocorrerão por intermédio de pesos atribuídos a estas ligações. A estes pesos dá-se o nome de *pesos sinápticos*.

Funções de ativação

A função de ativação, ou função de transferência, define a forma como será repassada a informação entre neurônios artificiais. Dá-se pela adição do produto dos sinais de entrada pelos pesos sinápticos respectivos, mais um estímulo externo (*bias*), para produzir um resultado que servirá como entrada para o neurônio subsequente.

Dentre as funções diferenciáveis, as mais utilizadas são a função sigmóide, a tangente hiperbólica e a gaussiana. As equações 1, 2 e 3 correspondem, respectivamente, às funções citadas.

$$\varphi(v) = \frac{b}{1+e^{-av}} \quad (1)$$

$$\varphi(v) = a \frac{e^{(bv)} - e^{(-bv)}}{e^{(bv)} + e^{(-bv)}} \quad (2)$$

$$\varphi(v) = ae^{\frac{(v-b)^2}{2c^2}} \quad (3)$$

Treinamento e validação da RNA

Neste experimento, foram aplicadas redes do tipo MLP (em inglês *MultiLayer Perceptrons* – MLP) para solução do problema de calibração de modelos de simulação hidráulica.

A capacidade de aprendizado de uma RNA é sua mais importante característica. Com base em um conjunto de regras preestabelecidas, ela é capaz de adaptar-se às respostas esperadas, alterando-se a cada situação apresentada. Mais especificamente, o treinamento de uma rede é realizado com o ajustamento dos pesos sinápticos de cada conexão. Estes pesos formam uma matriz que será a memória do que foi “aprendido” pela RNA.

Quanto à forma com que é feito o ajuste dos pesos, os métodos de aprendizagem podem ser su-

pervisionados, onde padrões de entradas e saídas são fornecidos; ou não supervisionado, em que apenas os padrões de entrada estão disponíveis. As redes MLP utilizam aprendizado supervisionado.

Para evitar problemas de estabilidade da RNA, recomenda-se a normalização (padronização) dos dados de entrada. Esta normalização, no caso da variável de entrada ser contínua, é geralmente realizada para o intervalo $[-1,1]$ ou $[0,1]$.

Após o fornecimento dos dados, a rede neural calculará o erro entre o padrão de saída pretendido e o obtido por ela. Com base nessa avaliação, o algoritmo de treinamento fará o ajuste dos pesos. O algoritmo supervisionado mais conhecido para treinamento de redes neurais artificiais multicamadas é o algoritmo *backpropagation*. O treinamento é realizado nas fases *forward* e *backward*. A primeira fase determina a resposta da rede para certo conjunto de dados de entrada. Na outra fase, a resposta calculada é comparada com a resposta desejada e, assim, calcula-se o erro ocorrido, atualizando-se os pesos das conexões.

Para realização dos cálculos de treinamento e validação das RNAs, adotou-se o *software* comercial desenvolvido pela empresa Vesta Systems, QNet v2000, em versão demonstrativa. O modelo de RNA adotado é o *Multi-Layer Perceptrons* (MLP). Apesar de simples, este é um dos mais precisos *softwares* para treinamento de RNA de que se dispõe (GROWE, 1999).

A RNA passa inicialmente por uma etapa denominada *treinamento*, onde cerca de oitenta por cento dos dados de entrada e dados de saída são lançados simultaneamente no programa QNET e a rede vai ser *treinada*, ou seja, vai aprender a correlacionar dados de entrada com dados de saída.

Após treinada, a rede será *validada*. Nesta etapa, os vinte por cento restantes dos dados serão utilizados. Aqui, entra-se apenas com os dados de entrada e solicita-se que a rede retorne com os dados de saída estimados. Em seguida, faz-se a comparação entre os dados medidos (reais) e os estimados pela rede. Então é calculado o erro absoluto, fazendo a diferença entre as rugosidades reais e as estimadas.

Em suma, pode-se dizer que as redes neurais artificiais são capazes de correlacionar os dados de entrada com os dados de saída mediante funções preestabelecidas e, com suporte nessas correlações (aprendizado), podem ser obtidos dados de saída com base em quaisquer novos dados de entrada lançados na RNA.

Saldarriaga, Gómez e Salas (2004) exibem duas hipóteses de arquitetura de uma RNA para uso em calibração de redes hidráulicas.

A primeira considera as mesmas variáveis presentes no cálculo hidráulico. Assim, os dados de entrada na RNA são: viscosidade, aceleração da gravidade, comprimento, diâmetro, material, demanda, cota topográfica, carga de pressão e altura manométrica fornecida. Os dados de saída seriam: rugosidade absoluta ou coeficiente de perda de carga, coeficientes de vazamentos e expoentes de vazamentos. Caso se pudesse realizar a validação de uma RNA com todas essas considerações, seria possível calibrar praticamente qualquer tipo de rede hidráulica mediante o simples cálculo da RNA. Tal suposição se torna inviável pela complexidade que se transferiria à RNA.

