

NARUMI ABE

**Proposição de Calibração de Redes de Sistemas de Abastecimento
de Água Através de Método Híbrido**

VERSÃO CORRIGIDA

São Carlos, SP

2014

NARUMI ABE

**Proposição de Calibração de Redes de Sistemas de Abastecimento de
Água Através de Método Híbrido**

Tese apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutor em Ciências: Engenharia Hidráulica e Saneamento

Orientadora: Prof^a. Dra. Luisa Fernanda Ribeiro Reis

VERSÃO CORRIGIDA

São Carlos, SP

2014

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento da Informação do Serviço de Biblioteca – EESC/USP

Abe, Narumi

A138p

Proposição de calibração de redes de sistemas de abastecimento de água através de método híbrido.

Narumi Abe; orientadora: Luisa Fernanda Ribeiro Reis. São Carlos, 2014.

Tese (Doutorado) - Programa de Pós-Graduação e Área de Concentração em Hidráulica e Saneamento - Escola de Engenharia de São Carlos da Universidade de São Paulo, 2014.

1. Modelos hidráulicos. 2. Redes Neurais Artificiais. 3. Algoritmos genéticos. 4. Calibração.
I. Título.

FOLHA DE JULGAMENTO

Candidato: Bacharel **NARUMI ABE.**

Título da tese: "Proposição de calibração de redes de sistemas de abastecimento de água através de redes neurais e artificiais".

Data da defesa: 30/05/2014

Comissão Julgadora:

Profa. Titular **Luisa Fernanda Ribeiro Reis (Orientadora)**
(Escola de Engenharia de São Carlos/EESC)

Prof. Associado **Rodrigo de Melo Porto**
(Escola de Engenharia de São Carlos/EESC)

Prof. Dr. **Erich Kellner**
(Universidade Federal de São Carlos/UFSCar)

Prof. Dr. **Edevar Luvizotto Junior**
(Universidade Estadual de Campinas/UNICAMP)

Prof. Dr. **Peter Batista Cheung**
(Universidade Federal de Mato Grosso do Sul/UFMS)

Resultado:

Aprovado

Aprovado

APROVADO

aprovado

APROVADO

Coordenadora do Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento:

Profa. Associada **Maria Bernadete A. Varesche Silva**

Presidente da Comissão de Pós-Graduação:

Prof. Titular **Denis Vinicius Coury**

Agradecimentos

À Profa. Fernanda, pelas grande paciência e orientações.

Ao DAAE Araraquara, por toda prestatividade dos engenheiros e técnicos.

Ao CNPq e CAPES, pela bolsa de estudos.

Ao pessoal do Departamento de Hidráulica e Saneamento.

Aos amigos do LabSiN.

Resumo

ABE, N. (2014). *Proposição de Calibração de Redes de Sistemas de Abastecimento de Água Através de Método Híbrido*. São Carlos, 2014. 165p. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2014.

A popularização das tecnologias de monitoramento remoto possibilita e cria a necessidade do desenvolvimento de sistemas de calibração mais velozes, capazes de calibrar redes enquanto recebem dados, ou seja, em tempo real. Este trabalho consistiu na proposição de dois novos métodos de calibração baseados em redes neurais artificiais construtivas, visando a aumentar a velocidade de processamento e a performance dos sistemas de calibração. O primeiro método consistiu em calibrar utilizando somente redes neurais artificiais. Um sistema foi desenvolvido para recorrentemente produzir respostas de modelos hidráulicos baseados no Epanet e transformá-los em padrões de treinamento para as RNA (redes neurais artificiais) construtivas. O segundo método consistiu no desenvolvimento de um sistema de calibração híbrido, utilizando as saídas da RNA do primeiro método para produzir valores para constituir a população inicial de soluções a serem buscadas usando os algoritmos genéticos (AG). Assim, pode-se considerar que o método híbrido proposto foi desenvolvido para produzir soluções a partir de boas aproximações para os valores ótimos. Os métodos propostos foram aplicados a quatro (4) setores de rede da cidade de Araraquara, SP. Os resultados das calibrações foram avaliados através da comparação das simulações e com os respectivos valores observados em campo, considerando critérios recomendados no Reino Unido. O primeiro método proposto mostrou-se pouco eficiente no processo de calibração, sendo útil, entretanto, como a primeira etapa da calibração através do método híbrido. O segundo método superou ligeiramente a performance obtida na qualidade da calibração dos dados de cargas de pressões e vazões comparadas com métodos de calibração clássicos e foi bastante superior no quesito velocidade.

Palavras-chave: calibração, redes neurais artificiais, algoritmos genéticos, EPANET

Abstract

ABE, N. (2014). *A proposition for calibrating water distribution systems models using hybrid method*. São Carlos, 2014. 165p. Thesis (Doctorate) – School of Engineer of São Carlos, University of São Paulo, São Carlos.

The popularization of remote monitoring technologies allows and creates the need to develop faster calibration systems capable of calibrating networks while receiving data, i.e. , in real time. This work consisted in proposing two new calibration methods based on constructive neural networks, aiming to increase the processing speed and performance of calibration systems. The first method was to calibrate using only artificial neural networks. A system was developed to produce responses of hydraulic models based on Epanet and turn them into training patterns for the constructive ANN (artificial neural networks) recurrently. The second method consisted in developing a hybrid calibration system using the outputs of the first method of RNA to produce values for the initial population of solutions to be searched using the genetic algorithms (GA). Thus, it can be considered that the hybrid method was developed to produce solutions from good approximations for the optimal values. The proposed methods were applied to four sectors of the city of Araraquara , SP. The results of the calibrations were evaluated by comparing the simulations and the respective values observed in the field, considering criteria recommended in the UK. The first proposed method proved inefficient in the calibration process, it is useful, however, as the first step of the calibration using the hybrid method. The second method was slightly better in performance obtained in the quality of the calibration data of pressures and flow rates compared with classical methods of calibration and it was quite superior in speed.

Keywords: calibration, neural networks, genetic algorithms, EPANET

LISTA DE FIGURAS

Figura 1	Resultado da calibração de dois nós através da alteração dos padrões de demanda	32
Figura 2	Efeito do expoente de vazamento na taxa de vazamentos	40
Figura 3	Exemplo de rede neural tradicional com duas camadas ocultas	49
Figura 4	Arquitetura do modelo DAN2	54
Figura 5	Etapas do novo sistema da calibração proposto	54
Figura 6	Plantas hidráulicas dos setores de abastecimento de Araraquara	56
Figura 7	Nós com coordenadas coincidentes, no caso, $n_2(x_2, y_2, z_2) = n_3(x_3, y_2, z_3)$	58
Figura 8	União de trechos com nós duplicados	58
Figura 9	Conversão de quebras de <i>polylines</i> em nós	59
Figura 10	Remoção de nós extras	60
Figura 11	Nó candidato rejeitado para remoção	60
Figura 12	Verificação do ângulo do nó candidato	60
Figura 13	Vazões obtidas através de telemetria no período de 18/03/2013 a 25/03/2013 na entrada do setor Iguatemi ZA. Não há medições no dia 21/03.	63
Figura 14	Vazões obtidas através de telemetria no período de 18/02/2013 a 25/02/2013 na entrada do setor Iguatemi ZB.	64
Figura 15	Vazões obtidas através de telemetria no período de 04/03/2013 a 11/03/2013 na entrada do setor Eliana.	64
Figura 16	Vazões obtidas através de telemetria no período de 25/02/2013 a 04/03/2013 na entrada do setor Martinez.	65
Figura 17	Gráfico adimensional do consumo semanal	66
Figura 18	Intervalos de confiança para as vazões no setor Iguatemi ZA,	67

	com 95% de confiança.	
Figura 19	Intervalos de confiança para as vazões no setor Iguatemi ZB, com 95% de confiança.	68
Figura 20	Intervalos de confiança para as vazões no setor Eliana, com 95% de confiança	68
Figura 21	Intervalos de confiança para as vazões no setor Martinez com 95% de confiança	69
Figura 22	Rede exemplo	71
Figura 23	Tela do <i>software</i> de amostragem	73
Figura 24	Pontos de amostragem do setor Iguatemi Zona Alta	74
Figura 25	Pontos de amostragem do setor Iguatemi Zona Baixa	75
Figura 26	Pontos de amostragem do setor Eliana	76
Figura 27	Pontos de amostragem do setor Martinez	77
Figura 28	Sensores de carga de pressão instalados nos cavaletes	78
Figura 29	Exemplo de carga de pressão obtida	79
Figura 30	Representação planialtimétrica do setor Iguatemi ZA	80
Figura 31	Representação planialtimétrica do setor Iguatemi ZB	80
Figura 32	Representação planialtimétrica do setor Eliana	81
Figura 33	Representação planialtimétrica do setor Martinez	81
Figura 34	Exemplos de correções nos valores dos dados	82
Figura 35	Arquitetura do modelo DAN2	89
Figura 36	Evolução do erro para a rede neural AMGA	93
Figura 37	Previsão do consumo para a série completa	94
Figura 38	Previsão para período arbitrário de 7 dias	95
Figura 39	Gerando padrões de treinamento	97
Figura 40	Exemplo de estratificação de função distribuição acumulada em cinco intervalos	100

Figura 41	Esquema de geração de padrões: g : quantidade de grupos gerados; n_i : coeficiente de rugosidade para o i -ésimo grupo; C_i : coeficiente de vazamento para o i -ésimo grupo; α : expoente de vazamento; m_i : coeficiente de perda localizada.	101
Figura 42	Função densidade de probabilidade da não ocorrência de erros de simulação para a variável Perda de Carga.	102
Figura 43	Gráfico comparativo entre o ajuste da probabilidade de ocorrência e os dados obtidos.	103
Figura 44	Função de Probabilidade Acumulada para valores de Perda de Carga com não ocorrência de erros na simulação.	104
Figura 45	Função densidade de probabilidade para o parâmetro coeficiente de rugosidade	105
Figura 46	Função densidade de probabilidade para o parâmetro coeficiente de vazamento.	105
Figura 47	Função densidade acumulada para o parâmetro coeficiente de vazamento.	106
Figura 48	Dados de entradas e saídas para o treinamento das RNAs.	107
Figura 49	Representação do uso das RNA para a calibração	108
Figura 50	Fluxograma da calibração através de A.G.	111
Figura 51	Esquema de funcionamento do método de calibração híbrido	112
Figura 52	Evolução do erro quadrado médio ao longo das iterações para o setor Iguatemi ZA	114
Figura 53	Regressão entre os padrões de treinamento e os resultados obtidos pela RNA (Iguatemi ZA)	114
Figura 54	Evolução do erro quadrado médio ao longo das iterações para o setor Iguatemi ZB.	115
Figura 55	Regressão entre os padrões de treinamento e os resultados obtidos pela RNA (Iguatemi ZB)	116
Figura 56	Evolução do erro quadrado médio ao longo das iterações para o	116

setor Eliana

Figura 57	Regressão entre os padrões de treinamento e os resultados obtidos pela RNA (Eliana)	117
Figura 58	Evolução do erro quadrado médio ao longo das iterações para o setor Martinez	118
Figura 59	Regressão entre os padrões de treinamento e os resultados obtidos pela RNA (Martinez)	118
Figura 60	Convergência da calibração – Iguatemi ZA	127
Figura 61	Iguatemi ZA – Calibração do Nó 48	128
Figura 62	Iguatemi ZA – Calibração do Nó 101	128
Figura 63	Iguatemi ZA – Calibração do Nó 109	129
Figura 64	Iguatemi ZA – Calibração do Nó 122	129
Figura 65	Iguatemi ZA – Calibração do Nó 264	130
Figura 66	Iguatemi ZA – Calibração do Nó 276	130
Figura 67	Iguatemi ZA – Calibração do Nó 398	131
Figura 68	Iguatemi ZA – Calibração do Trecho 5	131
Figura 69	Gráfico de regressão multivariada do setor Iguatemi ZA	132
Figura 70	Convergência da calibração – Iguatemi ZB	133
Figura 71	Iguatemi ZB – Calibração do Nó n35f	134
Figura 72	Iguatemi ZB – Calibração do Nó n37h	135
Figura 73	Iguatemi ZB – Calibração do Nó n57d	135
Figura 74	Iguatemi ZB – Calibração do Nó n192	136
Figura 75	Iguatemi ZB – Calibração do Nó n226	136
Figura 76	Iguatemi ZB – Calibração do Nó n587	137
Figura 77	Iguatemi ZB – Calibração do Nó n587	137
Figura 78	Iguatemi ZB – Calibração do Trecho 5	138

Figura 79	Gráfico de regressão multivariada do setor Iguatemi ZB	139
Figura 80	Convergência da calibração Eliana	140
Figura 81	Eliana – Calibração do Nó n113	141
Figura 82	Eliana – Calibração do Nó n60	142
Figura 83	Eliana – Calibração do Nó n103	142
Figura 84	Eliana – Calibração do Nó n37	143
Figura 85	Eliana – Calibração do Nó n92	143
Figura 86	Eliana – Calibração do Nó n155	144
Figura 87	Eliana – Calibração do Nó n89	144
Figura 88	Eliana – Calibração do Nó n2n	145
Figura 89	Eliana – Calibração do Trecho 4	145
Figura 90	Gráfico de regressão multivariada do setor Eliana	146
Figura 91	Convergência da calibração Eliana	147
Figura 92	Calibração do Martinez – Nó n45	148
Figura 93	Martinez – Calibração do Nó n83h	149
Figura 94	Martinez – Calibração do Nó n296	149
Figura 95	Martinez – Calibração do Nó n102	150
Figura 96	Martinez – Calibração do Nó n203	150
Figura 97	Martinez – Calibração do Nó n523	151
Figura 98	Martinez – Calibração do Nó n405	151
Figura 99	Martinez – Calibração do Trecho 3	152
Figura 100	Martinez – detalhe da variação de consumo do Trecho 3	153
Figura 101	Gráfico de regressão multivariada do setor Martinez	154

LISTA DE TABELAS

Tabela 1	Relação entre o diâmetro e a vazão mínima para diferentes classes de hidrômetros.	36
Tabela 2	Alguns valores de expoentes encontrados em tubulações de diferentes materiais	40
Tabela 3	Exemplos de coeficientes de perda localizada teóricos	43
Tabela 4	Quantidade de sensores sugeridos pelo Reino Unido	45
Tabela 5	Quantidade de sensores sugeridos pelos EUA	46
Tabela 6	Comparação entre os valores das redes originais e as redes corrigidas	61
Tabela 7	Subtração entre o número de elementos da rede original e da rede corrigida	62
Tabela 8	Proporções de consumo de acordo com os dias da semana.	66
Tabela 9	Matriz de sensibilidade exemplo	72
Tabela 10	Correções consideradas no setor Iguatemi ZA	82
Tabela 11	Correções consideradas no setor Iguatemi ZB	83
Tabela 12	Correções consideradas no setor Eliana	83
Tabela 13	Correções consideradas no setor Martinez	84
Tabela 14	Evolução do Erro em função do número de camadas para a rede neural DAN2	93
Tabela 15	Erro para a previsão das RNAs	94
Tabela 16	Variáveis utilizadas para geração do padrão de treinamento.	98
Tabela 17	Saídas obtidas para o setor Iguatemi Zona Alta	119
Tabela 18	Saídas obtidas para o setor Iguatemi Zona Baixa	120
Tabela 19	Saídas obtidas para o setor Eliana	121

Tabela 20	Saídas obtidas para o setor Iguatemi Martinez	122
Tabela 21	Parâmetros calibrados para o setor Iguatemi ZA.	123
Tabela 22	Parâmetros calibrados para o setor Iguatemi ZB.	124
Tabela 23	Parâmetros calibrados para o setor Eliana.	124
Tabela 24	Parâmetros calibrados para o setor Martinez	125
Tabela 25	Resultado da calibração dos setores com diferentes métodos	126
Tabela 26	Matriz de correlação esparsa para o setor Iguatemi ZA	133
Tabela 27	Matriz de correlação esparsa para o setor Iguatemi ZB	139
Tabela 28	Matriz de correlação esparsa para o setor Eliana	145
Tabela 29	Matriz de correlação esparsa para o setor Martinez	154

LISTA DE SÍMBOLOS

Siglas

AG	Algoritmos genéticos
AMGA	<i>Adaptive Merging and Growing Algorithm</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
CAKE	<i>Current accumulated knowledge element</i>
CDF	<i>Cumulative Density Function</i>
CURNOLE	<i>Current residual nonlinear element</i>
DAAE	Departamento Autônomo de Água e Esgotos
DAN2	<i>Dynamic Architecture for Artificial Neural Networks</i>
DLL	<i>Dynamic Link Library</i>
EPA	<i>Environmental Protection Agency</i>
FFBP	<i>Feed-forward back-propagation</i>
FO	Função Objetivo
FOSM	Primeira Ordem Segundo Momento
GIS	<i>Geographic Information System</i>
LHS	<i>Latin Hypercube Sampling</i>
LM	Levenberg-Marquadt
MAD	Desvio médio absoluto (<i>Mean Absolute Deviation</i>)
min.	Minimização
MCMC	<i>Markov Chain Monte Carlo</i>
MCS	<i>Monte Carlo Sampling</i>
MSE	Erro Médio Quadrado (<i>Mean Square Error</i>)
MTI	Método Transiente Inverso
OOP	<i>Object-Oriented Pascal</i>

PDF	<i>Probability Density Function</i>
PVC	Policloreto de Polivinila
RNA	Redes Neurais Artificiais
SCADA	<i>Supervisory Control and Data Acquisition</i>
SCEM-UA	<i>Shuffled Complex Evolution Metropolis Algorithm</i>
SDA	Sistema de Distribuição de Água
SDP	Sistemas Dirigidos pela Pressão
ZA	Zona Alta
ZB	Zona Baixa

Variáveis

A	Área (m ²)
$Cov(C)$	Matriz de covariância da matriz C
D	Diâmetro da tubulação [mm]
g	Aceleração da gravidade [m/s/s]
H	Carga de pressão [m.c.a.]
i	Índice de uso geral
j	Índice de uso geral
K	Coeficiente de perda de carga localizada
N_l	Números de trechos na rede
N_n	Números de nós nas redes
n	Variável que indica alguma quantidade de acordo com o contexto da equação
Q	Vazão [L/s]
q	Vazão oriunda de vazamentos [L/s]

T	Tempo [h]
V	Velocidade do fluido [m/s]
w_h	fator de carga de pressão
w_f	fator de vazão
Z	Conjunto de variáveis de decisão
β	Expoente de perda do modelo de vazamento
θ	Coefficiente de perda de vazamentos
$[\]^T$	Transposição de matriz

SUMÁRIO

1 Introdução	21
1.1 Objetivos gerais	23
1.2 Objetivos específicos	23
2 Revisao da Literatura	25
2.1 Modelos hidráulicos de simulação de rede.....	25
2.1.1 Modelagem utilizando Epanet	27
2.2 Calibração de modelos hidráulicos	28
2.2.1 Calibração para estimar parâmetros de vazamentos	33
2.2.2 Criação de zonas homogêneas	32
2.3 Incertezas na Modelagem	34
2.3.1 Demandas	35
2.3.2 Coeficientes de rugosidades e diâmetros incertos	37
2.3.3 Erros de medição	38
2.3.4 Vazamentos	39
2.3.5 Perdas de carga localizadas	42
2.4 Planos de amostragem para modelos de calibração	43
2.4.1 Campanhas de campo	44
2.4.2 Avaliação da densidade	45
2.4.3 Procedimentos existentes para determinação do plano de amostragem	46
2.5 Redes Neurais Artificiais	48
2.5.1 Arquiteturas Dinâmicas de Redes Neurais	49
3 Materiais e Métodos	54
3.1 Modelagem das redes de abastecimento	55

3.1.2 Alocação e redução da incerteza nas demandas	62
3.2 Determinação de pontos de monitoramento (rede de amostragem)	69
3.3 Aquisição de dados	77
3.3.1 Correção dos dados de campo	79
3.4 Definição das arquiteturas das RNAs	84
3.4.1 <i>Adaptive merging and growing algorithm</i> (AMGA)	85
3.4.2 <i>Dynamic Architecture for Artificial Neural Networks</i> (DAN2)	88
3.5 Criação dos padrões de treinamento	95
3.5.1 Divisão do setor em zonas homogêneas	96
3.5.2 Software gerador de padrões	105
3.6 Descrição dos métodos de calibração	106
4 Resultados e Discussão	122
4.1 Calibração via redes neurais	106
4.2 Calibração via algoritmos genéticos	122
4.3 Calibração híbrida (RNA + AG)	125
5 Conclusões	155

1 INTRODUÇÃO

O uso de modelos matemáticos tem se tornado comum no setor de abastecimento de água. Através de simulações computacionais é possível prever o comportamento hidráulico e da qualidade da água em redes de abastecimento, produzindo respostas a cenários diversos. No entanto, para que os modelos sejam úteis, é necessário que representem a realidade com um nível de exatidão aceitável ao objetivo para o qual serão utilizados. Portanto, a calibração de modelos é uma tarefa necessária.

