

I-231 - ANÁLISE COMPARATIVA ENTRE DOIS MÉTODOS DE CALIBRAÇÃO DE RUGOSIDADES DE REDES: O MIGHA VERSUS AS REDES NEURAIS (RNA)

Valder Adriano Gomes de Matos Rocha⁽¹⁾

Engenheiro Civil, mestre em Saneamento Ambiental pela Universidade Federal do Ceará. Doutorando em Recursos Hídricos pela Universidade Federal do Ceará. Professor Assistente do Departamento de Ciências Ambientais e Tecnológicas da Universidade Federal Rural do Semi-Árido.

John Kenedy Araújo⁽²⁾

Engenheiro Civil, Doutor em Engenharia Hidráulica pela Universidade de São Paulo. Professor Adjunto do Departamento de Engenharia Hidráulica e Ambiental da Universidade Federal do Ceará

Marco Aurélio Holanda de Castro⁽³⁾

Engenheiro Civil, PhD., Drexel University -USA. Professor Adjunto, Departamento de Enga. Hidráulica e Ambiental, Coordenador da Pós-Graduação em Eng. Civil - Recursos Hídricos e Saneamento Ambiental. – Universidade Federal do Ceará.

Magno Gonçalves da Costa⁽⁴⁾

Engenheiro Civil, mestre em Recursos Hídricos pela Universidade Federal do Ceará.

Endereço⁽¹⁾: Av. Santos Dumont 6400 bl. C apto 1302. Bairro: Papicu. Fortaleza-CE. CEP: 60190-800 - Brasil - Tel: (85) 8744.9330 - e-mail: gomesdematos@hotmail.com

RESUMO

A realização deste trabalho visa apresentar uma análise comparativa entre dois métodos de calibração de rugosidades de redes de abastecimento de água. No primeiro método, a rede neural artificial (RNA) foi a ferramenta de otimização adotada, enquanto que o balanceamento hidráulico é obtido através da biblioteca dinâmica do EPANET. O segundo método é conhecido como método iterativo de gradiente hidráulico alternativo (MIGHA), inicialmente desenvolvido para calibrar parâmetros hidrodinâmicos como, por exemplo, condutividade hidráulica em escoamentos subterrâneos, que foi adaptado neste trabalho para calibração das rugosidades. A simulação hidráulica foi realizada de forma semelhante ao primeiro método. O procedimento válido seria adquirir, através de medições de campo, dados observados de variação temporal da carga hidráulica e, utilizando tais dados, resolver o problema inverso realizando um confronto entre as cargas hidráulicas observadas e estimadas. Neste estudo, a metodologia de estimação de parâmetros utilizará dados adquiridos por meio de uma rede hipotética.

PALAVRAS-CHAVE: Calibração de rugosidades, Redes Neurais Artificiais (RNA), MIGHA, EPANET.

1. 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.

O processo 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 companhias de saneamento obtêm dados de demandas em nós da rede através da micromedida das unidades consumidoras. Tais medidas são imprecisas devido a vários fatores tais como falhas de cadastro por parte da companhia, fraudes, ligações clandestinas, consumos faturados estimados, consumos não-faturados não-medidos (incêndios, favelas, etc.), erros de medição provocada por hidrômetros descalibrados ou velhos e, finalmente, por vazamentos ao longo da rede de distribuição.

As técnicas utilizadas para calibração de rugosidades de redes de distribuição têm sido desenvolvidas desde a década de 70 e podem ser divididas em três classes: (1) procedimentos de tentativa e erro através de equações analíticas (WALSKI, 1983; BHAVE, 1988); (2) métodos explícitos ou simulação hidráulica (ORMSBEE e WOOD, 1986a e 1986b; BOULOS e WOOD, 1990) 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, através da resolução analítica do sistema de equações não lineares. Para isso o número de medidas de pressões e/ou vazões deve ser igual ao número 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.