Na segunda hipótese, é sugerida a criação de uma RNA cujos dados de entrada são apenas as medidas em campo e as cargas de pressão iniciais. Os dados de saída: os mesmos da hipótese anterior. Deve-se observar que esta RNA será válida apenas para a configuração da rede hidráulica utilizada no treinamento. Se houver qualquer alteração na rede, variação nos consumos ou mudança do número de pontos monitorados, inutilizará a RNA treinada. Deve-se, então, repetir o processo de treinamento ou, até mesmo, reconstruir a RNA.

Neste trabalho, foi adotada a segunda hipótese apresentada como configuração da RNA para os testes.

Costa (2008) testou várias possíveis arquiteturas na RNA para a rede hidráulica deste ensaio. Quanto à correlação total, verificou-se que, com o uso de camadas intermediárias, as funções de ativação apresentam resultados ainda mais próximos entre si e, neste caso, foram obtidos resultados melhores para uma menor quantidade de exemplos. Portanto, entre as várias arquiteturas testadas, a que utiliza a função sigmóide e arquitetura $7 \times 14 \times 14 \times 14 \times 10$ exibiu os menores erros entre valores medidos e calculados.

Adotou-se, portanto, a RNA sig5000 $7 \times 14 \times 14 \times 14 \times 10$ para comparação de resultados.

Neste trabalho, os dados de entrada foram padronizados (normalizados) no intervalo $[0,1]$ para, em seguida, serem lançados no QNET. Após retornar dados de saída padronizados na fase de validação, procedia-se exatamente com o processo contrário, isto é, com base em resultados padronizados em $[0,1]$, foram obtidos os valores reais do parâmetro procurado, o coeficiente de rugosidade.

MIGHA

A estimativa de parâmetros (*parameter estimation*), também conhecida como problema inverso, é uma importante etapa no processo de modelagem de redes de distribuição.

Em geral, se aborda a estimativa de parâmetros utilizando o critério clássico da técnica inversa dos mínimos quadrados, onde se define uma função objetivo que minimiza a diferença entre as cargas de pressão observadas e calculadas (equação 4).

$$F_{OBJ} = \sum_{i=1}^N (h_i^{obs} - h_i^{calc})^2 \quad (4)$$

O MIGH - Método Iterativo de Gradiente Hidráulico - Guo e Zhang (1994) e Guo e Zhang (2000) - minimiza a função onde se estabelece arbitrariamente um parâmetro inicial ajustado a cada iteração.

O método iterativo de gradiente hidráulico alternativo (MIGHA) desenvolvido por Schuster (2002) abandona a calibração tradicional dos mínimos quadrados. Trata-se de um método indireto eficaz, rápido e prático, porque minimiza os resíduos dos gradientes hidráulicos dos trechos das redes de distribuição.

Aplicado neste trabalho à estimativa do parâmetro rugosidade das tubulações, o MIGHA corrige a cada iteração o coeficiente de rugosidade do trecho pela equação (5) a seguir:

$$C_j^{i+1} = C_j^i \cdot \frac{|\nabla h_j^{i,calc}|}{|\nabla h_j^{i,obs}|} \quad (5)$$

onde C_j^i é o coeficiente de rugosidade de Hazen-Williams do trecho j na iteração i , C_j^{i+1} é o coeficiente de rugosidade do trecho j na iteração $i+1$, $|\nabla h_j^{i,calc}|$ é o gradiente hidráulico calculado na iteração i do trecho j e $|\nabla h_j^{i,obs}|$ é o gradiente hidráulico observado na iteração i do trecho j .

Como critério de convergência, calculam-se em cada iteração o ângulo φ formado entre vetores do gradiente hidráulico observado e calculado no espaço unidimensional, dado pela equação (6) a seguir:

$$\cos \varphi_j = \frac{\nabla h_j^{obs} \cdot \nabla h_j^{calc}}{|\nabla h_j^{obs}| \cdot |\nabla h_j^{calc}|} \quad (6)$$

Pela fórmula descrita há pouco, vemos que os resultados só podem ser $\cos \varphi = -1$ ou $\cos \varphi = 1$, ou seja, o ângulo φ só pode resultar em 0° ou 180° .

O critério é a aceitação apenas dos ângulos menores que 60° , ou seja, $\varphi < 60^\circ$; os ângulos maiores que este valor não são considerados até que as rugosidades dos trechos vizinhos induzam a diminuição deste ângulo nas próximas iterações.