Técnicas de calibração têm sido desenvolvidas com o objetivo de minimizar os desvios entre os valores de vazões e cargas de pressão produzidos através da simulação e os respectivos valores observados em campo. A minimização do erro é feita ajustando parâmetros físicos incertos do modelo, como por exemplo, os coeficientes de rugosidades das tubulações.

A calibração feita de forma manual é uma atividade extremamente morosa e pouco precisa, pois exige diversos ciclos de tentativa e erro. Para redes com muitos trechos de tubulações, a calibração manual só é possível mediante simplificações do sistema físico real, as quais, por sua vez podem ocasionar perdas significativas na fidelidade do modelo.

A calibração automática envolve um processo semelhante ao da calibração manual. Apesar de extremamente rápida em relação à calibração manual, a calibração automática é desprovida de “senso crítico”. Assim, devido à existência de inúmeras incertezas relativas aos parâmetros de um modelo, esse ajuste pode levar a resultados não realísticos, pois um erro na calibração de uma variável pode ser compensado pelo ajuste de outras variáveis.

A inclusão de instruções condicionais nos algoritmos de otimização utilizados com o propósito da calibração automática pode ajudar a evitar erros grosseiros. No entanto, ocasionam incremento significativo no tempo de processamento computacional, que pode não ser vantajoso em redes relativamente grandes.

Estudos têm demonstrado que os melhores resultados para calibração são obtidos através da técnica dos algoritmos genéticos (AG), entretanto a busca por variáveis ótimas através desta técnica ainda exige um custo de processamento e tempo computacionais elevados. O tempo despendido na calibração não era considerado um fator crucial, pois mesmo se a calibração fosse realizada em horas ou alguns dias, acreditava-se que os modelos

calibrados poderiam ser utilizados por longos períodos de tempo. No entanto, estudos recentes têm demonstrado que modelos calibrados constantemente produzem resultados mais próximos dos reais. Aliado a isso, a popularização dos sistemas de aquisição de dados em tempo real em empresas de saneamento permitiu e criou a necessidade do desenvolvimento de softwares de calibração cada vez mais rápidos.

As redes neurais artificiais (RNA) são modelos multivariados multiregressivos com capacidade de aprendizado com elementos simplificados análogos as estruturas de redes neurais naturais. As RNA têm sido utilizadas para uma vasta gama de finalidades pela qualidade dos resultados obtidos e pela grande velocidade de processamento, já que uma vez treinadas, as redes neurais resolvem funções extremamente simples. Porém, a revisão da literatura mostrou que as redes neurais artificiais mais utilizadas atualmente possuem como limitação a falta de critérios objetivos para que funcionem de modo ótimo, sendo necessário a execução de testes empíricos trabalhosos por parte do modelador. Atualmente uma nova categoria de redes neurais tem sido desenvolvida para resolver esta limitação, capazes de encontrar a arquitetura ótima de forma automática, conhecidas como redes neurais construtivas.

Na área de abastecimento de água, as redes neurais têm sido utilizadas para modelagem e previsão de comportamento em redes de água em termos de suas variáveis de estado (cargas de pressões, vazões, níveis nos reservatórios), em substituição aos modelos hidráulicos convencionais, de maneira eficiente e com velocidade de processamento muito superior aos métodos hidráulicos analíticos. Entretanto, existem poucos estudos que utilizam as redes neurais artificiais para a finalidade de calibração. Ao contrário dos modelos hidráulicos, que produzem respostas baseadas no balanço de massa e energia, as RNAs produzem resultados a partir do ajuste de coeficientes que não possuem significado físico, tornando seus resultados não verificáveis facilmente (caixa-preta) e que podem produzir respostas não realísticas, principalmente se houver necessidade de extrapolação (reproduzir comportamento para situações distintas daquelas utilizados durante o treinamento da rede).

Para minimizar este problema, as redes neurais necessitam de uma grande quantidade de dados para que a generalização ocorra de forma satisfatória. Na prática, nem sempre é possível a obtenção de quantidades de dados suficientes, além disso, para que melhores resultados sejam produzidos utilizando RNAs, é desejável que se colem dados com a maior amplitude de variações possível, por exemplo, operando a rede em situações diversificadas, através de realização de manobras.

Resumidamente, pode se dizer que modelos hidráulicos são compostos por informações físicas, conjuntos de equações e regras operacionais, e que a calibração consiste apenas na determinação de valores ótimos para variáveis de decisão que aproximem os resultados simulados dos dados obtidos em campo. Sendo assim, mesmo antes de calibrado, um modelo hidráulico possui internamente informações extremamente úteis sobre o setor de interesse, mas que não são aproveitadas nos estudos atuais. Variando os parâmetros do modelo, tais como coeficientes de rugosidades ou demandas, é possível criar cenários para os quais é possível produzir valores para as variáveis de estado (cargas de pressões e vazões) como respostas do sistema aos valores imputados. Hipoteticamente, os valores das variáveis de estado resultantes dessas simulações podem ser utilizados juntamente com os parâmetros modificados para treinar redes neurais artificiais, definindo-se as cargas de pressões e vazões ao longo do tempo como variáveis de entrada do modelo neural e os valores modificados como saídas(respostas) desejadas. Em outras palavras, as redes neurais após treinadas, estariam aptas a realizar a calibração dos modelos hidráulicos, sendo que as entradas do modelo seriam valores das variáveis de estado registrados em campo, e as saídas seriam os parâmetros calibrados.

Se por um lado, as RNAs são intensivas em termos do número de dados necessários para o seu aprendizado, por outro, os modelos hidráulicos possibilitam a produção de tantas informações desse tipo quanto necessário for. Assim, a idéia do presente trabalho foi a de propor a calibração automática com o auxílio de redes neurais artificiais construtivas, objetivando acelerar o processo de calibração e melhorar os resultados obtidos pelos métodos em uso.

1.1 Objetivos Gerais

O objetivo deste trabalho foi propor e testar um sistema de calibração automático utilizando técnicas de redes neurais artificiais para aprimorar os resultados dos sistemas de calibração atuais, tanto em termos de acurácia, quanto de diminuição do tempo de processamento computacional.

1.2 Objetivos específicos

- Desenvolvimento e aplicação do sistema de calibração através de redes neurais artificiais autoajustáveis a setores de rede existentes.

- Desenvolvimento e aplicação de um sistema de calibração híbrido que utilize redes neurais artificiais e algoritmos genéticos para otimização.
- Comparação dos sistemas de calibração propostos com métodos de calibração fazendo uso dos algoritmos genéticos.

2 REVISÃO BIBLIOGRÁFICA

No presente capítulo é apresentada uma revisão dos trabalhos recentes pertinentes ao tema e a fundamentação teórica necessária para o desenvolvimento deste trabalho. Assim, envolverá aspectos considerados chave à calibração de modelos de redes de distribuição de água para abastecimento.

2.1 Modelos Hidráulicos de Simulação de Redes

Existem vários modelos de simulação hidráulica que se prestam ao propósito de reprodução do comportamento das redes de distribuição de água para abastecimento. Estes modelos geralmente são usados para determinar cargas de pressões nodais e vazões nas tubulações, satisfazendo as equações de balanço de massa e energia seguintes (KAPELAN; SAVIC; WALTERS, 2005):

$$\sum_{m=1}^{N_i} Q_m - Q_{d,i} = 0 \quad (i = 1, \dots, N_n) \quad (1)$$

$$H_{i,u} - H_{i,d} - \Delta H_i = 0 \quad (i = 1, \dots, N_l) \quad (2)$$

Sendo:

Q_m : Vazões desconhecidas em todos os trechos N_i conectados ao i -ésimo nó da rede;

$Q_{d,i}$: demanda conhecida no i -ésimo nó;

$H_{i,u}$: carga de pressão desconhecida no nó a montante do i -ésimo trecho;

$H_{i,d}$: carga de pressão desconhecida no nó a jusante do i -ésimo trecho;

ΔH_i : diferença calculada entre a perda de carga total no i -ésimo trecho e a carga de bombeamento (em função da vazão do trecho Q_i);

N_i : número de trechos na rede;

N_n : número de nós na rede.

Em geral, o escoamento de fluidos em condutos forçados é modelado simplificadaamente de forma unidimensional, acompanhando o sentido do eixo dos condutos.

Cabrera et al. (1994) classificam os modelos hidráulicos em estáticos e dinâmicos. Modelos estáticos são aqueles que não consideram a variação do escoamento ao longo do tempo, ao contrário dos dinâmicos, que realizam a simulação de forma temporal. Os modelos dinâmicos são subdivididos em inerciais e não inerciais, quando consideram a inércia como elemento variável no tempo. Dentro dos modelos dinâmicos inerciais, estes ainda podem possuir a característica de considerar a deformação do fluido e do conduto, podendo ser classificados em modelos elásticos ou não elásticos. Este último tipo de modelo é o mais adequado e próximo do real, entretanto, na maioria dos casos, simplifica-se os modelos, desprezando a característica inercial e elástica devido a complexidade para modelagem destes tipos de sistemas e pelo pequeno ganho na qualidade das simulações. Modelos que consideram a inércia e a elasticidade têm usos bastante específicos, como por exemplo, estudos que visam investigar golpe de aríete e escoamentos oscilatórios.

Segundo Neves (2007), em modelos dinâmicos, o tempo de simulação geralmente exigido para se conhecer as características hidráulicas do sistema é de 24 horas. Sabe-se que a demanda sofre variações não só ao longo de um dia, mas também em diferentes dias da semana. Mesmo assim, segundo o autor, a simulação durante 24 horas revelou a tendência de consumo ao longo do dia e permitiu que fossem observadas demandas de pico, horários de baixo consumo, enchimento e esvaziamento de reservatórios e a resposta do sistema às variações de demanda.

Alguns modelos hidráulicos são dirigidos pela demanda nos nós. Neste tipo de modelo, supõe-se como conhecidos os valores das demandas dos consumidores, bem como seu padrão de consumo. Neste tipo de modelo, vazões e cargas de pressões são as variáveis de saída do modelo. Um software bastante popular que faz uso de um modelo dirigido pela demanda é o EPANET (ROSSMAN, 2000).

Outros modelos hidráulicos existentes são dirigidos pelas cargas de pressões. Este tipo de modelo é interessante, por exemplo, quando um dos objetivos da modelagem é a simulação de vazamentos (GIUSTOLISI; SAVIC; KAPELAN, 2008). Segundo Soares et al. (2003), os modelos dirigidos pelas demandas podem não ser confiáveis, pois consideram que as demandas são abastecidas integralmente, independentemente dos níveis de cargas de pressões atuantes na rede.

Iglesias (2001) apresentou uma revisão dos modelos hidráulicos mais comumente utilizados, como o EPANET, KYPIPE, MIKE-NET e SARA. Segundo o autor, a maioria dos

modelos utilizam o método gradiente (TODINI e PILATI, 1988) para realização dos cálculos das análises estáticas e/ou dinâmicas. Dentre os modelos mais utilizados, a exceção é o modelo KYPIPE que, ao contrário dos demais, utiliza o método da teoria linear.

Segundo Giustolisi e Todini (2009), o método clássico de representação das demandas em nós, ao invés de distribuídas ao longo dos trechos é errada pois pode gerar erros significativos no cálculo da perda de carga. Os autores propuseram o aprimoramento do método clássico representando as demandas aglomeradas por meio da correção da resistência hidráulica da tubulação. A correção se deu por meio de um algoritmo genético que permitiu que o cálculo da perda de carga apresentasse valores mais próximos dos reais. O estudo demonstrou que a distribuição da demanda nos nós gera grandes erros no balanço da conservação de energia quando as demandas estão aglomeradas em nós no final dos trechos, entretanto, as previsões apresentaram valores próximos aos reais em outros pontos da rede.

2.1.1 Modelagem Utilizando Epanet

O Epanet (ROSSMAN, 2000) é um software que permite realizar simulações quali-quantitativas, estáticas e dinâmicas, de sistemas de distribuição de água, amplamente utilizado na literatura. Possui a vantagem de ser gratuito e possuir o código fonte aberto, permitindo alterações personalizadas. Os sistemas gerados pelo Epanet agregam as informações físicas (topografia, comprimentos e diâmetros de tubulações, coeficientes de rugosidade, consumos nos nós, níveis dos reservatórios). Nas simulações estáticas, todas as demandas são tratadas como constantes no tempo, fazendo com que, conseqüentemente, as simulações de vazões e cargas de pressões também apresentem um único valor. Nas análises dinâmicas, consideram-se as variações de demandas e nos níveis de reservatórios e nas condições operacionais e, com isso, é possível obter uma série de soluções ao longo do tempo. O Epanet resolve o sistema de equações não lineares, que caracterizam o balanço de massa e energia na rede, utilizando como ferramenta o método Gradiente, proposto por Todini e Pilati (1988). O método consiste em resolver iterativamente uma série sistemas, na forma de matrizes jacobianas, determinando os valores das cargas de pressões e vazões desconhecidas.

O código fonte do Epanet 2 (ROSSMAN, 2000) é composto de duas partes, desenvolvidas em linguagens de programação distintas: um *front-end* e o *back-end*. O *front-end* consiste na parte visual (interface gráfica) do Epanet. Foi criado no ambiente de

desenvolvimento Delphi utilizando a linguagem *Object-Oriented Pascal* (OOP). É no *front-end* que o usuário irá construir o modelo de rede, executar as simulações hidráulicas e de qualidade e visualizar os resultados. A versão oficial do Epanet está disponível no site da EPA (*Environmental Protection Agency*) e é distribuída somente em inglês. Entretanto, como o código fonte do programa é aberto, o programa compilado possui versões traduzidas não-oficiais para diversos idiomas, incluindo o português.

O *back-end* chamado de Epanet Toolkit é um pacote de desenvolvimento que contém todas as funções para cálculos hidráulicos utilizados pelo *front-end*. Além de ser utilizado pelo *front-end*, o Epanet Toolkit pode ser utilizado independentemente por programadores para criarem seus próprios *softwares*. O Epanet Toolkit foi desenvolvido em linguagem C e também é distribuído livremente em forma de um arquivo DLL (*Dynamic Link Library*). O arquivo DLL pode ser incorporado em aplicações Windows escritas em qualquer linguagem capaz de fazer chamadas das funções Windows DLL, tal como C++ e Visual Basic, por exemplo.

O Epanet não considera os vazamentos explicitamente, mas é possível simulá-los através de um artifício que consiste no uso de aspersores de irrigação no modelo. Apesar de todas as vantagens do Epanet, ele não possui uma ferramenta de calibração própria, fazendo com que o desenvolvimento de softwares de calibração seja um objeto de interesse por parte dos pesquisadores.

2.2 Calibração de Modelos Hidráulicos

A calibração do modelo de rede é um procedimento preliminar a ser adotado antes que ele possa ser utilizado para reproduzir comportamento do sistema real (rede) por ele representado de maneira mais realística em termos das variáveis de estado. A calibração visa ao ajuste dos parâmetros do sistema de tal forma que os desvios entre os valores simulados e os respectivos valores observados em campo sejam minimizados.

Diversos métodos de calibração têm sido propostos na literatura como os métodos que empregam procedimentos *ad hoc*. Walski (1983, 1986), Bhave (1988) propuseram algoritmos apoiados em equações analíticas para a calibração dos fatores de atrito das tubulações e demandas nos nós. Estes métodos possuíam a desvantagem da dificuldade de formulação de equações analíticas. Ormsbee e Wood (1986) propuseram um método explícito para calibração de redes de distribuição de água. O processo é formulado em termos dos fatores de

atrito e de uma reformulação das equações governantes do escoamento, que são resolvidas explicitamente para determinadas condições operacionais. Os métodos explícitos resolvem analiticamente um sistema de n equações não-lineares que descrevem a hidráulica da rede para um conjunto de n desconhecidos. Os autores obtiveram resultados satisfatórios para as calibrações, entretanto não foi considerada a calibração da vazão simultaneamente aos fatores de atrito. Além disso, assim como seus antecessores, o método explícito utilizado era inferior aos métodos atuais, pois a calibração dos parâmetros era executada de forma sequencial ao invés de calibrados simultaneamente.

Greco e Giudice (1999) propuseram um método de calibração utilizando técnicas de programação não linear a partir de dados de cargas de pressão. A metodologia consistiu em buscar um conjunto para valores de coeficientes de rugosidade que minimizassem a soma do quadrado das diferenças entre as cargas de pressão simuladas e observadas. Posteriormente, Vítkovský et al. (2000) demonstraram que essa técnica de otimização é inferior aos algoritmos genéticos na determinação de soluções ótimas.

Righetto (2001) propôs um método de calibração utilizando coeficientes de rugosidades e diâmetros das tubulações como variáveis de decisão. O método de otimização utilizado foram algoritmos genéticos e embora tenha apresentado resultados satisfatórios, a metodologia foi aplicada somente a uma pequena rede teórica composta por 17 nós e 25 trechos. O trabalho não considerou a divisão da rede em grupos, devido ao tamanho reduzido e o trabalho não considerou a importância da determinação dos pontos de calibração.

Soares et al. (2004) dividem o processo geral da calibração em seis etapas. (i) obtenção dos dados cadastrais referentes as características físicas das tubulações (diâmetro, rugosidades, comprimento e material) e características dos componentes (válvulas e bombas), elevações topográficas, consumo das quadras, incidência de vazamentos, dentre outros. (ii) simplificação da rede, desconsiderando diâmetros inferiores a 150mm, salvo algumas exceções (ponta de rede, proximidades de reservatórios, mudança de diâmetro, dentre outras); (iii) divisão da rede em setores homogêneos em termos de rugosidade e parâmetros do modelo de vazamentos, de forma que as estimativas para cada setor de rede correspondam a um fator de ajuste global para o setor; (iv) detecção e reparo de vazamentos via campanhas de geofonamento; (v) instalação de medidores de carga de pressão e vazão (medidas preliminares de campo) na rede, de forma a armazenar tais dados simultaneamente com as informações relativas aos níveis dos reservatórios; (vi) simulação da rede utilizando os dados coletados para obter valores das variáveis de estado (carga de pressão e vazão) e compará-los

com os dados obtidos em campo. Se o ajuste é aceitável, a calibração é finalizada, caso contrário, volta-se a etapa de simulação, determinando (por algum processo de otimização) novos valores para os parâmetros e assim por diante, até que o critério de convergência seja satisfeito.

Dentre os diversos métodos de otimização, os algoritmos genéticos têm sido uma das técnicas mais utilizadas para a calibração de modelos de redes de distribuição de água (VITKOVSKY; SIMPSON; LAMBERT, 2000; SOARES et al., 2004; WU; SAGE, 2006). Outros estudos foram realizados utilizando diferentes métodos de otimização. Kapelan, Savic e Walters (2007) utilizaram um novo procedimento baseado em recursividade bayesiana. Esse método apresentou vantagens como a determinação de parâmetros de funções densidade de probabilidade e o fato da resolução não envolver equações diferenciais, evitando possíveis erros numéricos e problemas de descontinuidade.