Já se têm disponíveis inúmeras técnicas de calibração, porém, ainda não há uma destacadamente superior às demais. Este trabalho propõe a utilização de Redes Neurais Artificiais (RNA) para calibração do modelo de simulação de redes de abastecimento. Foi estudada a calibração do parâmetro de rugosidade, mas o método descrito é genérico quanto sua formulação, podendo ser incluída a calibração de demandas, diâmetros ou parâmetros de vazamentos.

As RNA foram idealizadas conceitualmente para descrever matematicamente um mecanismo de aprendizado similar ao do cérebro humano. Elas possuem a capacidade de aprender com a experiência e realizar generalizações baseadas no conhecimento prévio do objeto em estudo. As RNA encontraram aplicações nas diversas áreas do conhecimento, sobretudo na engenharia.

O processo de calibração utilizando-se RNA consiste em treinar a rede neural através de uma série de dados sintéticos, obtidos através da variação conhecida dos parâmetros que se deseja calibrar. Uma vez treinada a rede neural, é possível obter os valores dos parâmetros calibrados fornecendo-se os valores medidos de pressão e vazão.

Neste trabalho utilizou-se de técnicas de calibração de parâmetros hidrodinâmicos na determinação das rugosidades das tubulações. O método MIGHA, desenvolvido por S. CHUSTER (2000), é um método iterativo que determina seus parâmetros a partir dos gradientes hidráulicos dos trechos. Tivemos como objetivo comparar os dois métodos expondo seus pontos positivos e negativos, um em relação ao outro.

2. METODOLOGIA

Os métodos apresentados neste trabalho determinam 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 utiliza uma função objetivo que por meio de iterações com o simulador hidráulico EPANET (Rossman, 2000), ajusta continuamente as rugosidades até que a função objetivo atinja um valor mínimo, enquanto a RNA treina a rede e, a partir disso, estima as rugosidades.

Dentre as linguagens de programação disponíveis, para efetuar as modelagens de ambos os métodos, escolheu-se a linguagem DELPHI 7.0 em função de sua facilidade de uso e, principalmente por proporcionar recursos numéricos e gráficos, que oferece 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 devido à 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.

2.1. REDES NEURAIAS ARTIFICIAIS - RNA

Existem dois paradigmas em Inteligência Artificial, o Simbólico e o Conexionista, os quais possuem diferentes maneiras para descrever os sistemas inteligentes e o aprendizado. A abordagem simbólica acredita que a habilidade cognitiva do cérebro baseia-se na manipulação de símbolos e um sistema inteligente seria criado com o entendimento de símbolos e regras explícitas. Já os sistemas conexionistas, dos quais fazem parte as Redes Neurais Artificiais, idealizam que processamentos complexos podem ser reproduzidos utilizando-se um massivo número de unidades de processamento paralelas e interligadas, semelhantemente ao cérebro humano.

2.1.1. Neurônio Artificial

As RNA foram concebidas com o intuito de se obter um mecanismo artificial capaz de simular o sistema de aprendizado do cérebro. Embora se perceba, atualmente, que uma RNA ainda diferencie-se bastante da estrutura biológica que lhe originou, as RNA já possuem inúmeras aplicações em nossa vida cotidiana.

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 neurônios artificiais possuem estruturas muito mais simples que os biológicos.

A Figura 1 apresenta um comparativo entre um neurônio do sistema nervoso e um artificial. Eles são compostos por três partes principais:

- Dendrito / Terminal de entrada;
- Corpo celular / Função de ativação;
- Axônio / Terminal de saída.




Figura 1 – Ilustração comparativa entre o neurônio biológico (esquerda) e o neurônio artificial (direita).

As conexões entre neurônios ocorrem através da sinapse. No neurônio biológico, o estímulo que passa de um neurônio a outro é realizado por neurotransmissores, que são mediadores químicos que tornam possível a passagem da informação (impulso nervoso) entre o axônio de um neurônio aos dendritos receptores de outro. Ainda não se sabe ao certo o mecanismo biológico que gera o aprendizado e a memória, mas acredita-se que a essência destes esteja no aumento da função sináptica ou na criação de novas sinapses.