Calculado o ângulo em uma iteração i , se este ângulo for maior do que 60° calcula-se C_j^{i+1} pela equação 6, senão repete-se o valor anterior, ou seja:

$$\begin{cases} \text{Se } \varphi < 60^\circ \Rightarrow C_j^{i+1} = C_j^i \cdot \frac{|\nabla h_j^{i,calc}|}{|\nabla h_j^{i,obs}|} \\ \text{Se } \varphi \geq 60^\circ \Rightarrow C_j^{i+1} = C_j^i \end{cases} \quad (7)$$

Neste trabalho foi desenvolvido um programa computacional em linguagem DELPHI 7.0 para a resolução do problema proposto. Os dados de entrada são: pressões observadas, demandas nodais, níveis dos reservatórios, cotas topográficas dos nós, diâmetro das tubulações, comprimento das tubulações, rugosidades observadas das tubulações.

Nesta análise comparativa, decidiu-se empregar medições de pressão em todos os nós da rede.

Algoritmos Genéticos

Módulo de calibração

Para Righetto (2001), o problema da calibração de rede consiste em se determinar o conjunto de valores das demandas nodais e dos coeficientes de rugosidade das tubulações que minimizam a função objetivo F (equação 8), definida pela soma dos quadrados das cargas nodais e vazões em trechos simulados e observados. Admitindo que se conheçam os valores das cargas de pressão em m_{obs} nós da rede, isto é, distinguindo tais nós com enumeração própria, isto é, $i^* = 1, 2, \dots, m_{obs}$, buscam-se os conjuntos de valores de rugosidade que minimizem o valor da função objetivo, ou seja:

$$\min F = \sum_{i^*}^{m_{obs}} (H_{obs,i^*} - H_{calc,i^*})^2 \quad (8)$$

Para obter-se a solução ótima, usa-se o *software* UFC4, que executa um procedimento combinando um algoritmo de busca baseado em algoritmo genético com o simulador hidráulico de redes EPANET (ROSSMAN, 2000). A rugosidade absoluta ou o coeficiente de Hazen-Williams dos tubos é continuamente ajustado até que a função objetivo (E-

quação 8) atinja um valor mínimo, resultando numa simulação que forneça pressões semelhantes àquelas observadas em campo.

O algoritmo genético

Tabela 1 – Operadores Genéticos utilizados no AG

Cruzamento	Modelo
Média Aritmética	$Filho_i = \frac{Pai_{i1} + Pai_{i2}}{2}$
Média Geométrica	$Filho_i = \sqrt{Pai_{i1} \cdot Pai_{i2}}$
Mistura (BLX- α)	$Filho_{i1} = Pai_{i1} + \beta \cdot (Pai_{i2} - Pai_{i1})$ $Filho_{i2} = Pai_{i2} + \beta \cdot (Pai_{i1} - Pai_{i2})$
Aritmética	$Filho_{i1} = \beta \cdot Pai_{i1} + (1 - \beta) \cdot Pai_{i2}$ $Filho_{i2} = (1 - \beta) \cdot Pai_{i1} + \beta \cdot Pai_{i2}$
Heurística	$Filho_{i1} = Pai_{i1} + \beta \cdot (Pai_{i1} - Pai_{i2})$
Simplex	Adaptação da recombinação da representação binária
Uniforme	$Filho_i = \begin{cases} \text{Uniforme}(a_i; b_i), & \text{se } i=j; \\ Pai_i, & \text{caso contrário} \end{cases}$
Gaussiana	$Filho_i = \begin{cases} \text{Normal}(Pai_i; \sigma), & \text{se } i=j; \\ Pai_i, & \text{caso contrário} \end{cases}$
Limite	$Filho_i = \begin{cases} a_i, & \text{se } r < 0,5 \text{ e } i=j; \\ b_i, & \text{se } r \geq 0,5 \text{ e } i=j; \\ Pai_i, & \text{caso contrário.} \end{cases}$ MICHALEWICZ, 1994
Não Uniforme	$Filho_i = \begin{cases} Pai_i + (b_i - Pai_i) \cdot f(G), & \text{se } r < 0,5 \text{ e } i=j; \\ Pai_i - (Pai_i - a_i) \cdot f(G), & \text{se } r \geq 0,5 \text{ e } i=j; \\ Pai_i, & \text{caso contrário.} \end{cases}$ MICHALEWICZ, 1994
Não Uniforme Múltipla	Amplia a aplicação do operador mutação não uniforme para todos os genes do cromossomo. MICHALEWICZ, 1994

Os algoritmos genéticos são métodos de otimização e busca inspirados na teoria da evolução das populações de seres vivos. Introduzidos por John Holland em 1975; seguem o princípio da seleção natural e sobrevivência do indivíduo mais apto. A técnica de busca para o melhor conjunto de rugosidades dos trechos de um sistema de redes de distribuição utilizando algoritmos genéticos apresenta um espaço de busca com as possíveis soluções do problema e uma função objetivo, utilizada para avaliar as soluções produzidas.