Independente do método de otimização utilizado, a função objetivo consiste na minimização dos desvios entre os valores de carga de pressão e vazão, observados e simulados hidráulicamente, segundo equações do tipo:

$$\min FO = \sum_{t=1}^{n^{PD}} \left[\sum_{j=1}^{n_t^P} \frac{(P_{t,j} - P_{t,j}^*)^2}{\left(\sum_{i=1}^{n_t^P} \frac{P_{t,j}}{n_t^P} \right)^2} + \sum_{k=1}^{n_t^Q} \frac{(Q_{t,k} - Q_{t,k}^*)^2}{\left(\sum_{i=1}^{n_t^Q} \frac{Q_{t,k}}{n_t^Q} \right)^2} \right] \quad (3)$$

sendo n^{PD} o número de padrões de demanda observados, n_t^P o número de observações de cargas de pressões realizadas para o padrão t, n_t^Q o número de observações de vazões realizadas para o padrão t, P as pressões simuladas, P* as cargas de pressões observadas, Q as vazões simuladas, Q* as vazões observadas. Essa equação está sujeita as restrições dadas pelo conjunto de variáveis de decisão Z do problema, dado por:

$$Z = (\theta_1, \dots, \theta_{n\theta}, \beta_1, \dots, \beta_{n\beta}, k_1, \dots, k_{nk}) \quad (4)$$

Sendo θ o coeficiente de vazamentos, β o expoente do modelo de vazamentos, K o coeficiente de perda de carga localizada devido à presença de singularidades nas tubulações, tais como registros, válvulas ou tubos incrustados (SOARES et al. 2004).

Em geral, o grau de ajuste da calibração é avaliado através de funções de erro, que calculam a diferença entre os dados de campo e os dados simulados de algum modo, tais como somatório dos erros quadrados, soma dos erros absolutos e erro absoluto máximo.

No Reino Unido, estabeleceu-se critérios de performance dos modelos hidráulicos. De acordo com Walski (1983), dado um bom conjunto de dados de campo, recomenda-se que um modelo bem calibrado atinja uma diferença média de cargas de pressões entre $\pm 1,5$ a ± 5 m.c.a. e com um conjunto pobre de dados, uma diferença média de $\pm 3,1$ com diferença máxima de ± 10 m.c.a.

Este tipo de critério não existe nos EUA ou no Brasil, entretanto existe um consenso entre modeladores de que os níveis de esforço necessários para calibrar um modelo de rede hidráulica e o nível desejado de acurácia, dependem da intenção de uso do modelo (Walski et al. 2003).

Koppel e Vassiljev (2009) propuseram a calibração de modelos utilizando o algoritmo de Levenberg-Marquardt. O método consistia em classificar as redes de acordo com a idade das tubulações para calibrar os coeficientes de rugosidades. O principal problema deste método é a falta de informação cadastral a respeito da idade das tubulações nas companhias de saneamento.

Speight e Khanal (2009) avaliaram como a calibração da maneira como vem sendo feita por companhia de saneamento nos EUA. Os autores relatam que as principais dificuldades são a quantidade de dados gerados por sistemas GIS e SCADA e a falta de interesse das próprias companhias para financiar pesquisas desta natureza, pois estes estudos competem com outros considerados prioritários.

Jacobsen e Kamojjala (2009) fizeram um estudo sobre as ferramentas e processos para calibrar grandes modelos que consideram todos os trechos de rede. De acordo com os autores, os modelos do passado faziam muitas simplificações, como por exemplo, a eskeletonização, que consistia em considerar apenas os trechos com diâmetros maiores ou iguais a determinado diâmetro (ex: 300 mm de diâmetro).

Sanz e Pérez (2013) propuseram a calibração de redes de abastecimento, alterando os valores dos padrões de demanda do setor. Os autores verificaram que a qualidade da calibração é proporcional a quantidade de medidores de carga de pressão instalados em campo, no entanto, pelos resultados verificados, nota-se que isto ocorre pois a coleta de mais dados força ao aumento do intervalo de confiança, como ilustrado na Figura 1. Os gráficos do lado esquerdo, mostram a calibração de dois nós e os valores medidos encontram-se dentro do intervalo de confiança admitido para os valores calibrados com o uso de 10 medidores de

carga de pressão. Os valores do lado direito mostram a calibração com a utilização de 4 medidores. Além disso, foram utilizados dados sintéticos para a calibração.

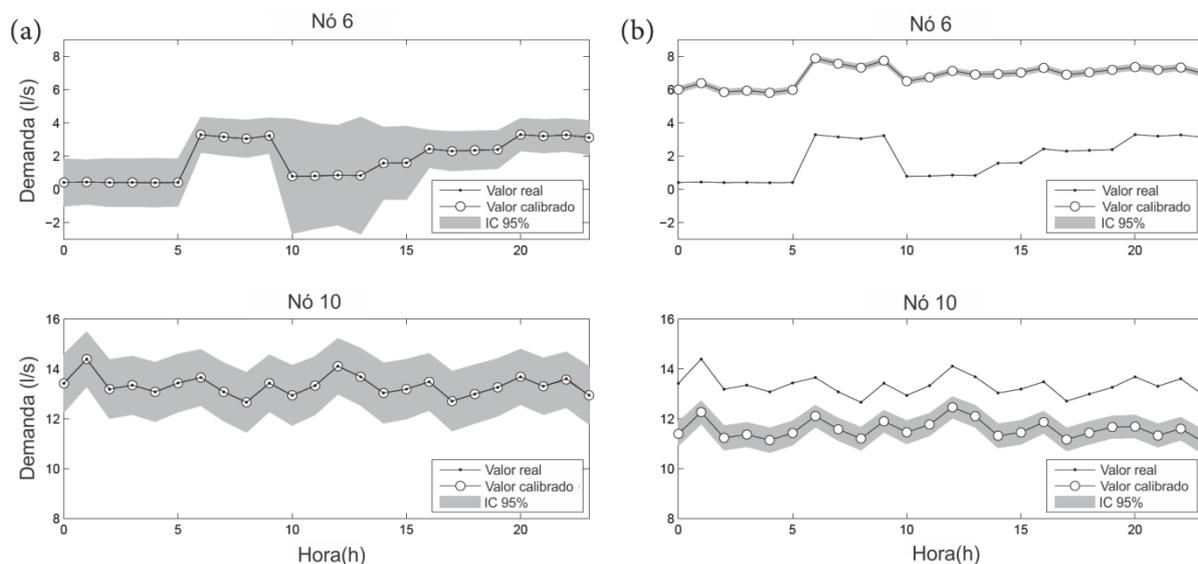


Figura 1 – Resultado da calibração de dois nós através da alteração dos padrões de demanda (SANZ E PÉREZ, 2013).

Recentemente, a EPA promulgou um guia a respeito de agentes desinfetantes que podem causar riscos a saúde. O guia requer que os modelos de sistemas de distribuição possuam pelo menos:

- 75% de todos os trechos do sistema
- Todas as tubulações de 300mm e superiores
- Pelo menos 50% do comprimento total da rede de distribuição
- Todos os trechos iguais ou superiores a 150mm que conectam áreas remotas à porção principal do sistema.

De acordo com Jacobsen e Kamojjala (2009), a calibração de redes com grande número de trechos deve ser realizada para intervalos menores que um ano, ao contrário do que ocorre com redes menores. Segundo os autores, esta etapa não é difícil, pois os dados são facilmente adquiridos por monitoramento remoto. O trabalho relatou os softwares desenvolvidos que integram os sistemas de modelagem, calibração e monitoramento. No estudo é enfatizado a necessidade da criação de softwares que automatizem essas tarefas, pois a inserção de dados manuais pode gerar erros de digitação e criar a necessidade de alocação de mão-de-obra para a atividade.

Estudos recentes tem demonstrado que modelos hidráulicos calibrados frequentemente resultam em simulações mais realísticas do que modelos calibrados ao longo de grandes períodos de tempo (Allen, Preis e Iqbal , 2011; Nicolini e Patriarca, 2011; Wu, Gao, Yuan et al 2011;. Hutton, Kapelan, Vamvakeridou-Lyroudia et al 2012).

2.2.1 Calibração para estimar parâmetros de vazamentos

Alguns estudos propõem a detecção de vazamentos e a calibração de modelos através do método do transiente inverso (MTI). Liggett e Chen (1994) realizaram o primeiro estudo e introduziram o conceito de MTI, utilizando o algoritmo de Levenberg-Marquadt para realizar a calibração. Vitkovsky, Simpson e Lambert (2000) utilizaram o mesmo conceito de MTI, usando a técnica de algoritmos genéticos para realização da otimização. Segundo Vitkovsky, Simpson e Lambert (2000), a eficiência dos algoritmos genéticos é superior à implementação proposta anteriormente, devido ao fato do espaço de busca do problema ser muito grande, com grande chance de falhas de convergência ou convergência para um mínimo local ao invés do mínimo global, dependendo do ponto de partida inicial adotado no processo de otimização.

Wu et al. (2006) realizaram o processo de calibração para estimar vazamentos. O trabalho consistiu em minimizar a diferença entre os valores de carga de pressão e vazão simulados pelo modelo e observados em campo, através do ajuste dos fatores do padrão de consumo. A técnica de otimização utilizada foi algoritmos genéticos.

Soares (2007) realizou a calibração considerando transitórios hidráulicos para detecção de vazamentos em modelos de sistemas de distribuição de água. O trabalho foi aplicado a redes hipotéticas e em uma rede de laboratório. Os resultados obtidos no laboratório foram ineficientes na reprodução do comportamento hidráulico utilizando o modelo clássico pois o circuito era composto de tubos plásticos. Entretanto, os resultados foram satisfatórios em modelos que consideravam o comportamento viscoelástico do material.

2.2.2. Criação de zonas homogêneas

Os sistemas de distribuição de água para abastecimento usualmente apresentam grandes quantidades de tubulações com coeficientes de rugosidade desconhecidos. Esta

grande quantidade de tubulações torna inviável a determinação dos coeficientes de rugosidade para todos os trechos. Portanto, o modelo deve ser simplificado, de modo a assumir que conjuntos de tubulações possuam a mesma rugosidade. Essa etapa é conhecida na literatura como parametrização e é importante tanto para estimar menor número de valores desconhecidos, reduzindo o grau de indeterminação do problema, quanto para reduzir a quantidade de cálculos computacionais. Mallick et al. (2002) listam como critérios para a seleção dos trechos em grupos: (1) idade e material da tubulação, (2) diâmetro da tubulação, (3) localização relativa, e (4) identificação de trechos críticos em termos de zonas de carga de pressão. A escolha do melhor critério é feita de forma empírica e através da experiência do modelador. Mallick et al. (2002) propõem uma formulação de cálculo da medida de incerteza em previsões do modelo (Equação 5).

$$Cov(H^A) = \left[\frac{\partial H^A}{\partial C} \right]^T Cov(C) \left[\frac{\partial H^A}{\partial C} \right] \quad (5)$$

Sendo:

$Cov(C)$: é a matriz de covariância do modelo previsto.

H^A : carga prevista para a condição de demanda.

C : é o coeficiente de rugosidade.

$[J]^T$: denota transposição de matriz.

A medida da incerteza é armazenada na forma da matriz jacobiana (Equação 5). Este cálculo é melhor detalhado no Capítulo 3 (Materiais e Métodos).

2.3 Incertezas na Modelagem

Modelos de sistemas de distribuição de água estão sujeitos a incertezas, por exemplo incertezas no consumo de água futuro, incertezas nas características de um SDA atual e futuro (e.g., detalhes da configuração da rede, coeficientes de rugosidade das tubulações, status de funcionamento de válvulas, etc.) e incertezas sobre parâmetros econômicos (e.g., taxas de juros, vários custos unitários de reparos etc). Ao mesmo tempo, os orçamentos das companhias de abastecimento de água geralmente são limitados, levando à necessidade de identificar soluções de custo efetivo. A identificação e implementação de soluções que visem diminuir a incerteza levam a uma melhoria na performance, geralmente manifestada em gerenciamento de cargas de pressões mais eficientes, melhoria na performance da qualidade

da água etc (KAPELAN; SAVIC; WALTERS, 2005). A otimização dessas incertezas tem sido objeto de interesse de pesquisadores e pela administração de SDA. Um dos principais objetos de pesquisa tem sido a pesquisa para redução de custos operacionais.

As primeiras pesquisas utilizavam métodos de otimização não-evolucionários, e alguns autores (DANDY; SIMPSON; MURPH, 1993, 1996) identificaram limitações nos algoritmos de busca local e propuseram métodos baseados em algoritmos genéticos.

Kang, Pasha e Lansey (2009) compararam 4 métodos de análise de incerteza: Simulação Monte Carlo (MCS), método da estimação pontual, método da primeira ordem segundo momento (FOSM) e a amostragem hipercubo latino (LHS). Os parâmetros avaliados foram a qualidade das aproximações e a quantidade de esforço computacional envolvidos. As simulações foram feitas no Epanet e foram considerados parâmetros hidráulicos e de qualidade da água. Foram considerados para o trabalho, a carga de pressão, a idade da água e a concentração de cloro. A metodologia foi aplicada em um sistema real com 116 trechos e 90 nós. Os resultados demonstraram que o LHS provê boas estimativas de intervalos de saída para condições estacionárias e não estacionárias comparadas com MCS, enquanto FOSM foi bem para condições estacionárias, mas pobre em alguns períodos de simulação para concentração de cloro. O trabalho examinou (1) a normalidade das saídas do modelo MCS através de inspeção visual e testes estatísticos, (2) o impacto de fontes alternativas de incerteza nas previsões de carga de pressão e na qualidade da água e (3) o efeito dos níveis de incerteza de entrada na saída avaliando três níveis de incerteza.

2.3.1 Demandas

A demanda é um dos fatores mais importantes para os modelos de distribuição de água. Caso o valor da demanda seja subestimado, o balanço de massa levará a um incremento irreal na quantidade de vazamentos ou ligações clandestinas.

Branisavljevic, Prodanovic e Ivetic (2009) estudaram meios de reduzir a incerteza em modelos de sistema de distribuição de água usando dados de vazão. Segundo os autores, o somatório das demandas nodais é a variável que menos possui incertezas, pois pode ser medido diretamente. Os autores classificam as incertezas que afetam os dados de entrada em dois grupos: aqueles dependentes da acurácia dos equipamentos de medição, e aqueles cuja incerteza é devido a falta de informação. No primeiro grupo incluem-se além dos dados de carga de pressão e vazão, características da bomba, níveis dos reservatórios. No segundo

grupo, coeficientes de rugosidades das tubulações e demandas nodais (inclusive vazamentos) são os mais significativos. Apesar das medições apresentarem erros, dados medidos são considerados satisfatórios, indicando que a maioria das incertezas vem do segundo grupo. Foi feita análise de sensibilidade, pois nem todas as demandas tem um impacto igual no modelo de saída, somente as demandas nodais mais sensíveis foram consideradas. Outra desvantagem é que não foi considerada que exista incertezas na topologia da rede. Existem 3 maneiras de representar as variáveis de incerteza (usando intervalos, usando distribuições estatísticas, conjunto disperso). No artigo foi usado conjunto disperso. O trabalho mostrou uma redução de 25% na incerteza. Foi desenvolvido um algoritmo genético modificado e a eficiência do método não é clara para redes mais complicadas devido ao grande tempo de processamento requerido pelos AG.

Apesar de ser medido diretamente, de acordo com estudos de Arregui et al. (2005), a demanda é um dado sujeito a diversas incertezas. Os hidrômetros utilizados para medição do consumo subestimam as leituras por uma série de fatores, como sólidos suspensos, inclinação no ângulo de instalação, bloqueamento parcial do filtro e encrustações. Além disso, o uso de caixas d'água reduzem a velocidade de escoamento para um nível inferior a faixa de operação para o qual os hidrômetros foram projetados. Existem no mercado, hidrômetros preparados para medir velocidades mais baixas e que são imunes ao ângulo de instalação. A Tabela 1 mostra as diferenças nas vazões mínimas mensuráveis para cada classe de hidrômetro de acordo com o diâmetro.

Tabela 1 – Relação entre o diâmetro e a vazão mínima para diferentes classes de hidrômetros.

Classe Metrológica	B	C	B	C	B
Diâmetro (mm)	15	15	20	20	50
Vazão mínima (L/h)	30	15	50	25	450

Fonte: Adaptado de Arregui, Cabrera e Cobacho (2006)

Cutore et al. (2008) propuseram um novo algoritmo chamado SCEM-UA (Shuffled Complex Evolution Metropolis Algorithm) para previsão de demandas. Durante a revisão do trabalho, os autores verificaram que árvores de decisão são rápidas para este tipo de aplicação, mas as redes neurais artificiais apresentam melhores resultados. Segundo os autores, apesar da nítida incerteza envolvida, todos os modelos de previsão de demanda

atuais tratam o problema como sendo determinístico. Tal comportamento faz com que a incerteza das medições não sejam propagadas para parâmetros de calibração e estes não são propagados para os modelos de previsão. Alguns modelos atuais já consideram a incerteza, por exemplo, o FOSM (modelo de primeira ordem segundo momento) e o MCMC (Markov Chain Monte Carlo). O método proposto (SCEM-UA) determina parâmetros de calibração, considerando-os como pesos desconhecidos ligados a neurônios da rede neural. O método foi aplicado na cidade de Catania e demonstraram resultados de previsão de demanda melhores que os modelos anteriores. Houve uma diminuição nos intervalos de previsão, entretanto o modelo necessita de um grande esforço computacional.

2.3.2 Coeficientes de rugosidades e diâmetros incertos

Segundo Walski et al. (2003), o diâmetro de uma tubulação é bastante incerto. Além dos casos em que existe falta de registros cadastrais, normalmente, os diâmetros reais das tubulações são diferentes dos valores nominais, pois sofrem processos químicos de corrosão ou de depósito de material. O diâmetro da tubulação tem influência muito maior na perda de carga através de um tubo do que o valor do coeficiente de rugosidade. Para exemplificar, um aumento de 10% no diâmetro da tubulação, implica na redução em quase 40% a perda de carga, enquanto um aumento de 10% no coeficiente de rugosidade aumenta a perda de carga em aproximadamente 20%. Segundo os autores, fatores *C* de Hazen-Williams tão pequenos quanto 20 ou 30 podem ser necessários em tubulações obstruídas para a obtenção de calibrações satisfatórias. Por outro lado, o diâmetro de tubulações novas geralmente é maior do que o diâmetro nominal, um aumento no coeficiente de rugosidade também é utilizado para corrigir essa diferença. Portanto, nos modelos matemáticos, devido ao fator de rugosidade também ser utilizado indiretamente para calibração de diâmetros, o coeficiente de rugosidade encontrado nas calibrações podem variar bastante dos valores esperados.

De acordo com Kang (2010b), as rugosidades das tubulações e as demandas nodais são as variáveis de entrada mais incertas em modelos de simulação, pois são difíceis de serem medidas diretamente. De acordo com o autor, existem estudos para estimação desses parâmetros, por exemplo através de tentativa e erro, métodos de otimização e métodos de mínimos quadrados ponderados. Uma desvantagem, segundo o autor é que os estudos anteriores assumiam que os consumos de água são conhecidos. A contribuição do referido trabalho foi a determinação dos parâmetros através da calibração ao mesmo tempo do

coeficiente de rugosidade e das demandas de água. Além disso, foi considerado os erros nos dados, sendo possível a realização de uma análise de incerteza. O trabalho utilizou apenas séries de dados sintéticas em uma rede hipotética e a rugosidade estimada foi o coeficiente de Hazen-Williams. Os resultados mostraram que usando a vazão e carga de pressão geradas sinteticamente para diversos cenários. Os resultados mostraram que o método sequencial proposto é estável em termos de convergência numérica no cálculo dos mínimos quadrados ponderados e traz melhores estimativas comparados com a estimação conjunta tradicional, em que as estimativas são pobres e frequentemente violam o intervalo aceitável dos coeficientes de rugosidade levando a resultados não realísticos.

2.3.3 Erros de medição

Kang (2010a) realizaram um estudo sobre a determinação da localização de dados incorretos medidos em sistemas SCADA (*Supervisory Control and Data Acquisition*). Segundo os autores, as medições utilizando SCADA possuem, além de ruídos gaussianos, erros grosseiros de medição devido a falhas no sistema e/ou mal funcionamento nas medições.