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

2.1.2. 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.

As primeiras redes neurais artificiais empregavam funções de ativação do tipo “tudo ou nada”, ou degrau. Estas funções são úteis na classificação de padrões de um conjunto de dados. Deste tipo de função, as mais conhecidas são a função *threshold* (Equação 1) e a função *hard limiter* (Equação 2)

$$\varphi(v) = \begin{cases} 1, & \text{se } v_K \geq 0 \\ 0, & \text{se } v_K < 0 \end{cases} \quad v_K = \sum_{j=1}^m w_{kj} x_j + b_k \quad (1)$$

$$\varphi(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (2)$$

Entretanto, posteriormente seria provado que funções diferenciáveis em qualquer ponto apresentariam diversas vantagens sobre as funções degrau. A priori, qualquer função conhecida pode ser utilizada como função de ativação. Dentre as funções diferenciáveis, as mais utilizadas são a função sigmóide, a tangente hiperbólica e a gaussiana. As equações 3, 4 e 5 correspondem, respectivamente, às funções citadas.

$$\varphi(v) = \frac{b}{1 + e^{(-av)}} \quad (3)$$

$$\varphi(v) = a \frac{e^{(bv)} - e^{(-bv)}}{e^{(bv)} + e^{(-bv)}} \quad (4)$$

$$\varphi(v) = ae^{\frac{(v-b)^2}{2c^2}} \quad (5)$$

2.1.3. Tipos de Redes Neurais Artificiais

As RNA's são compostas de interconexões entre neurônios e são classificadas de acordo com sua estrutura. O conjunto dessas características, chamado *arquitetura* da RNA, pode variar de acordo com o número de camadas, a quantidade de neurônios em cada camada e a função de ativação dos neurônios. Quanto à sua arquitetura, as principais classificações para as RNA's são:

i) Rede alimentada adiante de uma camada

É o caso mais simples de redes em camadas. A camada de entrada é formada por nós que alimentam diretamente a única camada da rede. A propagação de sinais nesta rede é unidimensional da entrada para a saída (*feedforward*).

ii) Rede alimentada adiante de múltiplas camadas

As redes neurais são do tipo Perceptron de múltiplas camadas (em inglês *MultiLayer Perceptrons* – MLP), pois possuem uma ou mais camadas intermediárias.

iii) Redes recorrentes

São também chamadas de RNA com memória. Possui retroalimentação, possuindo, pelo menos, um circuito (*loop*) gerando recorrência (*feedback*).

Neste trabalho adota-se uma denotação para descrição rápida da quantidade de neurônios e camadas da rede neural MLP. Por exemplo, uma rede neural com 4 Nós na camada de entrada, 3 Nós em uma camada intermediária e 2 Nós de saída, será representada por: RNA MLP 4x3x2.

As redes MLP vem sendo utilizadas com sucesso em diversos problemas com altos graus de não-linearidade. No presente trabalho foram aplicadas redes do tipo MLP para solução do problema de calibração de modelos de simulação hidráulica.

2.1.4. Treinamento da RNA

A capacidade de aprendizado de uma RNA é sua mais importante característica. A partir de um conjunto de regras pré-estabelecidas, 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 supervisionados, onde padrões de entradas e saídas são fornecidas; ou não supervisionado, onde apenas os padrões de entrada estão disponíveis. As redes MLP utilizam aprendizado supervisionado.

Como apresentado, durante a execução do cálculo pela rede neural são efetuadas diversas somas e produtos entre pesos e sinais, além dos cálculos produzidos pelas funções de ativação. Isto pode fazer com que o resultado numérico computacional afete a estabilidade da RNA. Por isso, recomenda-se a normalização 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 desejado 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 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 avaliação 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) e para o treinamento é utilizado o algoritmo *Backpropagation*. Apesar de simples, este é um dos mais precisos *softwares* para treinamento de RNA que se dispõe (GROWE, 1999).