Este trabalho utiliza a representação real, haja vista as pesquisas desenvolvidas por Michalewicz (1994), cujos experimentos revelam que a representação real produz resultados melhores do que a representação binária.

Os operadores utilizados neste trabalho são apresentados na tabela 1.

Rede exemplo

Com o objetivo de avaliar a eficiência dos modelos de calibração propostos, foi analisada uma rede de distribuição hipotética criada por Walski (1983) e adaptada por Gambale (2000), consoante ilustrada na figura 1.

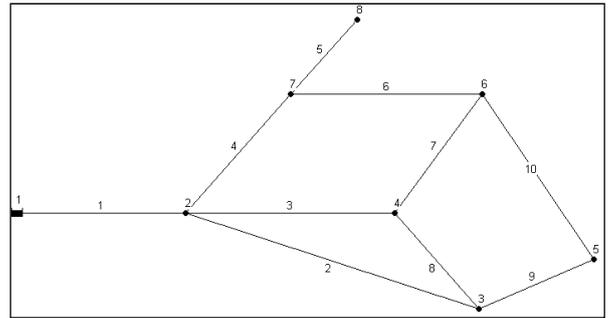


Figura 1 – Rede Hipotética

Tabela 2– Características físicas da rede hipotética

TUBO	DIÂM. (mm)	COMP. (m)	RUG.C (m ^{0,3698} /s)
1	500	700	140
2	250	1800	110
3	400	1520	130
4	300	1220	135
5	300	600	90
6	200	1220	110
7	250	920	120
8	150	300	115
9	200	600	85
10	100	1220	80

Tabela 3 – Características dos nós, Cenários 1 e 2

NÓ	Cenário 1		Cenário 2	
	DEM. (L/s)	PRESSÃO OBS. (mca)	DEM. (L/s)	PRESSÃO OBS. (mca)
2	0,0	58,74	0,0	56,44
3	15,0	55,75	36,0	48,37
4	62,5	56,08	120,0	48,72
5	15,0	53,77	10,0	47,03
6	47,5	53,35	80,0	41,80
7	30,0	54,27	80,0	44,12
8	37,5	53,03	37,5	42,88

Todas as variáveis são conhecidas. A água do reservatório de nível fixo marca a cota 60 metros e os nós estarão na mesma cota topográfica, com elevação igual a zero. As características físicas da rede em estudo estão apresentadas na tabela 2.

Considerando que o exemplo é hipotético, os dados de pressão observada não serão adquiridos em observações em campo, e sim pela simulação da rede por meio do EPANET 2.0, cujos valores de pressão calculados serão havidos como pressão observada em campo. Foram considerados dois cenários de demandas não proporcionais.

As demandas nodais e pressões observadas (sintéticas) para os cenários 1 e 2 estão indicadas na tabela 3.

Simulações

ALGORITMO GENÉTICO – como o método é um procedimento estocástico, o ato de calibração foi realizado dez vezes. A cada execução foi adotada uma população de 100 indivíduos e realizadas 100 iterações. Todas as funções inseridas foram utilizadas aleatoriamente, com a probabilidade de cruzamento e mutação de 90% e 5%, respectivamente.

- MIGHA – em cada teste, o programa foi rodado, em cada cenário, doze vezes, com um número de 100 iterações cada qual. Em seguida, foi calculada a rugosidade média dos dois cenários, então aplicada à rede para a determinação das “pressões calculadas”.
- RNA – foi utilizada a função sigmóide, tendo sido treinados 5.000 exemplos e validados 500 outros, realizando-se 1.000.000 iterações em cada exemplo.

RESULTADOS E DISCUSSÃO

A avaliação do desempenho do modelo de calibração será baseada nos critérios estabelecidos pelo Water Research Centre (1989). Para os valores de pressão, o erro absoluto, que é a diferença entre o valor calibrado e o observado, deve estar dentro das seguintes faixas:

- ± 0.5 m para 85% das medidas de pressão;
- ± 0.75 m para 95% das medidas de pressão;
- ± 2.0 m para 100% das medidas de pressão.

A tabela 4 exhibe os resultados de rugosidades obtidos para ambos os métodos, bem como as diferenças entre as rugosidades reais e calculadas de todos os trechos.

O gráfico 1 traz uma análise gráfica comparativa entre os valores reais e os calculados pelos três métodos.

Em todos os trechos, verificou-se que o sistema está calibrado segundo os critérios definidos pelo Water Research Centre. Os coeficientes de Hazen-Williams calibrados para os tubos 6, 8 e 10 apresentam, no entanto, um desvio-padrão elevado nos três métodos, entretanto, os desvios foram menos acentuados na RNA e mais acentuados no MIGHA.