A correção destes dados é um processo importante que deve ser efetuada antes da etapa de calibração. As falhas de sistema e mal funcionamento nas medições são fenômenos aleatórios, difíceis de serem identificados. De acordo com Kang (2010a), os métodos propostos anteriormente consistem em ajustes de pesos utilizando mínimos quadrados. Quando grandes valores são designados para os pesos, dados ruins com erros grosseiros são eliminados pela redução do peso associado com essas medições. O método proposto no estudo foi dividido em duas etapas. Detecção e localização de dados ruins. A detecção consiste apenas em dizer que existem dados errôneos em um conjunto de dados. A localização consiste na determinação dos valores incorretos. Na fase de detecção são realizados dois testes de hipótese utilizando os testes $J(x)$ e r^n , baseados na distribuição qui-quadrado e normal respectivamente. Caso a hipótese seja rejeitada, a etapa de localização dos dados é aplicada através da normalização e ordenação do conjunto de dados. Os valores com maior residual normalizado são os dados ruins. O estudo somente foi realizado em uma rede hipotética e os dados foram gerados sinteticamente.

2.3.4 Vazamentos

Dentre as diversas variáveis incertas estão os vazamentos. Em modelos elaborados é interessante que exista uma separação da demanda real e dos vazamentos. Segundo (SOARES, 2003), partindo do princípio de que os vazamentos dependem das cargas de pressões, os modelos de vazamentos podem ser subdivididos em métodos que se prestam a avaliações globais ou detalhadas da rede.

Os modelos globais fazem uso de cargas de pressões médias por zona (LAMBERT et al., 1999; BURROWS; TANYIMBOH; TABESH, 2000; LAMBERT; HIRNER, 2002). A deficiência principal desses modelos é a falta de capacidade do modelo ser empregado em simulações, admitindo as perdas dirigidas pela carga de pressão. Já nos modelos detalhados, é possível introduzir os vazamentos explicitamente nas simulações ou avaliá-las iterativamente sem que sejam explicitadas relações carga de pressão \times vazamento internamente ao modelo (SOARES, 2003).

No passado, a visão convencional supunha que vazamentos eram pouco sensíveis a carga de pressão, como descrito pela equação dos orifícios (Equação 6).

$$q = AC_d(2gh)^{0.5} \quad (6)$$

Sendo q o vazamento através de orifício, C_d é o coeficiente de descarga, A é a área do orifício, g é a aceleração da gravidade e h é a carga de pressão sobre o orifício. No entanto, segundo Zyl e Clayton (2007), a carga de pressão é um dos fatores que mais influenciam nos vazamentos em sistemas de abastecimento. Greyvenstein e Zyl (2007) demonstraram que os valores do expoente da Equação 6 dependem do tipo de material e que podem ser consideravelmente maiores do que 0,5. Para aplicar essa equação aos vazamentos em tubulações, ela pode ser escrita de forma mais geral como

$$q = ch^\alpha \quad (7)$$

Sendo c é definido como um coeficiente de vazamento e α um expoente de vazamento (α algumas vezes é referenciado como N1). Os limites encontrados para α de acordo com o tipo de material estão ilustradas na Tabela 2.

Tabela 2 – Alguns valores de expoentes encontrados em tubulações de diferentes materiais (GREYVENSTEIN; ZYL, 2007)

Material	Limites de α
Cimento amianto com fissura longitudinal	0,78 – 1,04
Ferro corroído	1,09 – 2,30
PVC rígido com fissura longitudinal	1,5 – 1,85
PVC rígido com orifício circular	0,41 – 0,53

A Figura 2 ilustra a importância do expoente de vazamento. O eixo das ordenadas representa as variações da razão entre as vazões, e o eixo das abscissas, a razão da carga de pressão. A curva representa o encontro dos eixos para diferentes valores de α . Por exemplo, se a carga de pressão em uma tubulação for reduzida para $H_1/H_0 = 0,3$, a taxa de vazamento será reduzida por 45%, 70% e 95% para expoentes de 0,5, 1,0 e 2,5 respectivamente.

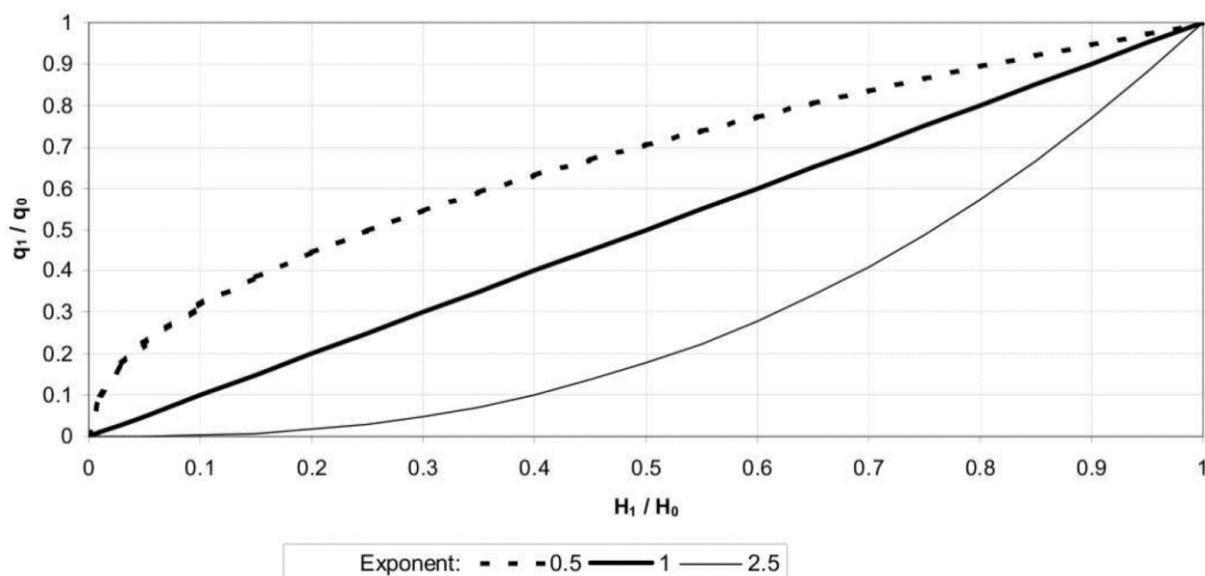


Figura 2 – Efeito do expoente de vazamento na taxa de vazamentos (GREYVENSTEIN; ZYL, 2007)

Tucciarelli, Criminisi e Termini (1999) quantificam o valor das perdas através da modelagem reversa, reiterando a importância da carga de pressão, dos coeficientes e expoentes de vazamento. Nesse estudo, Tucciarelli, Criminisi e Termini (1999) propõem uma equação aprimorada do cálculo do vazamento através dos nós consistindo em

$$Q_i = (H_i - Z_i)^\alpha \sum_{j=1}^{M_i} \frac{\pi}{2} D_{ij} \theta_{ij} L_{ij} \quad (8)$$

Sendo: L_{ij} : comprimento do trecho; D_{ij} : diâmetro do trecho; θ_{ij} : superfície de vazamento por unidade de superfície do trecho que une os nós i e j . Os valores de Q_i podem ser calculados estimando-se os valores de P , α e θ_{ij} . Esses valores podem ser estimados medindo-se a carga de pressão total H^* e taxas de vazão F^* em um conjunto de nós n_h e trechos n_f . As medidas são usadas para a resolução do problema inverso:

$$\text{Min. FO} = \sum_{j=1}^{n_h} w_h \frac{(H_j - H_j^*)^2}{(\sum_{i=1}^{n_h} H_i^*)^2} + \sum_{j=1}^{n_f} w_f \frac{(F_j - F_j^*)^2}{(\sum_{i=1}^{n_f} F_i^*)^2} \quad (9)$$

Sendo F = vetor de taxas de vazões computadas; as cargas de pressões e vazões observadas devem ser inseridas, respectivamente, nos primeiros n_h nós e nos primeiros n_f trechos; e w_h e w_f são dois pesos, correspondente a quantidade de valores observados. As diferenças quadradas são divididas pelo quadrado da soma dos valores para cada conjunto de dados para que a função objetivo FO seja independente de unidades (TUCCIARELLI; CRIMINISI; TERMINI, 1999).

De acordo com esses pesquisadores, quando o expoente α possui valor mínimo de 0,5 corresponde a um valor constante de áreas de pequenos vazamentos em torno dos nós. Araujo, Ramos e Coelho (2006) corroboraram estes valores em um estudo semelhante, criaram um modelo de sistema de suporte a decisão, realizando o controle automático de válvulas com o objetivo de minimizar a carga de pressão e consequentemente os vazamentos.

Modelos convencionais de SDA como o Epanet são formulados assumindo que os consumos de água ou demandas definidos nos nós são valores conhecidos e portanto, a carga hidráulica e a vazão podem ser determinadas resolvendo um conjunto de equações quasi-lineares (ROSSMAN, 2000). Entretanto, existem alguns cenários em que a carga de pressão nodal não é suficiente para fornecer a água requerida pelos nós. Nestes cenários, incluem-se situações como manutenções no sistema, falha nas estações de bombeamento e água insuficiente na fonte de fornecimento. Para este tipo de cenário, foram propostos modelos, que diferentemente dos modelos convencionais, dirigidos pela demanda, são dirigidos pela carga de pressão (WU et al., 2006).

Apesar de os modelos de simulação dirigidos pela pressão (SDP) apresentarem bons resultados em suas simulações, este trabalho focará o estudo em modelos convencionais, pois

a situação em que os modelos SDP são utilizados são em casos específicos e de curta duração.

Soares (2003) propôs um modelo híbrido de calibração que buscava coeficientes de rugosidades e parâmetros de vazamentos. Devido ao elevado tempo computacional dos algoritmos genéticos comparados a outras técnicas tais como Newton-Raphson e Levenberg-Marquardt, e a deficiência no refinamento das soluções, o autor criou um modelo híbrido que buscava as soluções utilizando AG no primeiro momento e depois refinava-se com o método Simplex. Os resultados demonstraram mais rapidez no tempo computacional do que unicamente através dos AG.

Cassa e Van Zyl (2013) estudaram a variação entre a equação dos vazamentos com descargas fixas e variáveis. Após a realização de experimentos, os autores propuseram uma nova formulação para o modelo de vazamentos, introduzindo uma nova variável adimensional definido como $N_L = mh/A_0$, sendo N_L a razão entre porções variáveis definidas como mh (inclinação do orifício criado) e as porções fixas dos vazamentos (A_0 = área do vazamento inicial sob condições sem pressão). Embora o trabalho contribua para o equacionamento dos vazamentos, o trabalho foi feito em laboratório sob condições controladas. Em modelos reais, onde prevalecem incertezas e coeficientes heterogêneos, a aplicação da nova equação proposta não é viável, pois a modelagem necessita de diversas generalizações e simplificações.

2.3.5 Perdas de carga localizadas

As perdas de carga localizadas (também chamadas de perdas de carga menores) são provocadas pela adição da turbulência causada por junções, medidores, válvulas e outras conexões. A ocorrência da perda de carga localizada é considerada concentrada no ponto, provocando uma queda da pressão no pequeno espaço compreendido pelo acessório. A importância deste tipo de perda depende do layout da rede de água e do grau de acurácia desejado. O EPANET permite que cada trecho ou válvula possua um coeficiente de perda localizada associado. A perda de carga resultante é calculado através da Equação 10:

$$h_L = K \frac{V^2}{2g} \quad (10)$$

Sendo:

K : coeficiente de perda localizada

V^2 : Velocidade média do fluxo (m/s)

g : aceleração da gravidade (m/s/s)

A Tabela 3 lista alguns exemplos com conexões e seus respectivos valores típicos para os valores de K encontrados na literatura.

Tabela 3 – Exemplos de coeficientes de perda localizada teóricos (ALPEROVITS e SHAMIR, 1977)

Acessório	Coeficiente
Alargamento gradual	$K=0,3$
Bocais	$K=2,75$
Comporta aberta	$K=1$
Curva de 45 graus	$K=0,20$
Cotovelo de 45 graus	$K=0,40$
Registro de globo	$K=10$
Registro de ângulo	$K=5$
T de saída bilateral	$K=1,8$

2.4 Plano de amostragem para modelos de calibração

Uma etapa fundamental para a calibração de modelos de redes de abastecimento é a aquisição de dados confiáveis de cargas pressão e vazão. O processo geralmente necessita de uma série de campanhas de campo, em que cargas de pressão e vazão são registrados em locais estratégicos do sistema, durante períodos de um ou mais dias. A seleção dos locais de monitoramento em um sistema de distribuição de água, também chamado de plano de amostragem, tem a finalidade de assegurar que dados de qualidade para o modelo de calibração sejam coletados.

2.4.1 Campanhas de campo

Campanhas de campo de uso normal

Uma campanha de campo típica envolve três tarefas sucessivas seguintes:

- Definir um plano de amostragem, incluindo o período da campanha e frequência do registro.
- Verificar se todas as válvulas do sistema estão fechadas.
- Finalmente, cargas de pressões e vazões são registrados simultaneamente nos pontos de monitoramento, normalmente continuamente durante um dia de trabalho típico.

O monitoramento de vazão deverá ser realizado em todos os pontos de importação e exportação do sistema, entradas e saídas de armazenamento de água e fornecimento para os maiores consumidores domésticos. Os pontos de monitoramento de cargas de pressão são usualmente colocados em nós considerados importantes (através de algum critério), distribuídos pela rede. Nós localizados em pontos finais raramente são monitorados devido à ocorrência de perdas de carga pequenas e intermitentes.

Pontos de monitoramento adicionais podem ser necessários onde se sabe que existe problemas no sistema. Entretanto, a exata localização dos registradores de cargas de pressão em um sistema de distribuição de água geralmente envolve um julgamento subjetivo e portanto não assegura a aquisição de dados mais adequados para a calibração de modelos.

Campanhas de campo de vazão de incêndio

Campanhas de vazão de incêndio consistem em estressar o sistema de distribuição de água abrindo um ou mais hidrantes para aumentar a demanda artificialmente. Embora campanhas de vazões de incêndio apresentem maiores custos que as campanhas de campo normais, produzem estimativas mais precisas, pois a maior vazão transportada nas tubulações ocasiona maiores perdas de carga necessárias para estimar valores de coeficientes de rugosidade. Geralmente é necessário fechar algumas válvulas para isolar as tubulações a serem testadas.

Existem dois métodos para determinar a perda de carga em um tubo durante um teste de vazão de incêndio. Ambos necessitam que a vazão através do tubo seja medida. Os métodos são:

- O teste da mangueira paralela que consiste em conectar uma mangueira ao hidrante com um medidor de carga de pressão em linha. Este método é tipicamente aplicado a tubos com comprimentos menores que 1000 m.
- O teste do manômetro consiste em usar dois medidores para registrar a carga de pressão em cada hidrante. Este método é tipicamente aplicado a tubulações com comprimentos maiores que 1000 m.

Uma vez que a perda de carga na tubulação é determinada, o coeficiente de rugosidade do tubo testado pode ser calculado utilizando uma equação de perda de carga (e.g. Hazen-Williams). Para testes manométricos, dados de elevação são importantes e devem ser determinados com precisão. Entretanto, para testes da mangueira paralela, os dados de elevação não são cruciais pois a pressão diferencial é com base nos mesmos pontos, fazendo com que erros de elevação sejam anulados.

2.4.2 Avaliação da densidade

Os EUA e o Reino Unido possuem guias para a quantidade de sensores a serem distribuídos durante a coleta de dados para calibração (DE SCHAETZEN, 2000). A Tabela 4 lista o número de sensores sugeridos pelo Reino Unido de acordo com o número de habitantes. Nos EUA, o critério da quantidade baseia-se na intenção do uso do modelo (Tabela 5).

Tabela 4 – Quantidade de sensores sugeridos pelo Reino Unido (DE SCHAETZEN, 2000)

Tipo de modelo	Sensor de pressão	Sensor de vazão	Sensor de nível
< 30000 habitantes	20 a 40	2 a 6	2 a 4
Aproximadamente 30000	40 a 80	5 a 15	4 a 8
Acima de 1000000	60 a 120	15 a 30	10 a 20

Tabela 5 – Quantidade de sensores sugeridos pelos EUA (DE SCHAETZEN, 2000)

Finalidade do uso	Sensor de pressão	Sensor de vazão
Planejamento a longo prazo	2% dos nós	1% dos trechos
Projeto	5% a 10% dos nós	3% dos trechos
Operação	2% a 10% dos nós	2% dos trechos
Qualidade da água	10% dos nós	5% dos trechos

2.4.3 Procedimentos existentes para determinação do plano de amostragem

Alguns pesquisadores têm investigado planos de amostragem para sistemas de distribuição de água. O problema geralmente consiste em definir a localização e o número de pontos de monitoramento em um sistema, que é geralmente sujeito a várias restrições, para coletar dados em campo para serem utilizados para calibração do modelo de rede.

A maioria das técnicas existentes para o plano de amostragem é baseada em classificação, isto é, são utilizados rankings para classificar locais de medidas potenciais em ordem decrescente acordo com algum critério (BUSH; UBER, 1998). Além disso, a maioria das propostas existentes identificam somente pontos de carga de pressão, independentemente do tipo de teste, i.e. se um teste de vazão de incêndio ou de uso normal de água. De Schaetzen (2000) utilizaram um método de plano de amostragem baseado em entropia que difere dos métodos tradicionais.

Pudar e Liggett (1992) desenvolveram uma proposta para detectar vazamentos em um sistema de distribuição de água usando dados de campo. Verificaram que a qualidade dos resultados depende do número e localização das medições. A localização e magnitude dos vazamentos são sensíveis à quantidade e qualidade das medições de carga de pressão. Os autores concluíram que uma matriz de sensibilidade é a chave para decidir onde realizar as medições. Uma matriz de sensibilidade normalmente é uma matriz composta de derivadas parciais de primeira ordem (Matrizes Jacobianas).

Lee (1992) desenvolveu um método baseado na maximização da cobertura para localizar os pontos de amostragem em sistemas de distribuição para monitorar a qualidade da água. O problema foi formulado como um problema de otimização e testado em duas redes exemplos. Entretanto, segundo os autores, as medidas disponíveis não eram suficientes para

quantificar a efetividade dos pontos amostrais, e as estações deveriam ser localizadas de modo que a fornecer o máximo de informação sobre o estado da rede.

Yu e Powell (1994) usaram análise de uma matriz de covariância para selecionar a localização de pontos de monitoramento. O problema da localização dos medidores foi formulado como um problema de otimização multiobjetivo. O número de dispositivos de medição e os custos totais de medição foram minimizados, enquanto a precisão das variáveis de estado eram maximizadas. Uma técnica de árvore de decisão juntamente com técnica de gradiente conjugado foi usada para resolver o problema não-linear de mínimos quadrados da estimação de estados. O método foi então testado em duas redes hipotéticas consistindo em 8 trechos e 6 nós para o primeiro modelo e 41 trechos e 34 nós para o segundo modelo. No entanto, a escolha do segundo modelo foi menos efetivo que o primeiro modelo, pois somente dois nós entre os 34 nós são nós de demanda e estes nós eram classificados como os dois primeiros locais de medição.

Ferreri, Napoli e Tumbiolo (1994) utilizaram uma matriz de sensibilidade para classificar trechos e nós mais apropriados para a medição de vazão e carga de pressão. Os resultados foram satisfatórios, no entanto a metodologia foi testada somente para uma pequena rede hipotética que consistia de 35 trechos e 16 nós.

Piller, Bremond e Morel (1999) apresentaram um método para definir o plano de amostragem ótimo para estimação de variáveis de estado. O método consistiu na minimização da influência dos erros de medição sobre o vetor de estimação de estados enquanto asseguravam a independência máxima das medições. A solução então foi determinada com o uso do algoritmo guloso. O método proposto foi testado para uma rede de distribuição real com 214 trechos e 163 nós.