2.2 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 hidráulicas observadas e calculadas (equação 6).

$$F_{OBJ} = \sum_{i=1}^N (h_i^{obs} - h_i^{calc})^2 \quad (6)$$

O MIGH (Método Iterativo de Gradiente Hidráulico, Guo e Zhang, 1994, Guo e Zhang, 2000) minimiza a iterativo onde se estabelece arbitrariamente um parâmetro inicial ajustado a cada iteração. Tal calibração é um O Método iterativo de gradiente hidráulico alternativo (MIGHA) desenvolvido por Schuster, 2002, abandona a calibração tradicional dos mínimos quadrados.

O método iterativo de gradiente hidráulico alternativo MIGHA é um método inverso indireto eficaz, rápido e prático porque minimiza os residuais dos gradientes hidráulicos dos trechos das redes de distribuição acarretando também uma minimização de suas respectivas cargas hidráulicas sendo, portanto, uma importante ferramenta na calibração de parâmetros hidráulicos.

Aplicado neste trabalho à estimativa do parâmetro rugosidade das tubulações, o MIGHA corrige a cada iteração o coeficiente de rugosidade do trecho pela expressão:

$$C_j^{i+1} = C_j^i \cdot \frac{|\nabla h_j^{i \text{ calc}}|}{|\nabla h_j^{i \text{ obs}}|} \quad (7)$$

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 $i+1$, $|\nabla h_j^{i \text{ calc}}|$ é o gradiente hidráulico calculado na iteração i do trecho j e $|\nabla h_j^{i \text{ obs}}|$ é o gradiente hidráulico observado na iteração i do trecho j .

Como critério de convergência, calculamos em cada iteração o ângulo φ formado entre vetores do gradiente hidráulico observado e calculado no espaço unidimensional o qual é dado por:

$$\cos \varphi_j = \frac{\nabla h_j^{\text{obs}} \cdot \nabla h_j^{\text{calc}}}{|\nabla h_j^{\text{obs}}| |\nabla h_j^{\text{calc}}|} \quad (8)$$

Pela fórmula descrita acima, 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 que 60° calcula-se C_j^{i+1} pela equação 7, senão repete-se o valor anterior, ou seja:

$$\begin{cases} \text{Se } \varphi < 60^\circ \Rightarrow C_j^{i+1} = C_j^i \cdot \frac{|\nabla h_j^{i \text{ calc}}|}{|\nabla h_j^{i \text{ obs}}|} \\ \text{Se } \varphi \geq 60^\circ \Rightarrow C_j^{i+1} = C_j^i \end{cases} \quad (9)$$

Nesse 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.

Para este trabalho, definem-se três tipos de redes hidráulicas que serão utilizadas:

Rede Gabarito: É a rede onde se conhecem todos os valores de rugosidades e, a partir destes valores, obtêm-se, no simulador, as pressões e vazões as quais a rede está submetida. Esta rede equivale à rede instalada no campo.

Rede Observada: Obtida a partir da rede gabarito, é a rede que apresenta apenas alguns nós medidos, nos quais se conhece a carga hidráulica. Nessa rede é atribuído um conjunto de valores iniciais de rugosidades para que se possam obter valores de gradientes hidráulicos que serão considerados “gradientes hidráulicos observados”. A rede observada pode coincidir com a rede gabarito se em todos os nós forem medidas as pressões, nesse caso, as rugosidades desta rede serão iguais às da rede gabarito. Quanto menor o número de nós medidos, mais essa rede se afasta da rede gabarito em termos de rugosidades.

Rede Calculada: É a rede onde também é atribuído um conjunto de valores iniciais de rugosidades (o mesmo da rede observada), mas que não apresenta nenhum valor de pressão medido. O simulador calculará seus gradientes que serão considerados “gradientes hidráulicos calculados”.