Percebe-se que, nos tubos onde o erro entre a rugosidade calculada e a observada foi maior no MIGHA, tais erros ocorreram com desvios-padrão mais elevados, mostrando que o MIGHA não estima muito bem um conjunto-resposta de rugosidades, contudo, em seis tubos, as rugosidades observadas e as calculadas foram bastante semelhantes, ocorrendo, comparativamente aos outros métodos, melhores resultados pelo MIGHA em três tubos - 1, 2 e 5. Decorre daí que o MIGHA busca um conjunto-resposta que satisfaz aos critérios da Water Research Centre, no que tange à pressão, como será visto adiante, mas não é preciso quanto às rugosidades estimadas. Os AG's e as RNA's mostram-se bem mais precisos no concernente às rugosidades estimadas, porém, oferecem conjuntos-respostas com maior erro entre as pressões observadas e calculadas.

A variável que determina a acurácia da calibração de uma rede é a pressão. Na tabela 5, encontram-se os valores de pressão observados e calculados para o cenário 1.

O gráfico 2, na sequência, ilustra as diferenças entre as pressões observadas e calculadas para o cenário 1.

Na tabela 6, encontram-se os valores de pressão observados e calculados para o cenário 2.

O gráfico 3 ilustra as diferenças entre as pressões observadas e calculadas para o cenário 2.

Apesar de o erro total entre as rugosidades calculadas e observadas nos três métodos ter sido, em geral, maior na calibração com a RNA, é bastante notável a superioridade do MIGHA no que se refere à diferença de pressões em qualquer um dos cenários. Com a configuração das rugosidades calculadas pelo MIGHA, obtiveram-se pressões calculadas idênticas às observadas praticamente em todos os nós. Tal resultado demonstra que a pressão não é uma variável determinante para a calibração, porquanto, mesmo a RNA apresentando diferenças

Tabela 4 – Resultados obtidos para valores de rugosidades pelos três métodos

TU-BO	C REAL	C CALC. RNA	C CALC. MIGHA	C CALC. AG	(C _{REAL} - C _{CALC}) RNA	Erro-RNA (%)	(C _{REAL} - C _{CALC}) MIGHA	Erro-MIGHA (%)	(C _{REAL} - C _{CALC}) AG	Erro-AG (%)
1	140	138.45	139.91	140.05	1.55	1.11%	0.09	0.06%	0.05	0.04%
2	110	112.24	110.46	115.42	2.24	2.04%	0.46	0.42%	5.42	4.93%
3	130	129.52	128.78	129.85	0.48	0.37%	1.22	0.94%	0.15	0.12%
4	135	134.64	136.8	132.41	0.36	0.27%	1.8	1.33%	2.59	1.92%
5	90	89.65	89.94	92.72	0.35	0.39%	0.06	0.07%	2.72	3.02%
6	110	103.94	122.33	116.08	6.06	5.51%	12.33	11.21%	6.08	5.53%
7	120	121.52	115.11	125.9	1.52	1.27%	4.89	4.08%	5.9	4.92%
8	115	111.45	122.85	108.16	3.55	3.09%	7.85	6.83%	6.84	5.95%
9	85	86.11	87.84	86.86	1.11	1.31%	2.84	3.34%	1.86	2.19%
10	80	113.32	138.07	112.13	33.32	41.65%	58.07	72.59%	32.13	40.16%
				SOMA	63.74		89.61		89.61	

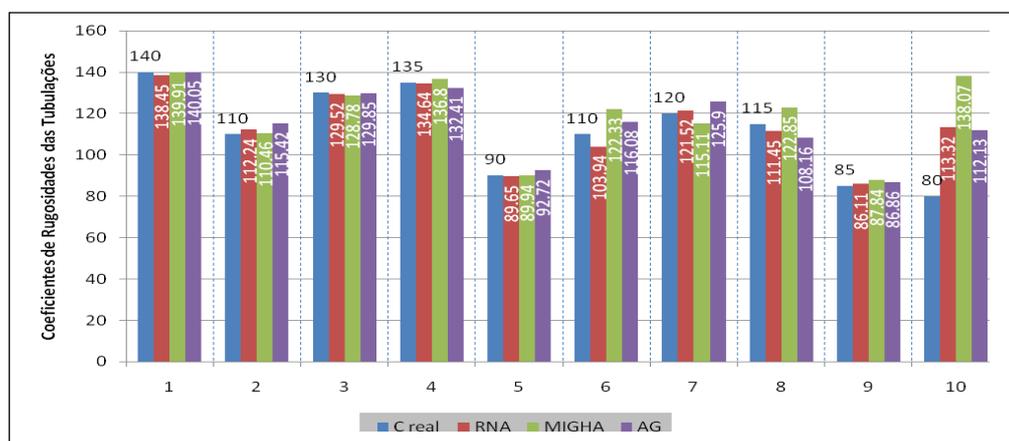


Gráfico 1 – Resultados obtidos para valores de rugosidades pelos três métodos

Tabela 5 – Resultados obtidos para valores de pressão (Cenário 1)