De Schaetzen, Walters e Savic (2000) aplicaram três diferentes planos de amostragem para selecionar pontos de monitoramento de carga de pressão para estimar coeficientes de rugosidade. Os primeiros dois métodos classificaram a localização baseado no algoritmo do menor caminho. O terceiro plano tentou identificar o conjunto ótimo de pontos de monitoramento maximizando a função de entropia de Shannon usando algoritmos genéticos. Os dois primeiros métodos baseados no menor caminho não são ótimos, entretanto, segundo os autores são práticos e funcionam bem para a medida necessária em um modelo hidráulico. O terceiro plano de amostragem proposto não foi baseado em classificação, mas sim na busca da maior entropia global com o uso de algoritmos genéticos e apresentou o melhor resultado

entre os três, demonstrando sua habilidade de auxiliar modeladores e potencial para economia e performance na atividade de plano de amostragem.

Kapelan, Savic e Walters (2003) realizaram um estudo semelhante utilizando dois objetivos: maximizar a precisão da calibração minimizando o modelo de predição global ou as medidas dos parâmetros de incerteza e minimizar o custo total do plano de amostragem. O trabalho normalizou os dois objetivos transformando-os em um objetivo único e foi otimizado, comparando com a otimização multiobjetivo. Os autores concluíram que o modelo multiobjetivo é melhor comparado com um modelo de objetivo único pois encontra explicitamente a precisão do modelo calibrado usando um modelo de predição de medição de incertezas ao invés do uso implícito de entropia ou medida de sensibilidade. Segundo Kapelan et al. (2005), a abordagem de redução da incerteza diretamente nos modelos hidráulicos torna este método preferível aos métodos de cálculos de incertezas de forma implícita, como através do uso da entropia (DE SCHAETZEN et al., 2000) ou pela medição da sensibilidade (SCHAETZEN et al., 2000; YEH, 1986). Entretanto, uma desvantagem do método é o tempo computacional comparado com os métodos anteriores. A avaliação direta da incerteza, que inclui cálculos de inversão de matrizes ou cálculos de determinantes, pode ser um obstáculo ao analisar grandes redes de abastecimento reais. De acordo com os autores, este problema tende a ser reduzido no futuro com a melhoria da tecnologia dos computadores.

2.5 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) têm mostrado serem eficazes para abordar problemas de reconhecimento de padrões, classificação e previsão. O método mais comum para o aprendizado das RNAs é o algoritmo *Feed-forward back-propagation* (FFBP). A arquitetura de uma rede neural geralmente é descrita como um arranjo de nós interconectados organizados em três grupos. O primeiro grupo consiste nos nós de entrada que aceitam informações externas para dentro do modelo. O segundo grupo forma as camadas ocultas da rede. Cada camada oculta é um conjunto de nós que recebe suas entradas da camada anterior, executa algum processamento (combinação e transferência) e alimenta uma saída para os nós da camada seguinte. O terceiro grupo representa a saída do sistema; nós deste conjunto processam valores transferidos da última camada oculta.

A maioria dos modelos de RNAs usam uma rede multicamada com uma ou mais camadas escondidas (Figura 3). A definição do modelo em termos dos nós de entrada, do número de camadas ocultas e de nós ocultos e a forma das funções de transferência geralmente necessita de tentativa e erro para o melhor ajuste a cada problema ao qual a rede será aplicada.

Segundo Ghiassi e Saidane (2005), no algoritmo FFBP, o número ideal de camadas ocultas é geralmente uma ou duas. No entanto, não há um método consagrado para determinar a quantidade de nós nas camadas ocultas de uma RNA de múltiplas camadas.

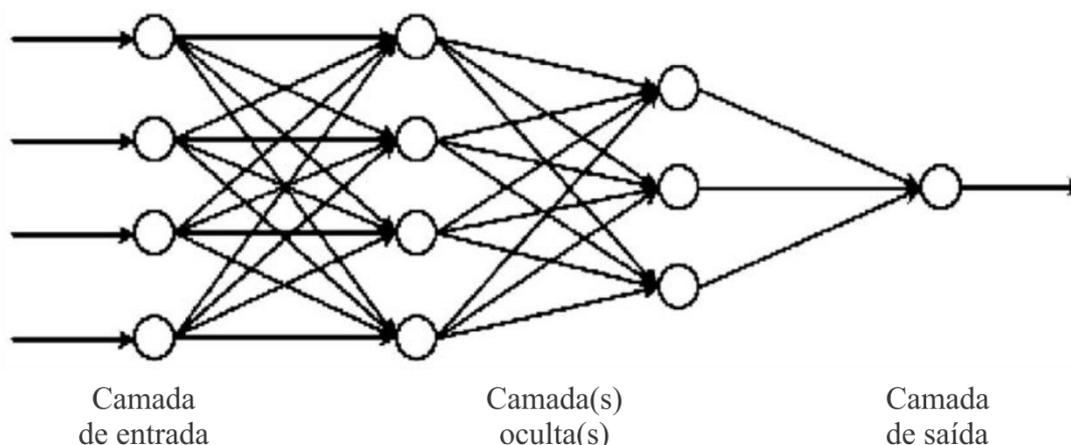


Figura 3 – Exemplo de rede neural tradicional com duas camadas ocultas (GHIASSI; SAIDANE; ZIMBRA, 2005).

Alguns trabalhos dedicam-se ao estudo de redes neurais construtivas. Baseiam-se em iniciar a rede com uma quantidade mínima de neurônios, adicionando dinamicamente mais neurônios e/ou camadas quando necessário. Em outros casos, a rede neural inicia com uma quantidade grande de elementos, e são utilizadas técnicas de poda para atingir o tamanho ideal. Recentemente, Ghiassi e Saidane (2005) propuseram uma nova arquitetura de rede neural. Essa nova arquitetura possui a vantagem de permitir que as camadas ocultas sejam ajustadas automaticamente.

2.5.1 Arquiteturas Dinâmicas de Redes Neurais

As arquiteturas dinâmicas de redes neurais, também conhecidas como métodos construtivos são algoritmos capazes de se ajustar automaticamente, sem a necessidade de intervenção do modelador para determinação de algum parâmetro (por exemplo, quantidade de camadas intermediárias, quantidade de neurônios na camada intermediária). Alguns

métodos consistem em começar com uma arquitetura mínima de rede e adicionar neurônios até que a solução adequada seja encontrada. Outras fazem o oposto, iniciando as camadas com dimensões elevadas e tendo suas unidades retiradas de acordo com os resultados obtidos, este método é conhecido como poda ou *prunning* (REED, 1993). Ambos os métodos possuem limitações, e os estudos atuais indicam que o procedimento mais adequado é um método híbrido contendo etapas construtivas, seguida de etapas de poda.

Ghiassi e Saidane (2005) desenvolveram uma proposta de arquitetura dinâmica chamada DAN2 (*Dynamic Architecture for Artificial Neural Networks*). A idéia geral do modelo é baseado no princípio de aprendizagem e acumulação de conhecimento em cada camada, propagando e ajustando o conhecimento para a próxima camada, e repetindo as etapas até que a performance desejada pela rede seja atingida. Segundo os próprios autores, a rede DAN2 classifica-se como um modelo puramente *feed-forward*.

Como na redes neurais clássicas, a arquitetura DAN2 é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Figura 4). A camada de entrada aceita dados externos para o modelo. Uma vez que os nós de entrada sejam identificados, todas as observações são usadas simultaneamente para treinar a rede. Os dados são normalizados para evitar problemas de diferentes unidades métricas.

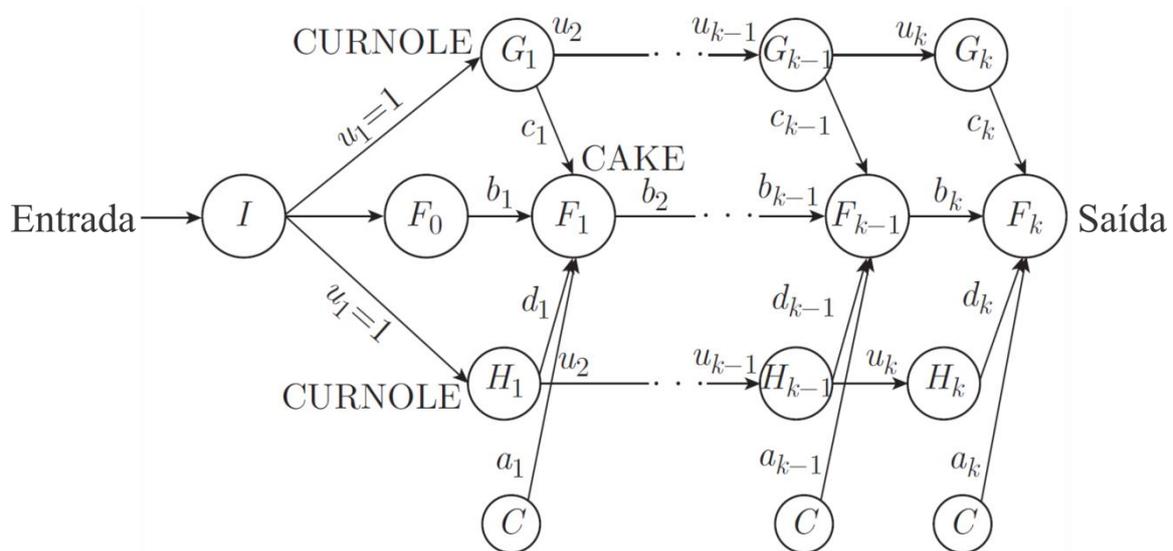


Figura 4 – Arquitetura do modelo DAN2 (GHIASSI; SAIDANE; ZIMBRA, 2005).

A próxima decisão de modelagem é a escolha do número de camadas ocultas e nós ocultos. Neste modelo, diferente das redes neurais clássicas, o número de camadas ocultas não é fixado a priori. Eles são gerados sequencialmente e dinamicamente até que o nível de acurácia seja atingido. Adicionalmente, a abordagem proposta usa um número de constante

de nós ocultos para cada camada escondida. Essa estrutura não é arbitrária, sendo justificada pela proposta de estimação. Em cada camada oculta, a rede é treinada usando todas as observações em um conjunto de treinamento simultaneamente, de modo a minimizar os erros. O primeiro nó é meramente uma constante de valor igual a 1, chamado de nó C. O segundo nó é consiste em uma função que encapsula o elemento de conhecimento acumulado atual e é chamado de CAKE, do inglês (*Current accumulated knowledge element*). O terceiro e quarto nós representam o componente não linear residual atual do processo, capturado através de uma função de transferência usando um somatório ponderado e normalizado das variáveis de entrada. Esses nós são chamados de CURNOLE (*current residual nonlinear element*).

O processo de treinamento começa com uma camada especial onde o nó CAKE captura o componente linear dos dados de entrada. Assim, sua entrada é uma combinação linear (somatório com pesos) de variáveis de entrada e um nó de entrada constante. Esses pesos são facilmente obtidos através de regressão linear. Se o nível desejado de acurácia é atingido, conclui-se que a relação é linear e o processo de treinamento é parado. Caso a relação seja não linear, novas camadas ocultas são adicionadas. Depois de capturar a componente linear dos dados de entrada no primeiro nó CAKE, o algoritmo transforma o conjunto de dados de entrada em um modelo de não linearidade do processo nas iterações subsequentes. O DAN2 utiliza a técnica da projeção vetorial para realizar a transformação de dados e consiste em projetar cada registro de observação em um vetor de referência para a normalização dos dados. A normalização é consiste na determinação dos ângulos entre cada registro i e o vetor de referência. DAN2 utiliza os ângulos para o treinamento e são atualizados a cada iteração.

Para avaliar o método, Ghiassi e Saidane (2005) aplicaram a rede neural para previsão de manchas solares, utilizando dados do período de 1700 a 1920. Os resultados mostraram ser 30% superiores aos estudos que utilizaram o mesmo conjunto de dados com redes neurais tradicionais. Em outro estudo, Ghiassi, Saidane e Zimbra (2005) aplicaram o DAN2 para previsão de séries temporais.

O trabalho consistiu em executar a previsão de três estudos clássicos da literatura: a previsão da quantidade de passageiros em um aeroporto internacional, a população de lincês canadenses, além do estudo sobre as manchas solares. A performance foi medida utilizando o erro quadrático médio (MSE) e o desvio médio absoluto (MAD). Os resultados obtidos foram comparados com os melhores resultados obtidos através do modelo ARIMA e do algoritmo tradicional FFBP. O conjunto de dados dos passageiros possui comportamento não linear,

além de possuir um comportamento de sazonalidade multiplicativo. Os dados dos lincos canadenses mostraram periodicidade de 10 anos com irregularidades na amplitude. O método DAN2 foi superior na maioria dos resultados comparados com os outros métodos, embora muito próximos. Segundo os autores, o DAN2 foi inferior em relação a alguns testes utilizando FFBP porque houve um excesso de treinamento na FFBP, e que isso raramente resulta em bons resultados.

Mais tarde, (GHIASSI; NANGOY, 2009) realizaram um extenso estudo sobre a eficiência do método DAN2, principalmente para processos não lineares. O estudo demonstrou que o método é eficiente em relações fracionárias (solução de regressão não linear para isomerização em química), relações multiplicativas e/ou aditivas (estimação de vitamina B2 relacionada a quantidade de radiação em uma planta), relações polinomiais (estimação na produção de madeira e lenha) e relações exponenciais (modelo de biodegradação relacionada a composição físicoquímica de óleos minerais).

O DAN2 também mostrou-se eficiente em problemas de classificação. Em um estudo, Ghiassi e Burnley (2010) encontraram resultados muito superiores (32%), aplicando o método DAN2 comparado a outros métodos. O estudo utilizou conjunto de dados sintéticos e reais, entretanto os melhores resultados foram obtidos com as séries sintéticas. Ghiassi, Zimbra e Saidane (2006) utilizaram o modelo DAN2 para previsão de cargas elétricas a médio prazo. O estudo apresentou erro de previsão (MAPE) abaixo de 1%. De acordo com os autores, apesar de as variáveis climáticas serem importantes para este tipo de previsão, essas informações nem sempre são confiáveis ou estão disponíveis. O DAN2 demonstrou que essas informações podem ser compensadas através do ajuste dos erros inerente ao próprio modelo construtivo.

Posteriormente, Wang, Niu e Li (2010) realizaram um estudo semelhante em Taiwan visando a previsão a médio e longo prazo. O estudo comparou os modelos DAN2, ARIMA, SVM com algoritmos genéticos e SVM com algoritmos imunes. O modelo DAN2 apresentou a melhor performance em relação aos outros métodos. Gomes et al. (2006) propuseram um modelo híbrido com arquitetura dinâmica utilizando o DAN2 e o modelo ARIMA. O estudo demonstrou um resultado superior em relação a cada método utilizado separadamente. Segundo os autores, a utilização de dois métodos pode levar a resultados mais próximos do real, principalmente em casos em que a série de dados observados for insuficiente ou com pouca qualidade.

Na área de sistemas de abastecimento de água, existem diversos estudos que utilizam redes neurais artificiais tradicionais, no entanto, ainda existem poucos que utilizam o modelo DAN2. Ghiassi, Zimbra e Saidane (2008) aplicaram o modelo DAN2 para previsão de demandas de água para curto, médio e longo prazo. Assim como no estudo realizado por Ghiassi, Zimbra e Saidane (2006), os autores demonstraram que fatores exógenos como variáveis climáticas não precisam ser explicitadas no modelo para que se obtenha uma boa previsão com o uso do DAN2. A previsão realizada apresentou acurácia de 99% para períodos de um dia e acima de 97% para previsões horárias.

Islam et al. (2009) desenvolveram um algoritmo para construir RNAs denominado “Adaptive Merging and Growing Algorithm” (AMGA). O algoritmo usa mecanismos de mescla e adição de neurônios da camada intermediária, baseando-se no progresso e na habilidade de aprendizado dos neurônios dessa camada. A mescla é realizada entre neurônios com repostas correlacionadas entre si, enquanto que a adição divide o neurônio em dois, de modo a reaproveitar o treinamento anterior e reduzir o treinamento necessário após a modificação. Este algoritmo pode ser aplicado a diversos tipos de RNAs, sendo que neste trabalho será aplicado a RNA “feedforward” com algoritmo de treinamento Backpropagation com o termo momentum, o qual confere maior velocidade ao treinamento sem prejudicar a estabilidade do mesmo.

3 MATERIAIS E MÉTODOS

Neste capítulo são descritos os materiais e métodos utilizados no desenvolvimento e avaliação do sistema de calibração proposto. A Figura 5 mostra resumidamente as etapas do trabalho, que compreendem a construção do modelo dos setores de rede a serem calibrados, a determinação dos pontos de monitoramento internamente a cada setor, a aquisição de dados de campo, a implementação das RNAs, a criação de padrões de treinamento para as RNAs e a calibração propriamente dita. Cada qual dessas etapas pode ser expandida em sub-etapas, conforme descrição das seções seguintes.

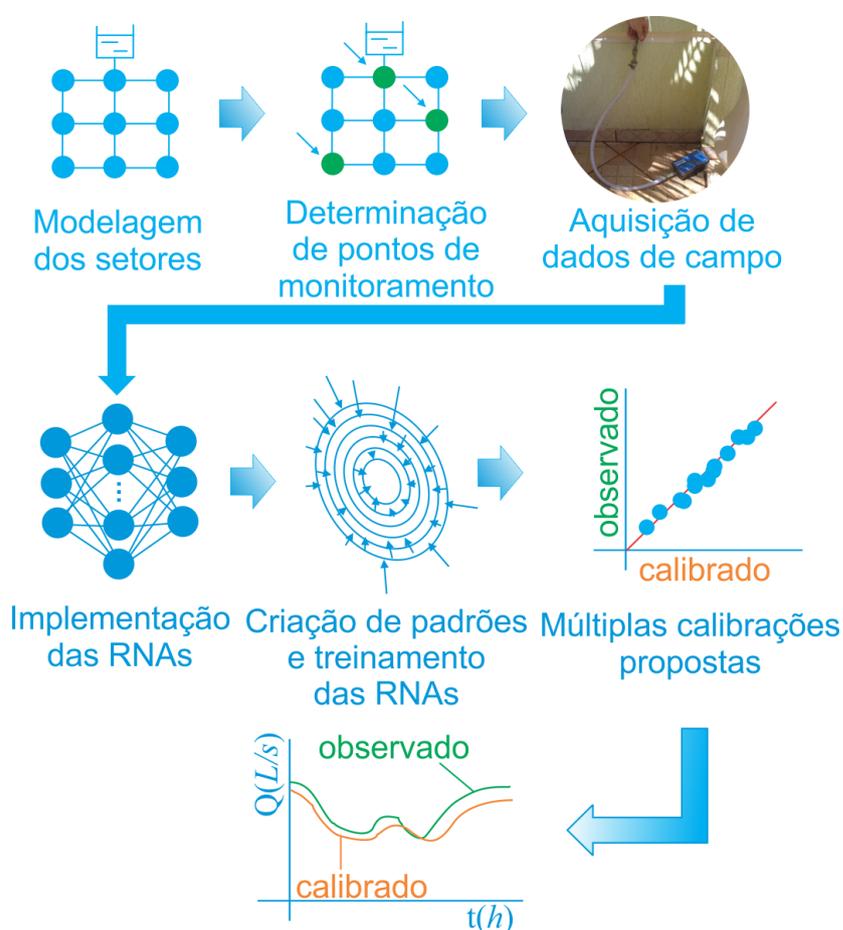


Figura 5 – Etapas do novo sistema da calibração proposto

A primeira parte do trabalho consistiu na modelagem de quatro setores de abastecimento reais que foram usadas para o teste do calibrador (Figura 5). A Seção 3.1 descreve como foi realizada esta etapa. Também descreve como foi realizada a correção dos erros de modelagem e a redução da incerteza atribuída aos valores de demanda dos consumidores.

Conforme foi descrito na revisão, os diversos pontos da rede apresentam maior ou menor grau de sensibilidade as cargas de pressão. Portanto, foi necessário estabelecer a melhor localização dos pontos para realização do monitoramento, através de análises de incerteza em pontos da rede. A Seção 3.2 descreve como foi desenvolvido o sistema para determinação da rede de monitoramento de carga de pressão para os setores de estudo.

Na Seção 3.3 foram descritas as atividades que envolveram a aquisição dos dados de carga de pressão nos pontos de monitoramento, além de descrever como foram obtidos os valores de vazão dos setores de rede de estudo. Nesta seção também foram analisadas e discutidas as incertezas que foram incorporadas aos dados, devido à influencia da instalação dos equipamentos em ramais residenciais.