O processo de calibração pelo MIGHA visa tornar os gradientes hidráulicos calculados o mais próximo possível dos gradientes hidráulicos observados.

O número de pontos medidos é de fundamental importância no processo. Na situação em que todos os pontos são medidos, a rede observada equivale à rede gabarito, que é a rede instalada no campo, quanto aos valores de carga hidráulica.

Na prática, geralmente há poucos pontos medidos em uma grande rede, significa dizer que os gradientes hidráulicos encontrados na rede observada poderão estar distantes dos gradientes hidráulicos reais da rede gabarito em alguns trechos.

Do exposto, percebe-se que para a calibração ser bem sucedida é necessário que se meça a pressão do maior número de nós possível porque, neste caso, a rede calibrada (calculada) ao se aproximar da rede observada, também estará se aproximando da rede gabarito.

O processo de calibração pelo MIGHA ocorre de forma simples e direta quando se conhecem as pressões em todos os pontos. A rede observada corresponde ao próprio gabarito (rede gabarito) conhecendo-se todos os gradientes hidráulicos observados.

Quando se elabora a rede observada, adota-se um conjunto inicial de valores de rugosidades, o simulador hidráulico então retorna valores de pressão, mas, quando há apenas algumas pressões medidas, precisa-se embuti-las no cálculo, ou seja, garantir que o EPANET retorne esses valores de pressão através do mesmo conjunto inicial de rugosidades.

Para resolver tal problema, este trabalho propõe uma solução: ligam-se reservatórios de nível fixo àqueles nós onde a pressão é conhecida (medida). No campo “Nível de água” do reservatório é atribuído o valor correspondente ao da pressão medida (observada). O trecho que interliga o nó ao reservatório deve ser bem pequeno e de grande diâmetro para garantir: i) que não haja perda de carga entre os dois e a carga hidráulica do nó seja equivalente à do reservatório e, ii) que a vazão entre o nó e o reservatório seja próxima de zero, já que não deve haver vazão entre eles pois não se trata de um reservatório pertencente ao sistema, e sim, de uma adaptação usada apenas no simulador hidráulico.

Esses reservatórios serão considerados “fictícios” uma vez que não existem realmente, trata-se apenas de uma solução prática encontrada para a fixação das pressões medidas na rede observada.

Nesta análise comparativa, utilizamos medições de pressão em todos os nós da rede.

2.3 REDE EXEMPLO

Objetivando avaliar a eficiência dos modelos de calibração propostos, foi analisado uma rede de distribuição hipotética criada por WALSKI (1983b) e adaptada por GAMBALE(2000) ilustrada na figura 2.




Figura 2: Rede Hipotética

Todas as variáveis, como: demandas nodais, topografia do terreno, nível do reservatório, diâmetro, comprimento e rugosidade das tubulações; são conhecidas. O nível de água do reservatório de nível fixo estará na 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 1 a seguir:

Tabela 1: Características físicas da rede hipotética

TUBO	DIÂMETRO (mm)	COMPRIMENTO (m)	RUGOSIDADE $C (m^{0,3698}/s)$
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

Considerando que o exemplo é hipotético, os dados de pressão observada não serão adquiridos em observações em campo, e sim pela simulação da rede através do EPANET 2.0 cujos valores de pressão calculados serão considerados 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, respectivamente, nas tabelas 2 e 3 a seguir.

Tabela 2: Características dos nós, Cenário 1

NÓ	DEMANDA (L/s)	PRESSÃO OBSERVADA (mca)
2	0,0	58,74
3	15,0	55,75
4	62,5	56,08
5	15,0	53,77
6	47,5	53,35
7	30,0	54,27
8	37,5	53,03

Tabela 3: Características dos nós, Cenário 2

NÓ	DEMANDA (L/s)	PRESSÃO OBSERVADA (mca)
2	0,0	56,44
3	36,0	48,37
4	120,0	48,72
5	10,0	47,03
6	80,0	41,80
7	80,0	44,12
8	37,5	42,88

3. ANALISE COMPARATIVA

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;

Adotou-se a RNA sig5000 7x14x14x14x10 para comparação de resultados. Foi realizado também o treinamento com esta RNA para o cenário 2 de demandas e os resultados comparados com aqueles obtidos pelo MIGHA.