NÓ	PRESSIONES OBSERVADAS (mca)	PRESSIONES CALCULADAS RNA	PRESSIONES CALCULADAS MIGHA	PRESSIONES CALCULADAS AG	DIFERENÇAS RNA	DIFERENÇAS MIGHA	DIFERENÇAS AG
	1	58.74	58.72	58.74	58.66	0.02	0
2	55.75	55.72	55.75	55.75	0.03	0	0
3	56.08	56.04	56.08	56.08	0.04	0	0
4	53.77	53.73	53.76	53.77	0.04	0.01	0
5	53.35	53.35	53.35	53.35	0	0	0
6	54.27	54.27	54.27	54.17	0	0	0.1
7	53.03	53.03	53.03	53.04	0	0	0.01

Tabela 6 – Resultados obtidos para valores de pressão (Cenário 2)

NÓ	PRESSÕES	PRESSÕES	PRESSÕES	PRESSÕES	DIFERENÇAS	DIFERENÇAS	DIFERENÇAS
	OBSERVADAS (mca)	CALCULADAS RNA	CALCULADAS MIGHA	CALCULADAS AG			
1	56.44	56.37	56.44	56.37	0.07	0	0.07
2	48.37	48.24	48.36	48.39	0.13	0.01	0.02
3	48.72	48.6	48.72	48.74	0.12	0	0.02
4	47.03	46.73	47	47	0.3	0.03	0.03
5	41.8	41.86	41.81	41.81	0.06	0.01	0.01
6	44.12	44.15	44.12	44.12	0.03	0	0
7	42.88	42.9	42.88	42.88	0.02	0	0

entre as pressões (observadas e calculadas), retornou rugosidades menos distantes das reais. O mesmo é lícito dizer do AG que, mesmo exibindo algumas diferenças entre as pressões observadas e as calculadas, retornou rugosidades menos distantes das reais.

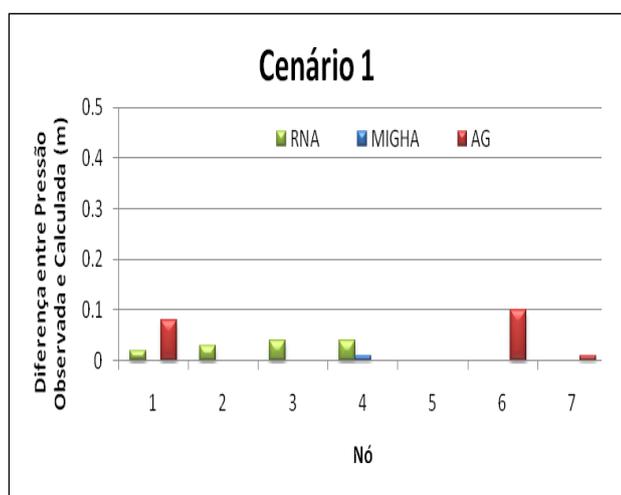


Gráfico 2 – Diferenças absolutas entre pressões reais e simuladas com as médias dos coeficientes de Hazen-Williams calibrados com MIGHA e RNA, cenário 1

Com efeito, é válido concluir-se que, para uma rede malhada, existem várias configurações de rugosidades possíveis que resultam em conjunto de pressões bem próximas. A função objetivo (equação 8) contém inúmeros pontos ótimos locais, podendo assumir valores nulos e não conter as rugosidades reais da rede.

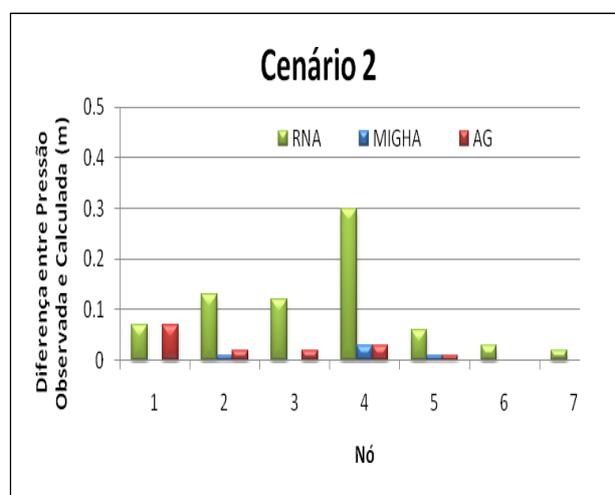


Gráfico 3 – Diferenças absolutas entre pressões reais e simuladas com as médias dos coeficientes de Hazen-Williams calibrados com MIGHA e RNA, cenário 2

Os trechos em que as rugosidades calculadas se distanciaram das reais podem ser considerados como candidatos à instalação de medidores de vazão. Uma vez conhecidas as vazões destes trechos, suas rugosidades se manterão próximas das reais, desde as primeiras iterações do processo de calibração, reduzindo o erro nos demais trechos.