A Seção 3.4 traz uma descrição detalhada das redes neurais construtivas utilizadas, a justificativa para a escolha destes tipos de redes, bem como testes realizados para avaliar o desempenho das mesmas.

Na Seção 3.5 são descritos o software gerador de padrões de treinamento das RNAs, o processo para criação dos padrões, as variáveis de entrada do modelo e as as variáveis de decisão da calibração.

Na seção 3.6 descrevem-se os detalhes dos dois métodos de calibração propostos, além do método de calibração tradicional.

3.1 Modelagem das redes de abastecimento

Para testar a proposta de calibração, foi escolhido o EPANET como software de simulação hidráulica. Os modelos das redes de abastecimento construídos foram convertidos para o formato de arquivo do EPANET a partir de plantas do AUTOCAD, utilizando o software EPACAD (OLIVARES, 2009). Apesar do EPACAD propiciar economia de tempo na modelagem, os modelos gerados necessitam de revisões, pois frequentemente trazem erros de conversão. As revisões através de inspeção visual requerem trabalhos repetitivos de simulação e correção e, em muitos casos, pode haver falha humana na detecção dos erros. Estas tarefas podem ser automatizadas através do uso de técnicas de visão computacional. Optou-se, portanto, pelo desenvolvimento de um software para correção automática de modelos do EPANET convertidos através do EPACAD, para a sua posterior aplicação aos setores de estudo.

As plantas hidráulicas de quatro setores de rede de abastecimento da cidade de Araraquara – SP , desenhadas no AutoCAD (Figura 6), foram fornecidas pelo Departamento Autônomo de Água e Esgoto do Município - DAAE Araraquara no âmbito do convênio EESC/USP x DAE.



Figura 6 - Plantas hidráulicas dos setores de abastecimento de Araraquara

Em seguida, as plantas foram convertidas pelo software EPACAD, resultando em quatro arquivos de rede do Epanet. A rede 1 (Iguatemi Zona Alta) possui 456 nós e 438 trechos com 15722,72 m de extensão. A rede 2 (Iguatemi Zona Baixa) possui 1141 nós e 1196 trechos e 36 km de extensão, a rede 3 (Eliana) possui 270 nós, 263 trechos e extensão de 89 km e a rede 4 (Martinez) possui 1128 nós, 1097 trechos e 61 km de extensão. Os arquivos de rede do Epanet são arquivos em formato texto que possuem todas as informações

de entrada necessárias para as simulações do modelo hidráulico e podem ser modificados via editor de texto ou programação.

Após a conversão, os arquivos precisaram de adequações. O EPACAD somente cria o traçado básico do modelo, adicionando os trechos e nós obtidos da planta do AUTOCAD. Assim, foi necessária a adição de um reservatório de nível fixo (RNF) nos arquivos, diretamente através do Epanet. Os RNFs não precisaram estar locados corretamente, pois nesta etapa do trabalho, não existe a preocupação de que os modelos produzam valores confiáveis. Os reservatórios foram adicionados somente para evitar erros nos arquivos de entrada, pois um dos pré-requisitos para os cálculos de simulação do modelo é a existência de no mínimo um reservatório.

De posse dos modelos funcionais do Epanet, iniciou-se a etapa da verificação dos tipos de erros gerados pelo EPACAD. O Epanet possui uma *toolkit* de programação que permite o desenvolvimento de softwares personalizados, alterando diversos parâmetros, além de permitir simular e obter dados sem a necessidade do uso da interface gráfica do Epanet. Entretanto, a *toolkit* não possui mecanismos para adicionar e excluir nós e trechos e não fornece as coordenadas (x,y) dos nós da rede. Como essas funcionalidades seriam necessárias para a correção dos erros no modelo, implementou-se um código para leitura e escrita diretamente no arquivo do modelo da rede. Para cada tipo de erro foi proposta uma solução. Um software foi desenvolvido em linguagem C para o propósito específico de determinação dos vários tipos de erros e suas correções. Os tipos de erros e as soluções propostas são listados a seguir.

NÓS COM COORDENADAS COINCIDENTES

O EPACAD percorre cada *polyline* do desenho criado no AutoCAD e converte a linha em um trecho de rede no arquivo de entrada do Epanet. O início e o final das *polylines* são convertidos em nós. Nos casos em que o projetista se esquece de unir as duas linhas, é criado um nó adicional, fazendo com que dois trechos que deveriam estar unidos sejam criados desconectados. A Figura 7 exemplifica o erro dos nós duplicados. O nó n_2 de coordenadas (x_2, y_2, z_2) possui as mesmas coordenadas (x_3, y_3, z_3) do nó n_3 , ou seja, $x_2=x_3, y_2=y_3, z_2=z_3$. Neste exemplo, O EPACAD gerou erroneamente dois trechos desconectados. O trecho que liga o n_4 deveria ser ligado diretamente a n_2 . Entretanto, foi criado um nó adicional (n_3) com as mesmas coordenadas que n_2 . A criação de n_3 , além de desnecessária, produz erros na

simulação ou falsos resultados, pois como não existe ligação entre os dois trechos, o modelo considera que não existe percurso de água por este caminho.

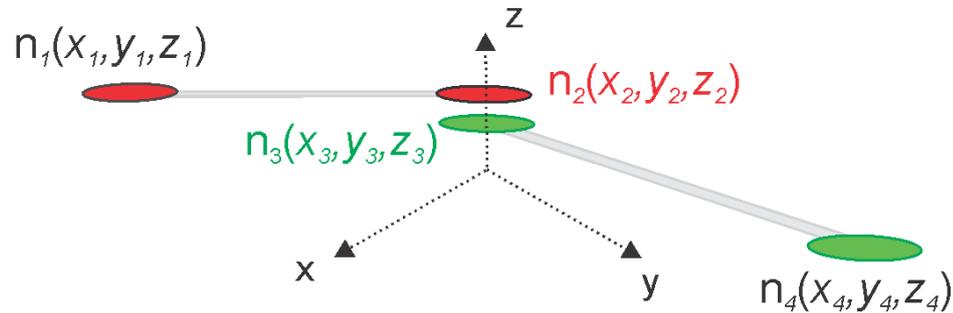


Figura 7 - Nós com coordenadas coincidentes, no caso, $n_2(x_2, y_2, z_2) = n_3(x_3, y_3, z_3)$

O algoritmo para resolução deste erro consistiu em:

- (i) Inicializar um vetor vazio *vcc* de coordenadas;
- (ii) armazenar os identificadores dos nós (ID) com coordenadas coincidentes em *vcc*;
- (iii) Enquanto vetor *vcc* possuir elementos, percorrer os trechos das redes obtendo os IDs dos nós iniciais e finais;
- (iv) se nó inicial ou nó final do trecho atual está contido no vetor de coordenadas coincidentes *vcc*, substituir o nó do trecho coincidente (inicial ou final) pelo próximo nó coincidente de mesmas coordenadas de *vcc*; excluir elemento atual de *vcc*;
- (v) Fim do Enquanto

A Figura 8 ilustra o resultado da correção para o erro de nós com coordenadas duplicadas. Com a aplicação do algoritmo, o trecho com o nó n_3 passa a ser ligado diretamente ao nó n_2 .

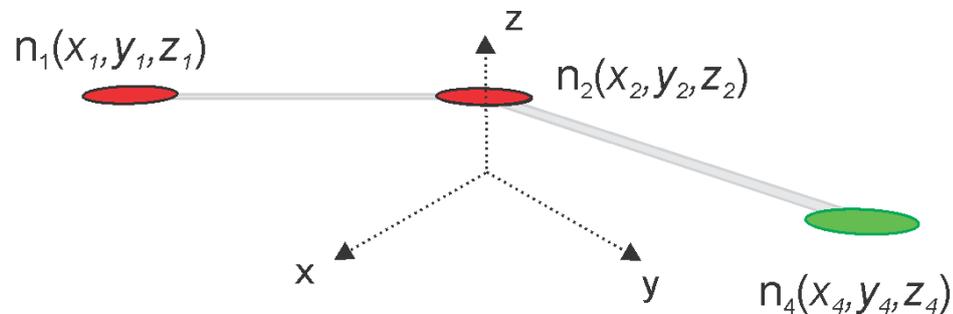


Figura 8 - União de trechos com nós duplicados

NÓS ERRONEAMENTE ADICIONADOS

Frequentemente, o desenhista precisa utilizar quebras nas *polylines* para representar curvas. Cada quebra nas *polylines* são convertidas em nós no Epanet. A Figura 9(a) ilustra um exemplo de nós criados erroneamente. A Figura 9(b) mostra o trecho com os nós reais.



(a) Nós erroneamente adicionados



(b) Nós corretos

Figura 9 - Conversão de quebras de *polylines* em nós

A princípio, a remoção dos nós extras parece trivial, entretanto, à medida que redes de maiores dimensões são consideradas, essa atividade pode consumir tempo considerável. O algoritmo proposto para automatizar o processo da remoção dos nós adicionais consiste em:

- (i) *Localizar todos os trechos com comprimentos muito pequenos (<50 m);*
- (ii) *Enquanto existirem trechos menor que 50 m, **repetir**:*
- (iii) *Armazenar parametros do trecho curto (comprimento, diametro e coeficiente de rugosidade);*
- (iv) *Localizar trecho adjacente e armazenar os parâmetros;*
- (v) *Testar se trecho curto pode ser unido ao trecho adjacente. Se sim, continuar, senão pular para etapa x. Os detalhes dos parâmetros testados são descritos após o algoritmo.*
- (vi) *Remover nó que liga os dois trechos adjacentes;*
- (vii) *Remover os dois trechos;*
- (viii) *Adicionar trecho ligando os dois nós remanescentes;*
- (ix) *Atualizar o comprimento do trecho adjacente para comprimento do trecho adjacente + comprimento do trecho curto.*
- (x) *Atualizar lista de trechos menores do que 50 m.*
- (xi) *Fim do **Repetir***

Existe a dificuldade na classificação automática dos nós reais e dos nós extras a serem removidos. Para efetuar o teste (etapa v do algoritmo), adotaram-se algumas considerações:

1. Os trechos candidatos a remoção ou trechos curtos devem possuir menos de 50 m de comprimento. Valores maiores do que 100 podem levar a perda de informação, pois é o comprimento de uma quadra padrão. A Figura 10 ilustra a remoção de um nó que une trechos de 1,1 m de comprimento e outro trecho de 1,3 m.

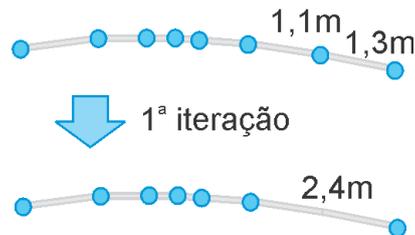


Figura 10 - Remoção de nós extras

2. Nós que unem trechos de materiais ou diâmetros diferentes devem ser mantidos. Na Figura 11, o nó foi mantido, pois, apesar do comprimento pequeno do trecho (2m), o nó candidato une dois trechos de diâmetros diferentes (100mm e 150mm de diâmetro).



Figura 11 - Nó candidato rejeitado para remoção

3. Quando o ângulo formado entre o nó candidato à remoção e os dois nós adjacentes for diferente de ângulo raso + liminar ($\pm 5^\circ$ determinado empiricamente) não remover o nó, para evitar deformação no traçado da rede (Figura 12).

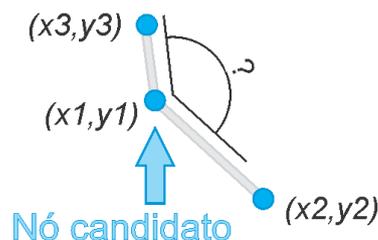


Figura 12 - Verificação do ângulo do nó candidato

Os ângulos foram determinados através da lei dos cossenos (Equação 11).

$$\alpha = \cos^{-1} \left(-\frac{(|x_2 - x_3| + |y_2 - y_3|)^2 - (|x_2 - x_1| + |y_2 - y_1|)^2 - (|x_3 - x_1| + |y_3 - y_1|)^2}{2(|x_2 - x_1| + |y_2 - y_1|) \cdot (|x_3 - x_1| + |y_3 - y_1|)} \right) \quad (11)$$

sendo:

α : ângulo formado entre o nó candidato e os nós adjacentes.

(x_1, y_1) : coordenadas do nó candidato.

(x_2, y_2) e (x_3, y_3) : coordenadas dos nós adjacentes.

A Tabela 6 lista os resultados obtidos pela execução do software. As primeiras colunas apresentam as características das redes originais e as demais colunas exibem os respectivos valores relativos às “Redes corrigidas”, ou seja, após a correção dos erros.

Tabela 6 - Comparação entre os valores das redes originais e as redes corrigidas

Redes	Redes Originais		Redes corrigidas	
	Trechos	Nós	Trechos	Nós
Iguatemi ZA	438	456	394	374
Iguatemi ZB	1196	1141	1092	942
Eliana	263	270	244	218
Martinez	1097	1128	1031	883

A Tabela 7 foi criada para melhor visualização das diferenças entre as características das redes originais e das respectivas redes corrigidas. A diferença numérica significa a subtração simples entre os valores originais e corrigidos e a diferença percentual é razão percentual entre o erro absoluto e os valores das redes corrigidas. Observa-se que os maiores erros absolutos na quantidade de trechos foram verificadas na rede 3 e na quantidade de nós na rede 4. As redes 3 e 4 são as que apresentam maior quantidade de trechos e nós. Entretanto, analisando a diferença percentual, percebe-se que os erros não seguem um padrão de acordo com o tamanho da rede, pois a quantidade de erros gerados na conversão depende mais da qualidade do desenho da rede no AutoCAD do que de sua extensão.

Tabela 7 - Subtração entre o número de elementos da rede original e da rede corrigida

Redes	Diferença numérica		Diferença %	
	Trechos	Nós	Trechos	Nós
Iguatemi ZA	19	52	7.79	3.85
Iguatemi ZB	44	82	11.17	1.92
Eliana	104	199	9.52	1.12
Martinez	66	245	6.40	7.75

A localização e correção de erros na conversão de desenhos para modelos de redes de abastecimento é uma tarefa fundamental. Nós com coordenadas coincidentes devem ser excluídos, caso contrário produzirão falsos resultados nas simulações, pois farão com que se alterem os percursos do fluido, alterando também as vazões e cargas de pressões produzidas pelo modelo. O outro tipo de erro encontrado (nós erroneamente adicionados) não são problemas críticos se o objetivo é ter um modelo funcional. Entretanto, se o modelo for utilizado com o intuito de executar otimização, necessária, por exemplo, à calibração ou determinação de planos de operação ótimos, é necessário que se eliminem os nós extras, devido ao incremento no tempo computacional, pois, tipicamente, são realizadas dezenas ou centenas de milhares de simulações. Para ambos os casos, o software criado demonstrou ser eficaz na tarefa de eliminação dos erros.

3.1.1 Alocação e redução da incerteza nas demandas

As demandas dos consumidores foram fornecidas pela companhia de saneamento, exportadas para planilhas a partir do banco de dados da companhia. As planilhas possuem informações de endereço, número da quadra, lote, matrícula e leitura mensal dos hidrômetros. Outros dois softwares foram desenvolvidos para automatizar o processo de alocação de demandas aos nós: um deles com a finalidade de determinar as coordenadas do centróide de cada lote nas plantas do AutoCAD, em linguagem LISP. Em seguida, o outro software calcula o consumo mensal de cada matrícula através da diferença de leitura entre dois meses consecutivos e localiza o nó adequado, ou seja, o nó mais próximo da centróide da matrícula. O EPANET exige que sejam inseridos valores de demandas base em cada nó, sendo que os

consumos em regimes transientes são calculados a partir da multiplicação das demandas base por fatores horários. Como o intervalo de medição dos valores de consumo é mensal, usualmente determina-se a demanda diária do nó através da equação $d_i = \frac{m_i}{30}$, sendo d_i a demanda média diária para o nó i , e m_i a demanda mensal. De posse das vazões na saída dos reservatórios pode-se analisar estatisticamente e melhor distribuir os dados ao longo da semana, diminuindo os erros de estimação de demanda no modelo.

Os dados de vazões foram obtidos através do sistema de telemetria do DAAE Araraquara nos dias correspondentes às campanhas de campo realizadas, com exceção do setor Martinez, pois houve falha no medidor de vazão nos dias em que foi realizada a campanha no setor. Para a modelagem e calibração deste setor foram utilizados os últimos registros disponíveis antes da falha do medidor.

A Figura 13 mostra o gráfico das vazões da entrada do setor Iguatemi ZA. Nota-se que, visualmente, existe pouca variação no consumo durante os dias da semana, entretanto houve falha na medição em determinados períodos no sábado (3 às 5, 12 às 14 e às 18h) e no domingo (1 às 2). As falhas foram preenchidas utilizando-se a média das vazões horárias dos dias da semana correspondente.

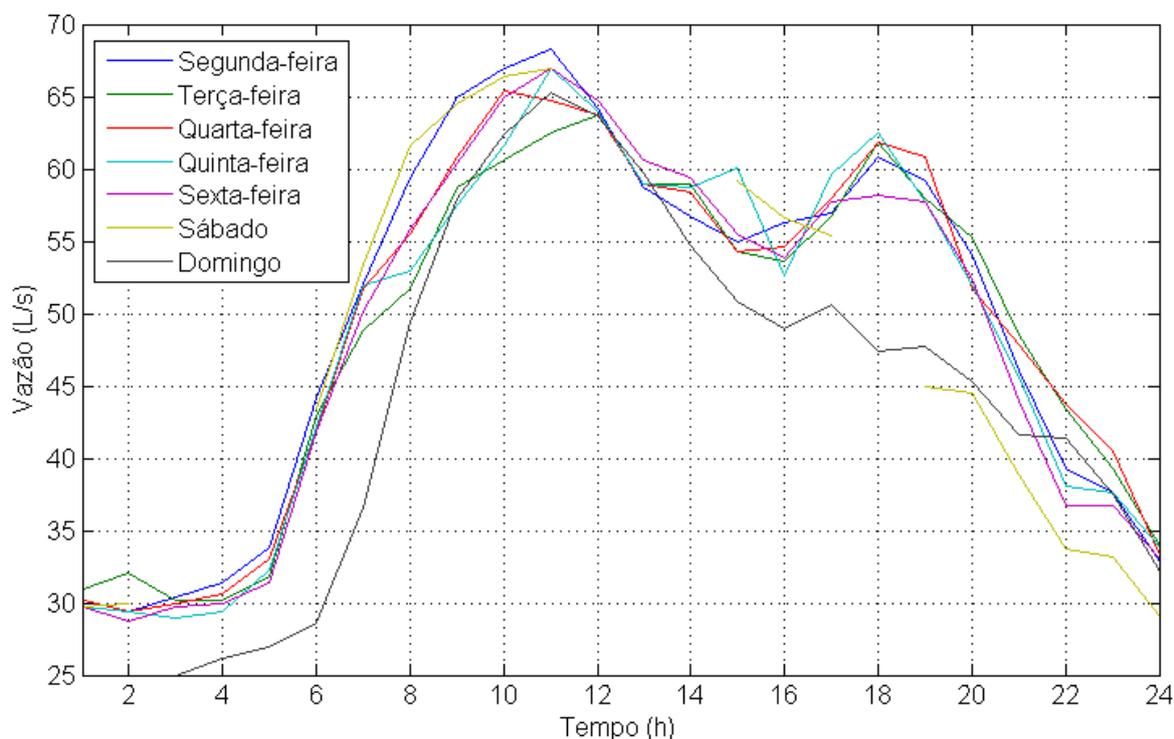


Figura 13 – Vazões obtidas através de telemetria no período de 18/03/2013 a 25/03/2013 na entrada do setor Iguatemi ZA. Não há medições no dia 21/03.

Diferentemente do primeiro setor, no reservatório R3 (setor Iguatemi ZB), existe um aumento perceptível do consumo na sexta-feira e no sábado, conforme ilustrado na Figura 14.