Os valores de coeficiente de rugosidade estimados com a RNA (segundo o critério adotado) e com o MIGHA estão apresentados na Tabela 4 e gráfico 1.

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

Tabela 4: Resultados obtidos para valores de rugosidades pelos dois métodos

TUBO	RUGOSIDADE REAL $C (m^{0,3698}/s)$	RUGOSIDADE CALCULADA RNA	RUGOSIDADE CALCULADA MIGHA	DIFERENÇAS RNA	Erro- RNA (%)	DIFERENÇAS MIGHA	Erro- MIGHA (%)
1	140	138.45	139.91	1.55	1.11%	0.09	0.06%
2	110	112.24	110.46	2.24	2.04%	0.46	0.42%
3	130	129.52	128.78	0.48	0.37%	1.22	0.94%
4	135	134.64	136.8	0.36	0.27%	1.8	1.33%
5	90	89.65	89.94	0.35	0.39%	0.06	0.07%
6	110	103.94	122.33	6.06	5.51%	12.33	11.21%
7	120	121.52	115.11	1.52	1.27%	4.89	4.08%
8	115	111.45	122.85	3.55	3.09%	7.85	6.83%
9	85	86.11	87.84	1.11	1.31%	2.84	3.34%
10	80	113.32	138.07	33.32	41.65%	58.07	72.59%
SOMATÓRIO				63.74		89.61	

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




Gráfico 1: Resultados obtidos para valores de rugosidades pelos dois métodos

Em todos os trechos verificou-se que o sistema está calibrado segundo os critérios definidos pelo WATER RESEARCH CENTRE. No entanto, os coeficientes de Hazen-Willians calibrados para os tubos 6, 8 e 10 apresentam um desvio padrão elevado nos dois métodos, entretanto, tais desvios foram menos acentuados na RNA.

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.

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

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

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




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

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

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

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

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




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

Percebe-se que nos tubos em que o erro entre a rugosidade calculada e a observada foi maior no MIGHA, tais erros ocorreram com desvios padrões mais elevados, entretanto, em seis tubos os resultados foram bastante semelhantes, ocorrendo melhores resultados pelo MIGHA em três tubos, 1, 2 e 5.

Apesar do somatório dos erros entre as rugosidades calculadas e observadas nos dois métodos ter sido, em geral superior 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 em cada um dos nós. Tal resultado demonstra que a pressão não é uma variável determinante para a calibração uma vez que mesmo a RNA apresentando diferenças entre as pressões (observadas e calculadas) retornou rugosidades menos distantes das reais.

Desta forma, podemos concluir que para uma rede malhada existem várias configurações de rugosidades possíveis que resultam em conjunto de pressões bem próximas. A função objetivo (equação 1) contém inúmeros pontos ótimos locais, podendo assumir valores nulos e não conter as rugosidades reais da rede.

Os trechos em que as rugosidades calculadas se distanciaram das reais podem ser considerados como candidatos a instalação de medidores de vazão. Uma vez conhecidas as vazões destes trechos, suas rugosidades se manteriam 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 (sintéticas), sendo que a calibração pelo MIGHA apresentou diferenças de pressões ainda menores que a calibração com a RNA, entretanto, pode-se afirmar, com segurança, que ambas as técnicas apresentam resultados satisfatórios que estão dentro dos limites estabelecidos pela Water Research Centre.