CONCLUSÕES

Os modelos de calibração propostos possibilitaram a determinação de coeficientes de resistência que originam pressões calculadas bem próximas das observadas, sendo que a calibração pelo MIGHA demonstrou diferenças de pressões ainda menores

do que a calibração pelos outros métodos. Pode-se dizer, porém, que ambas as técnicas mostram resultados satisfatórios contidos nos limites estabelecidos pela Water Research Centre.

No que diz respeito aos resultados de coeficientes de rugosidades, observa-se que a RNA e o AG operam coeficientes mais próximos dos reais relativamente ao MIGHA; esta, aliás, é uma característica do MIGHA – externar um conjunto-resposta de coeficientes de rugosidades que possui um desvio-padrão relativamente alto em relação ao real, mas que possibilita resultados excelentes em termos de minimização das pressões observadas e calculadas.

Um problema observado consiste na dificuldade de previsões dos coeficientes de rugosidade em trechos com vazões relativamente menores do que os demais. Isso faz com que, nestes trechos, as variações do coeficiente de rugosidade influenciem menos os resultados das pressões a jusante. Este problema ocorreu principalmente quando estes trechos estavam localizados em malhas da rede. Ocorre que, no caso focalizado, os trechos com este problema possuíam diâmetros menores do que os demais do circuito hidráulico. Isso, conseqüentemente, fez com que estes registrassem baixas velocidades no escoamento para as configurações de demanda utilizadas. Por outro lado, pelo mesmo motivo que acarreta o erro, a imprecisão na estimativa destes parâmetros não terá grande influência para os resultados de pressões do modelo.

Uma vantagem inerente à RNA funda-se na previsão desses trechos que manifestam maior dificuldade na calibração da rugosidade. Acredita-se, como aconteceu na comparação efetivada, que esta dificuldade ocorre independentemente da técnica de calibração adotada. Com os resultados produzidos ainda durante o treinamento da RNA, quando ainda não há necessidade de medições, já é possível indicar os trechos mais adequados para uma futura medição de vazão, por exemplo.

Uma vantagem dos *softwares* desenvolvidos é que todo o procedimento de calibração da rede é realizado em etapa única, proporcionando maior acessibilidade a estudiosos, e tornando desnecessária a utilização de *softwares* de otimização. Desvantajosa, porém, no MIGHA, em relação à RNA e ao AG, é a necessidade do maior número possível de medições de pressão, o que não ocorre, na prática, em uma rede instalada em campo.

O MIGHA porta uma grande vantagem em relação a outros métodos - seu tempo de processamento, bastante inferior, por exemplo, ao algoritmo genético. Enquanto o MIGHA despendeu 23 segundos no processamento, os longos tempos computa-

cionais demandados nos treinamentos da RNA não foram tão problemáticos no caso da rede hipotética estudada. Tratando-se, porém, de redes reais, com dezenas de parâmetros a calibrar, deve-se analisar esta característica com maior cuidado. Vale ressaltar, ainda, que no procedimento de calibração é desnecessária uma resposta imediata, estando o tempo de resposta subjetivamente relacionada a cada aplicação. Mesmo assim, percebe-se melhor eficiência do MIGHA quanto ao tempo de processamento.

Neste estudo, utilizou-se um modelo hidráulico em regime permanente, com demandas fixas, tendo-se calibrado apenas o parâmetro de rugosidade das tubulações. A priori, contudo, tanto o MIGHA quanto a RNA e o AG podem ser utilizados para calibração de qualquer parâmetro, inclusive de vazamentos, bastando para isso que os dados sejam fornecidos adequadamente.

É importante observar que os algoritmos genéticos e as redes neurais são técnicas de frequente sucesso em calibrações de modelos de redes de grande porte, o que ainda não foi objeto de estudo do MIGHA. Podem ser recomendados, portanto, novos estudos atestando o comportamento do MIGHA em calibrações de redes de macrosistemas.

Recomenda-se a implementação de um método que, durante a calibração, efetue uma análise de sensibilidade da variação das rugosidades, verificando suas influências nas mudanças de pressão nos nós, determinando trechos que devem ter valores de rugosidades limitados a certo intervalo. Por fim, convém que se aplique um modelo híbrido visando a poupar esforço computacional e refinar os coeficientes de rugosidade obtidos na solução.