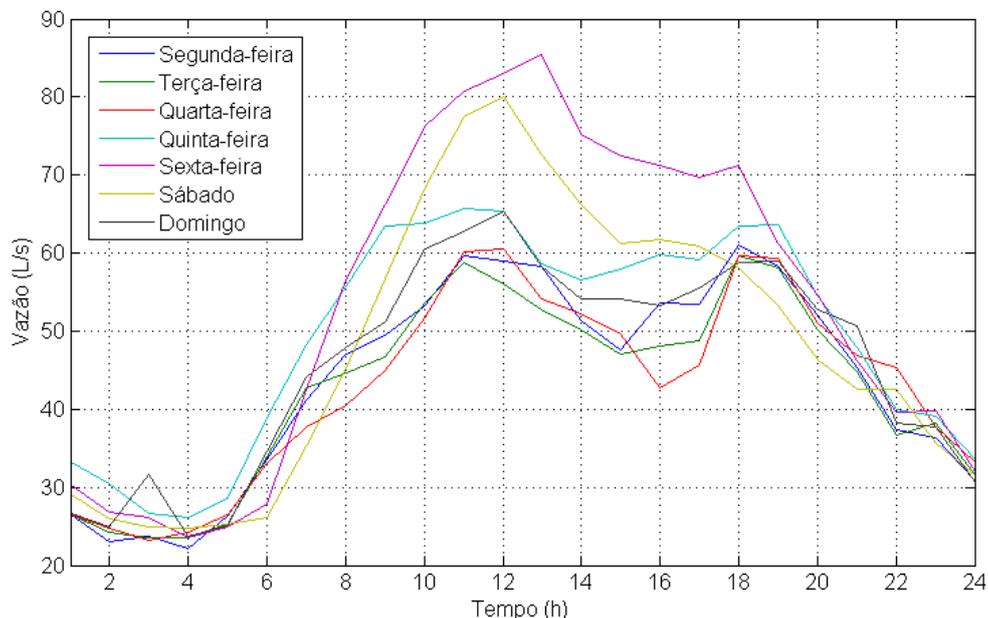


Figura 14 – Vazões obtidas através de telemetria no período de 18/02/2013 a 25/02/2013 na entrada do setor Iguatemi ZB.

O consumo de água no setor Eliana apresenta padrão de consumo distinto dos outros três. Neste setor, verificam-se picos constantes de consumos, seguidos por intervalos de baixo consumo, resultantes de indústrias locais (Figura 15).

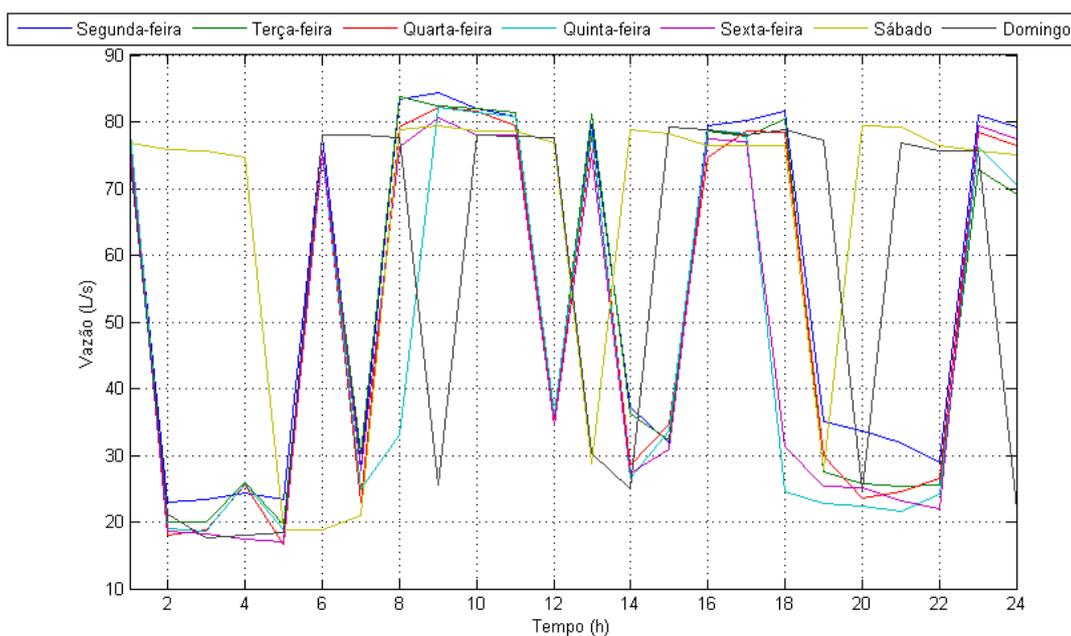


Figura 15 – Vazões obtidas através de telemetria no período de 04/03/2013 a 11/03/2013 na entrada do setor Eliana.

Assim como no setor Iguatemi ZB, o setor Martinez apresenta consumo maior de água no sábado comparado aos dias úteis, caracterizando um setor residencial (Figura 16).

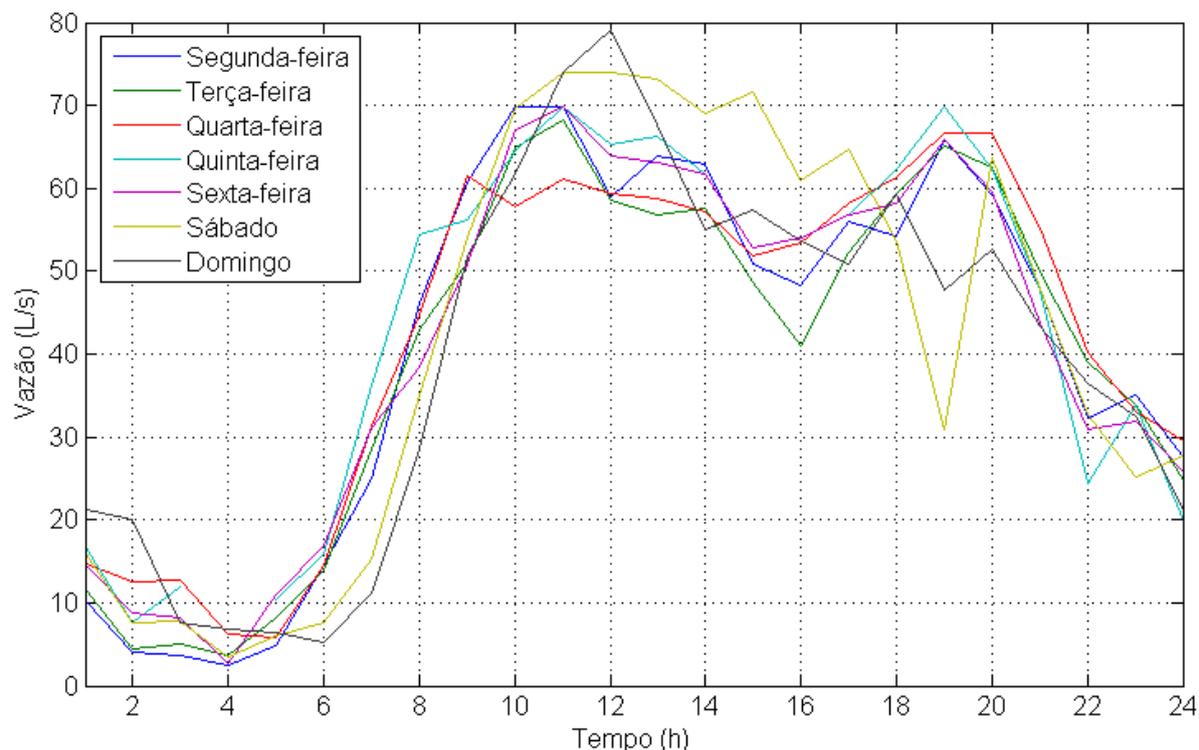


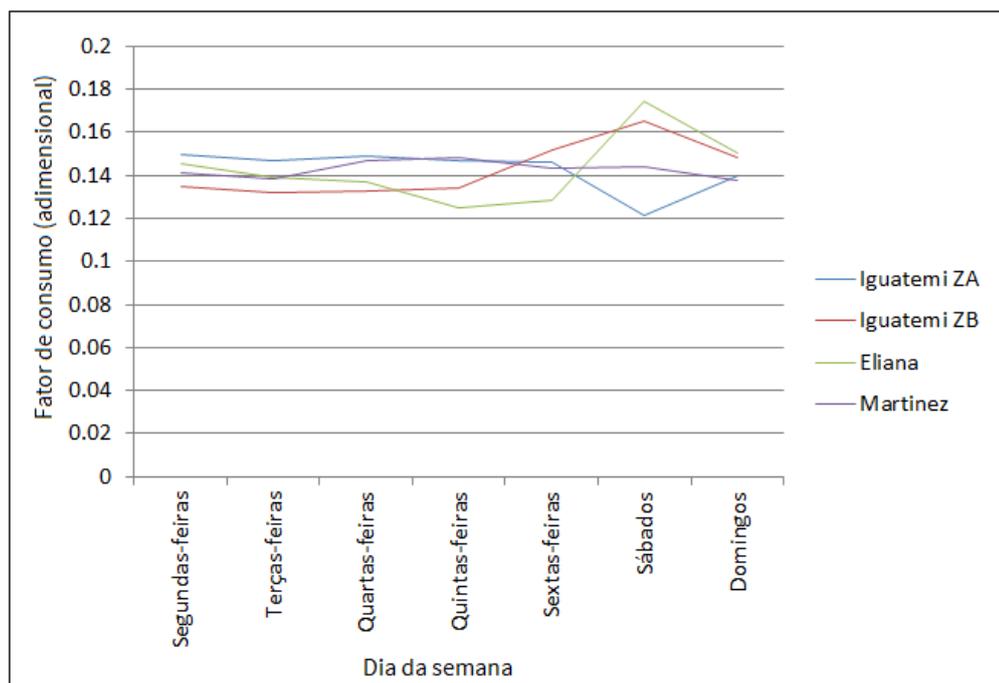
Figura 16 – Vazões obtidas através de telemetria no período de 25/02/2013 a 04/03/2013 na entrada do setor Martinez.

O levantamento das vazões semanais permitiu a verificação da tendência do consumo nos dias da semana, através do cálculo do volume médio diário. Isso possibilitou a correção da proporção adequada para a alocação de demandas, reduzindo a incerteza do modelo. Tipicamente, divide-se o volume de água mensal medido por trinta, chegando-se no valor médio diário consumido. Uma equação mais realística para o cálculo da demanda utilizada foi $d_i = \frac{V}{n_s f_s}$, sendo d_i o volume de água consumido no dia i ; V é o volume mensal de água do setor; n_s é a quantidade total de dias da semana no mês correspondente ao i -ésimo dia (e.g. se o dia 5 de março é em uma terça-feira, contar quantidade de terças-feiras do mês de março); e f_s , o fator de consumo proporcional semanal. A Tabela 8 lista as proporções obtidas para os consumos. A proporção média diária esperada é de $1/7$ ou $0,1428$.

Tabela 8 – Proporções de consumo de acordo com os dias da semana.

Dia da semana	Iguatemi ZA	Iguatemi ZB	Eliana	Martinez
Segunda-feira	0,149	0,135	0,145	0,141
Terça-feira	0,146	0,132	0,139	0,138
Quarta-feira	0,148	0,132	0,137	0,147
Quinta-feira	0,146	0,134	0,124	0,148
Sexta-feira	0,146	0,152	0,128	0,143
Sábado	0,121	0,165	0,174	0,143
Domingo	0,140	0,148	0,150	0,138
Σ	1	1	1	1

A Figura 17 ilustra as proporções obtidas. Observa-se que no setor Iguatemi ZA (linha azul), o consumo se mantém constante durante os dias úteis e é reduzido durante o sábado e domingo. Já no setor Iguatemi ZB (linha vermelha), ocorre o oposto, havendo um incremento no consumo durante o fim de semana a partir da sexta-feira. O comportamento do consumo do setor Eliana (linha verde) é semelhante ao consumo do setor Iguatemi com consumos menores durante os dias úteis e aumento do consumo no sábado e domingo. O setor Martinez apresentou o consumo mais uniforme durante toda a semana.

**Figura 17 – Gráfico adimensional do consumo semanal**

A partir das medições de vazão do período, foram calculadas faixas de intervalo de confiança supondo uma distribuição de probabilidades normal ($\alpha = 95\%$) para cada um dos quatro setores utilizando os 7 valores dos horários correspondentes. As Figuras 18-21 mostram a faixa de intervalos obtidos. A linha pontilhada mostra os desvios padrão ao longo do tempo. Esta linha mostrou que, em geral, os desvios tendem a variar mais nos horários de maior consumo. A Figura 20 mostra a vazão de entrada da rede Eliana. O padrão diferenciado, quando comparado com os outros setores, deve-se ao fato de que, para o período considerado, durante determinadas horas do dia (6h – 8h; 11h – 12h; 15h – 22h), o reservatório do setor abastece simultaneamente os setores Eliana e Martinez. Para a realização da calibração do setor Eliana, explicado posteriormente, levou-se em consideração o padrão de consumo do conjunto Eliana-Martinez para que os dados de todas as horas do dia pudessem ser utilizados na calibração.

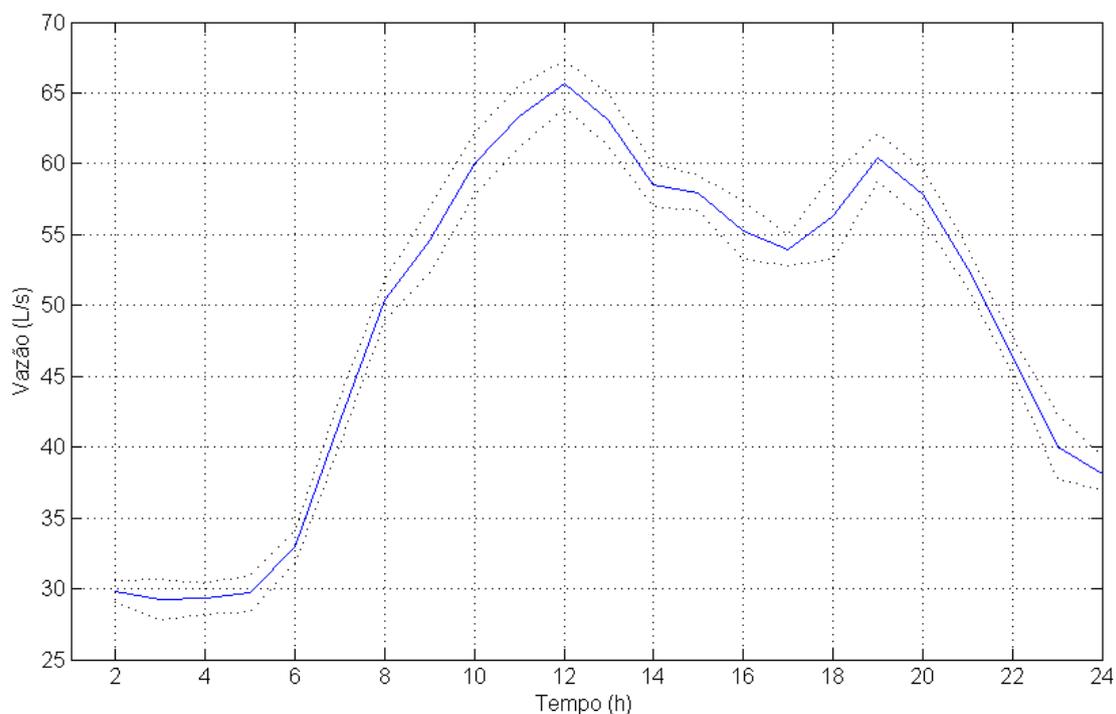


Figura 18 – Intervalos de confiança para as vazões na rede Iguatemi ZA, com 95% de confiança.

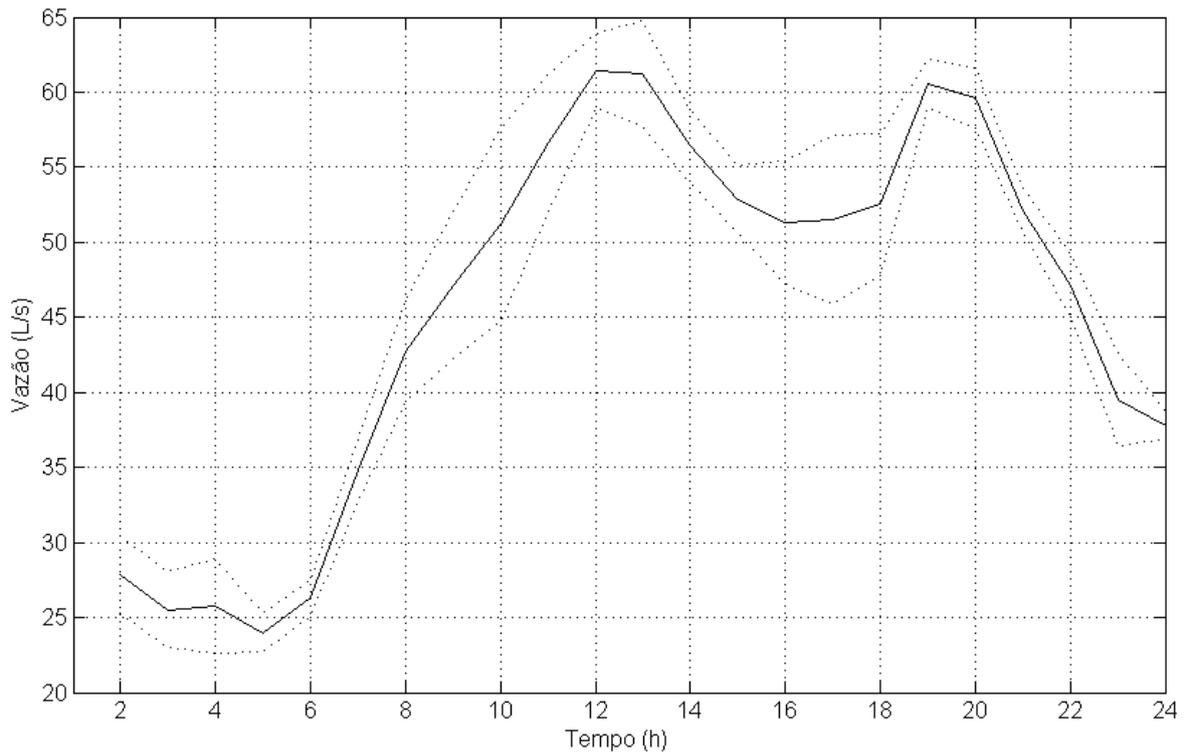


Figura 19 – Intervalos de confiança para as vazões na rede Iguatemi ZB, com 95% de confiança.

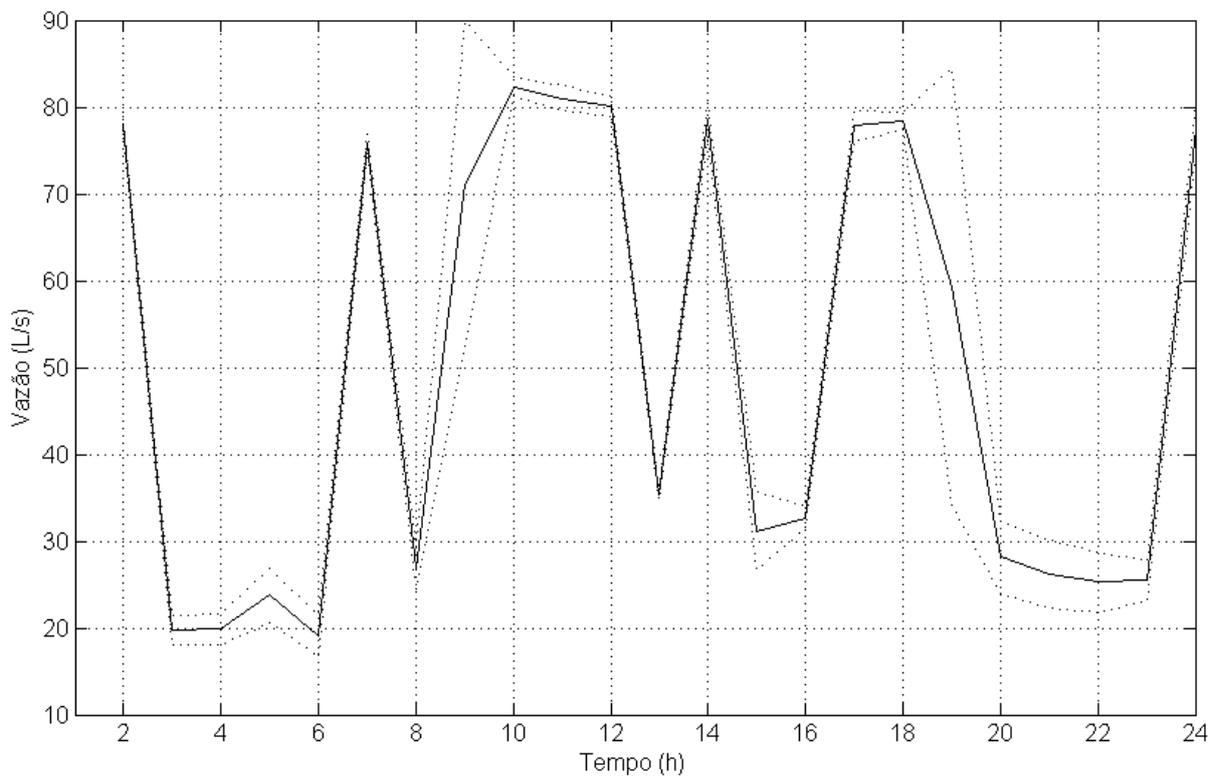


Figura 20 – Intervalos de confiança para as vazões na rede Eliana, com 95% de confiança.