No que diz respeito aos resultados de coeficientes de rugosidades, observa-se que a RNA opera coeficientes mais próximos dos reais relativamente ao MIGHA; esta, aliás, é uma característica do MIGHA, apresentar 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 que foi observado consiste na dificuldade de previsões dos coeficientes de rugosidade em trechos com vazões relativamente menores 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 apresentado, os trechos com este problema possuíam diâmetros menores que os demais do circuito hidráulico, o que, conseqüentemente, fez com que estes apresentassem 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 apresentada pela RNA consiste na previsão desses trechos que apresentam maior dificuldade na calibração da rugosidade. Acredita-se, como aconteceu na comparação realizada, que esta dificuldade ocorre independente 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.

Recomenda-se a implementação de um método que durante o processo de 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.

Uma vantagem dos softwares desenvolvidos é que todo o procedimento de calibração da rede é realizado em uma única etapa, proporcionando maior acessibilidade a estudiosos, e tornando desnecessária a utilização de softwares de otimização.

Uma desvantagem do MIGHA em relação à RNA é a necessidade do maior número possível de medições de pressão, o que não ocorre, na prática, em uma rede instalada em campo.

Outro parâmetro importante diz respeito ao tempo de processamento. Enquanto o MIGHA gastou 23 segundos no processamento, os longos tempos computacionais demandados nos treinamentos da RNA não foram tão problemáticos no caso da rede hipotética estudada. Mas no caso de redes reais, com dezenas de parâmetros a calibrar, deve-se analisar esta característica com maior cuidado. Vale ressaltar, ainda, que no processo de calibração não é necessária 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 e calibrou-se apenas o parâmetro de rugosidade das tubulações. Porém, a priori, tanto o MIGHA, quanto a RNA podem ser utilizados para calibração de qualquer parâmetro, inclusive de vazamentos, bastando para isso que os dados sejam fornecidos adequadamente.

REFERÊNCIAS BIBLIOGRÁFICAS

1. BHAVE, P. R. Calibrating water distribution network models. *Journal of Hydraulic Engineering*, v. 114, n. 1, p. 120-136, Feb, 1988.
2. BOULOS, P. F.; WOOD, D. J. Explicit calculation of pipe-network parameters. *Journal of Hydraulic Engineering*, v.116, n.11, p.1329-1344, Nov, 1990.
3. GAMBALE, S. R. Aplicação de algoritmo genético na calibração de rede de água. São Paulo. 266p. Dissertação (Mestrado em Recursos Hídricos) – Escola politécnica da Universidade de São Paulo, São Paulo, 2000.
4. GROWE, G. A. Comparing Algorithms and Clustering Data: Components of the Data Mining Process. Dissertação de Mestrado. Grand Valley State University, Michigan, 1999.
5. GUO, X.; C-M. ZHANG. (1994). Use of the physical feature of groundwater system to reduce the mathematic complexity in parameter identification – a practical and efficient automated procedure. In: *Proceedings of the 1994 Groundwater Modeling Conference*, Fort Collins, Colorado, 111-118.
6. GUO, X.; C-M. ZHANG. (2000). Hydraulic gradient comparison method to estimate aquifer hydraulic parameters under steady-state conditions. *Ground Water* 38, n. 6: 815-826.
7. ORMSBEE, L.E.; WOOD, D. J. Explicit pipe network calibration. *Journal of water Resources Planning and Management*, v.112, n.2, p.166-182, apr, 1986.
8. ROSSMAN, L. A. EPANET 2 Users manual. U. S. Environmental Protection Agency, Cincinnati, Ohio, 2000.
9. SCHUSTER, H.D.M. 2002. 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, no 4: 451-460.
10. SILVA, A. C. A. Calibração automática de rugosidades de tubulações em sistemas de distribuição de água com aplicação de algoritmos genéticos. 175 p. Dissertação (Mestrado). Universidade Federal do Ceará, 2006.
11. WALSKI, T. M. Technique for calibration network models. *Journal of water Resources Planning and Management*, v.109, n.4, p.360-372, oct, 1983a.
12. WATER RESEARCH CENTRE. Network Analysis – A code for practice. Published by WRC, Swindon, UK, 1989.