REFERÊNCIAS

- ARAÚJO, J. K. *Calibração de redes de distribuição de água pelo método inverso aplicado a escoamento transiente*. São Carlos. 2003. 166 p. Tese (Doutorado) -. Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2003.
- BHAVE, P. R. Calibrating water distribution network models. *Journal of Hydraulic Engineering*, v. 114, n. 1, p. 120-136, 1988.
- BOULOS, P. F.; WOOD, D. J. Explicit calculation of pipe-network parameters. *Journal of Hydraulic Engineering*, v. 116, n. 11, p. 1329-1344, 1990.

COSTA, M. G. *Redes neurais aplicadas à calibração de rugosidades de sistemas de distribuição de água*. 2008. 104 p. Dissertação (Mestrado) - Universidade Federal do Ceará, Fortaleza, 2008.

GAMBALE, S. R. *Aplicação de algoritmo genético na calibração de rede de água*. 2000. 266 p. Dissertação (Mestrado em Recursos Hídricos) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2000.

GROWE, G. A. *Comparing algorithms and clustering data: components of the data mining process*. 1999. 44 p. Thesis (Master of Science) - Grand Valley State University, Michigan, 1999.

GUO, X.; ZHANG C-M. Hydraulic gradient comparison method to estimate aquifer hydraulic parameters under steady-state conditions. *Ground Water*, v. 38, n. 6, p. 815-826, 2000.

GUO, X.; ZHANG C-M. Use of the physical feature of groundwater system to reduce the mathematic complexity in parameter identification – a practical and efficient automated procedure. In: GROUND-WATER MODELING CONFERENCE, 1994, Fort Collins, Colorado. *Proceedings...* 1994. p. 111-118.

LANSEY, K. E.; BASNET, C. Parameter estimation for water distribution networks. *Journal of Water Resources Planning and Management*, v. 117, n. 1, p. 126-144, 1991.

MICHALEWICZ, Z. *Genetic Algorithms + Data Structures = Evolution Programs*. 2nd ed. USA: Springer, 1994.

ORMSBEE, L. E. Implicit network calibration. *Journal of Water Resources Planning and Management*, v. 115, n. 2, p. 243-257, 1989.

ORMSBEE, L.E.; WOOD, D. J. Explicit pipe network calibration. *Journal of water Resources Planning and Management*, v. 112, n. 2, p. 166-182, 1986.

RIGUETTO, A. M. Calibração de modelo hidráulico de rede de distribuição de água. *Revista ABRH*, v. 6, n. 3 p. 33-44, 2001.

ROSSMAN, L. A. *EPANET 2 Users manual*. Cincinnati, Ohio: U. S. Environmental Protection Agency, 2000.

SALDARRIAGA, J.; GÓMEZ, D.; SALAS, D. Artificial Intelligence Methods Applicability on Water Distri-

bution Networks Calibration. In: WORLD WATER AND ENVIRONMENTAL RESOURCES CONGRESS, 2004, Salt Lake city, Utah. *Proceedings...* 2004.

SCHUSTER, H. D. M. Modelagem matemática do uso conjunto das águas superficiais e subterrâneas da sub-bacia das Fêmeas-Bahia (Projeto de Gerenciamento Integrado na Bacia do São Francisco – ANA/GEF/PNUMA/OEA). Salvador: SRH, 2002. p. 451-460.

SILVA, A. C. A. *Calibração automática de rugosidades de tubulações em sistemas de distribuição de água com aplicação de algoritmos genéticos*. 2006. 175 p. Dissertação (Mestrado) - Universidade Federal do Ceará, Fortaleza, 2006.

WALSKI, T. M. Technique for calibration network models. *Journal of Water Resources Planning and Management*, v. 109, n. 4, p. 360-372, 1983.

WATER RESEARCH CENTRE. *Network Analysis – a code for practice*. Swindon, England: Water Research Centre, 1989.

Comparative Analysis Between Ann, GA And MIGHA In Determining Roughness By Calibration Of Hydraulics Networks

ABSTRACT

This paper performs a comparative analysis between three methods to estimate roughness of water supply networks by calibration of hydraulics networks. In the first method, the artificial neural network (ANN) optimization tool was adopted, while hydraulic balance is achieved through the dynamic library of EPANET. The second, known as iterative alternative hydraulic gradient (MIGHA), initially developed to calibrate hydrodynamic parameters was adapted in this work. The third tool is the widely used optimization GA. The correct procedure would be to acquire, for the field measurements, data from the temporal variation of hydraulic head and, use them to solve the inverse problem through a comparison between the observed and estimated hydraulic loads. The estimation methodology uses data acquired by means of a hypothetical network.

Key-words: *Calibration of roughness, Artificial Neural Networks (ANN), MIGHA, Genetic Algorithms (GA), EPANET.*