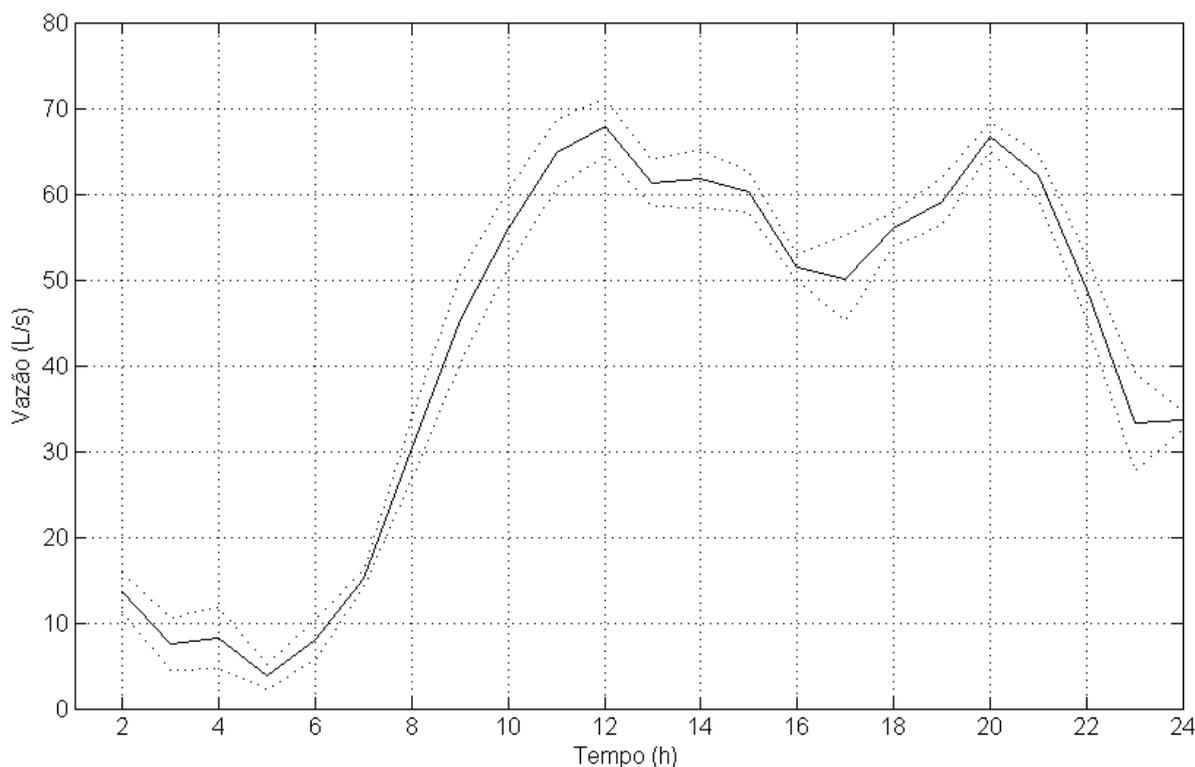


Figura 21 – Intervalos de confiança para as vazões na rede Martinez com 95% de confiança.

3.2 Determinação de pontos de monitoramento

Após a eliminação dos erros nos modelos, foram construídos os modelos funcionais, que ainda necessitavam ser calibrados. Nesta etapa, foi desenvolvido um software responsável por determinar as redes de monitoramento de carga de pressão otimizadas a serem implantadas na ocasião das campanhas de campo, levando-se em consideração a sensibilidade dos pontos às rugosidades. O *software* Epanet (ROSSMAN, 1999) foi utilizado para a simulação hidráulica das redes. A determinação dos pontos foi realizada utilizando o método da entropia de Shannon, proposto por De Schaezen et al. (2000) pelas razões já expostas, em linguagem C++. O método consiste em identificar um conjunto ótimo de monitoramento maximizando a função de sensibilidade e a entropia de Shannon. A função usada fornece a medida da sensibilidade da carga de pressão em n nós à variação nos coeficientes de rugosidade de m trechos a serem determinados através do processo. Os valores para cada uma das duas funções são calculados e ordenados usando uma matriz. A matriz, chamada matriz de sensibilidade, de dimensões $n \times m$, sendo n o número de nós e m o número de trechos no modelo. Kapelan (2000) lista diferentes métodos para o cálculo dos coeficientes da matriz de sensibilidade. Neste trabalho foi utilizado o método da aproximação

por diferenças finitas por ser de fácil implementação computacional e produzir resultados muito próximos aos dos métodos analíticos. Segundo este método, cada coeficiente é aproximado por diferenças finitas a partir de valores iniciais de rugosidade de Hazen-Willians C teóricos. Cada elemento é definido como:

$$\left| \frac{\partial H_i}{\partial C_j} \right| \cong \left| \frac{H_i(C_j) - H_i(C_j^*)}{C_j - C_j^*} \right| \quad \forall i \in [1, n], \forall j \in [1, m]. \quad (12)$$

$H_i(C_j)$ é a carga de pressão simulada no nó i para o coeficiente de rugosidade assumida C_j do trecho j e $H_i(C_j^*)$ é a carga de pressão simulada no nó i , após alterar o coeficiente de rugosidade assumida C_j do trecho j para C_j^* . No estudo, inicialmente considerou-se $C_j^* = C_j + 1$ para todos os trechos (adotando o coeficiente de perda de carga de Hazen-Willians).

Fisicamente, as derivadas parciais na Equação (12) representam a variação da carga de pressão no nó i para uma dada variação do coeficiente de rugosidade em um trecho j , i.e. a sensibilidade de H_i a uma pequena variação em C_j . O número de simulações hidráulicas necessárias para produzir a matriz de sensibilidade é $m + 1$, sendo m o número total de trechos. Segundo este método, define-se um plano de amostragem X como sendo um conjunto discreto de k pontos de monitoramento definido como: $X = (n_1, \dots, n_k)$.

O mérito de um plano de amostragem candidato X é avaliado usando uma função objetivo $F(X)$. O conjunto de k pontos de monitoramento escolhidos do total de n nós é definido como X_k . A função $F(X)$ é composta por duas outras funções $F_1(X)$ (Equação 13) e $F_2(X)$ (Equação 14). As funções são combinadas através da programação por compromisso. A primeira função a ser maximizada é:

$$F_1(x) = \sum_{j=1}^m a_j, \quad a_j = \max_{i \in X_k} \left| \frac{\partial H_i}{\partial C_j} \right| \quad \forall j \in [1, m] \quad (13)$$

$F_1(X)$ tende a selecionar o conjunto X mais sensível às mudanças nos valores dos coeficientes de rugosidades. a_j é o maior coeficiente de sensibilidade do trecho j do conjunto X_k . Um limite superior de F_1 , definido como $F1_{max}$, é deduzido da matriz por relaxação i.e. definindo $k = n$. Um limite inferior, definido como $F1_{min}$, assumido igual a 0.

A segunda função é a entropia (Equação 14), que define o espalhamento dos pontos de monitoramento do plano de amostragem X , dada por:

$$F_2(x) = - \sum_{j=1}^m p_j \ln p_j, \quad \text{sendo } p_j = \frac{a_j}{\sum_{j=1}^m a_j} \quad \forall j \in [1, m]. \quad (14)$$

A segunda função tende a selecionar um plano de amostragem X que proporciona o melhor espalhamento dos coeficientes de rugosidades dos trechos. Um limite superior de F_2 , definido como $F2_{\max}$, é igual a $\ln(m)$ e não é garantido que exista para a matriz dada. Um limite inferior, definido como $F2_{\min}$, é assumido igual a 0. A função de Shannon pode assim ser usada como uma medida de igualdade ou espalhamento uniforme dos números $(p_1, \dots, p_j, \dots, p_m)$, pois quanto mais próximo da igualdade esses números estão ou mais espalhados, maior é o valor *da entropia*.

As duas funções a serem maximizadas são então combinadas usando programação por compromisso. Uma solução de compromisso é definida como uma solução próxima, por alguma medida de distância, de uma solução ideal $(F1_{\max}, F2_{\max})$ que simultaneamente otimize ambos os objetivos, sendo a solução ideal geralmente inactível.

A função objetivo utilizada para a programação por compromisso foi:

$$F(X) = \sqrt{\sum_{i=1}^2 w_i \left(\frac{F_i(X) - F_{i\max}}{F_{i\min} - F_{i\max}} \right)^2}, \quad (15)$$

sendo w_i um coeficiente de peso da i -ésima função, $F_i(X)$ é o valor da i -ésima função e $F_{i\min}$ e $F_{i\max}$ são os limites inferior e superior da i -ésima função.

A Figura 22 ilustra uma rede hipotética usada para exemplificar os cálculos necessários à avaliação de $F(X)$ para um dado plano de amostragem X .

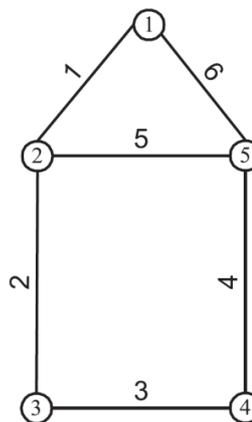


Figura 22 – Rede exemplo (DE SCHAETZEN, 2000).

A matriz de sensibilidade da rede exemplo é apresentada na Tabela 1.

Tabela 9 – Matriz de sensibilidade exemplo (DE SCHAETZEN, 2000).

Matriz de sensibilidade	Nó i					a_j	$\sum_{i=1}^n \left \frac{\partial H_i}{\partial C_j} \right $
	1	2	3	4	5		
Trecho j	1	2	3	4	5	a_j	$\sum_{i=1}^n \left \frac{\partial H_i}{\partial C_j} \right $
1	0	0	0,92	0,1	0,1	0,1	1,12
2	0,2	0,21	0,54	0,25	0,24	0,25	1,44
3	0,01	0,41	0,89	0,91	0,01	0,91	2,23
4	0,01	0,62	0,04	0,02	0,02	0,62	0,71
5	0,04	0,04	0,02	0	0,84	0,04	0,94
6	0,07	0,09	0,65	0,02	0,67	0,09	1,5
	0,33	1,7	3,06	1,3	1,88	$\sum_{j=1}^m a_j = 2,01$	

Por exemplo, a variação da carga de pressão no nó 2 para uma dada variação do coeficiente de rugosidade no trecho 3, destacada em negrito na Tabela 1, foi obtida da seguinte maneira (DE SCHAETZEN, 2000):

$$\left| \frac{H_2(C_3) - H_2(C_3^*)}{C_3 - C_3^*} \right| = \left| \frac{25,5 - 25,91}{75 - 76} \right| = 0,41 \quad (16)$$

Se for assumido que a rede de monitoramento é composta de dois pontos, os nós 2 e 4, ou seja, $X = (2, 4)$ então $F_1(X) = 2,01$. Cada p_j é calculado de a_j usando (14) e para $j = 3$, p_3 é calculado como:

$$p_3 = \frac{0,91}{2,01} \cong 0,45 \quad (17)$$

$F_2(X)$ é calculada usando a Equação (14) e é igual a 1,34. Finalmente, admitindo $w_1 = w_2 = 0,5$ e ($F1_{max} = 4,5$ e ($F2_{max} = \ln(6)$), $F(x)$ é igual a 0,63. O trecho é considerado sensível se

$$\sum_{i=1}^n \left| \frac{\partial H_i}{\partial C_j} \right| \geq 0,005 [m]. \quad (18)$$

A identificação de um conjunto de k pontos de monitoramento em uma rede de n nós classifica-se como um problema combinatório. A busca completa por uma solução ótima só pode ser calculada para pequenos valores de k e n . Por exemplo, a localização de 5 pontos de monitoramento em uma rede de 100 nós exige o cálculo de C_{100}^5 possíveis planos de amostragem, i.e. aproximadamente 108 soluções. Para resolver o problema de forma eficiente é necessário o uso de técnicas de busca estocásticas. Neste trabalho, a técnica de busca usada foi a dos algoritmos genéticos. Algoritmos genéticos são técnicas de otimização inspiradas na evolução natural, que possuem desempenho satisfatório em termos de localização e velocidade de processamento computacional (GOLDBERG, 1989). A Figura 23 mostra a tela de execução do software construído para esse fim.

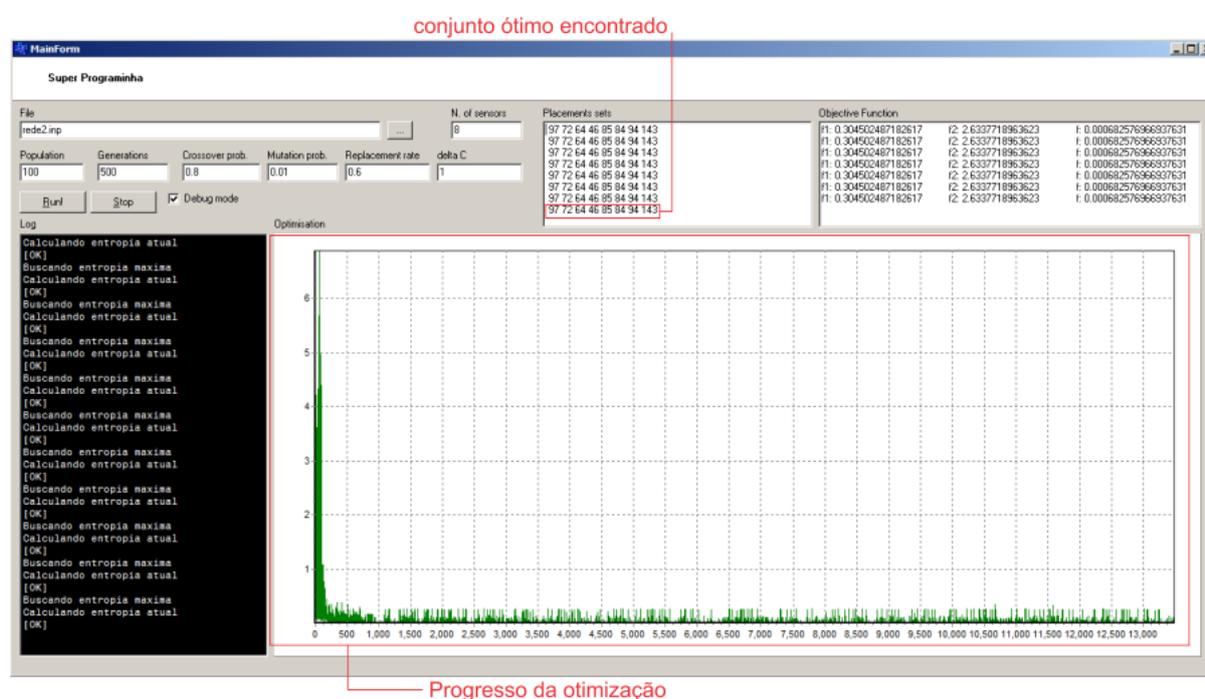


Figura 23 – Tela do software de amostragem

Para efetuar a busca, foi utilizada a biblioteca de programação GALib (WALL, 1996). As soluções foram representadas por vetores de números inteiros, nos quais cada elemento representa um candidato a ponto de monitoramento. A dimensão da solução, ou número de pontos constituintes da rede de monitoramento, foi definida como k . A função objetivo consistiu na minimização da Equação 15. Foi necessário ainda modificar o algoritmo genético para penalizar soluções com elementos repetidos. A penalização consistiu em somar a quantidade de elementos repetidos no conjunto de soluções atual à função a ser minimizada. Foram utilizados o esquema de AG *Steady-state* (populações sobrepostas), algoritmo de seleção *RouletteWheel* (seleção da roleta), operador de crossover *SinglePointCrossover*

(recombinação de ponto único) e operador de mutação *SwapMutator*. Os parâmetros de execução do AG foram população inicial de 100 soluções; 500 gerações; probabilidade de crossover de 80%; probabilidade de mutação: 1% e taxa de substituição populacional de 60%.

As Figuras 24-27 ilustram os setores com os pontos determinados em verde. Observa-se que em todos os casos que os pontos determinados encontram-se bem distribuídos ao longo das redes, com exceção do setor Iguatemi Zona Alta. Nota-se que os pontos ficaram concentrados na parte mais densa do setor, enquanto um pequeno apêndice ao norte do setor não foi selecionado. Analisando a matriz jacobiana, verificou-se que a preferência dada aos nós mais próximos se deveu à grande sensibilidade que prevaleceu sobre a entropia. Os pontos em vermelho presentes no setor Iguatemi Zona Alta e Iguatemi Zona Baixa indicam locais onde houve falha na aquisição dos dados.

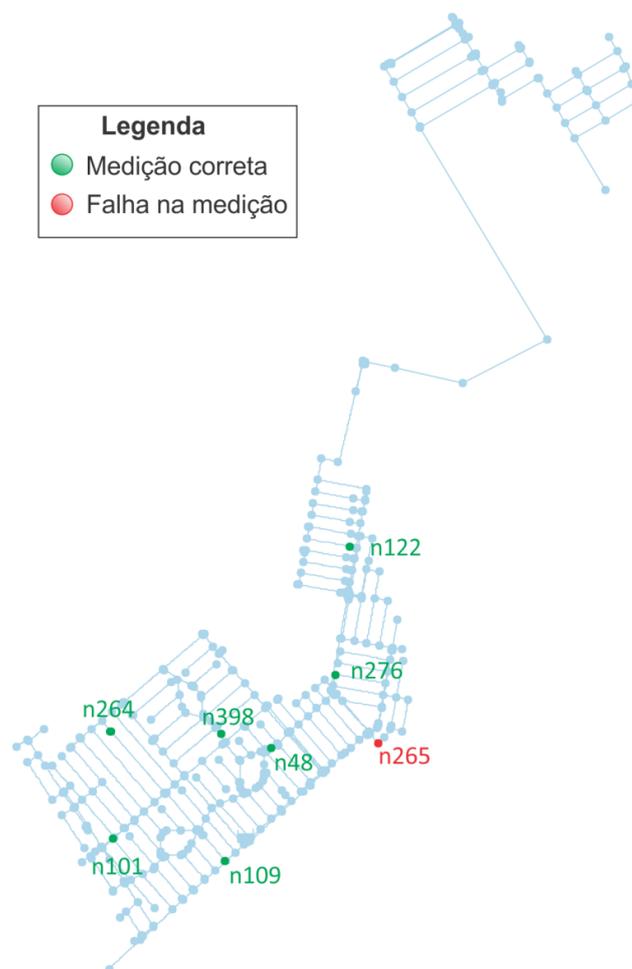


Figura 24 - Pontos de amostragem do setor Iguatemi Zona Alta



Figura 25 - Pontos de amostragem do setor Iguatemi Zona Baixa

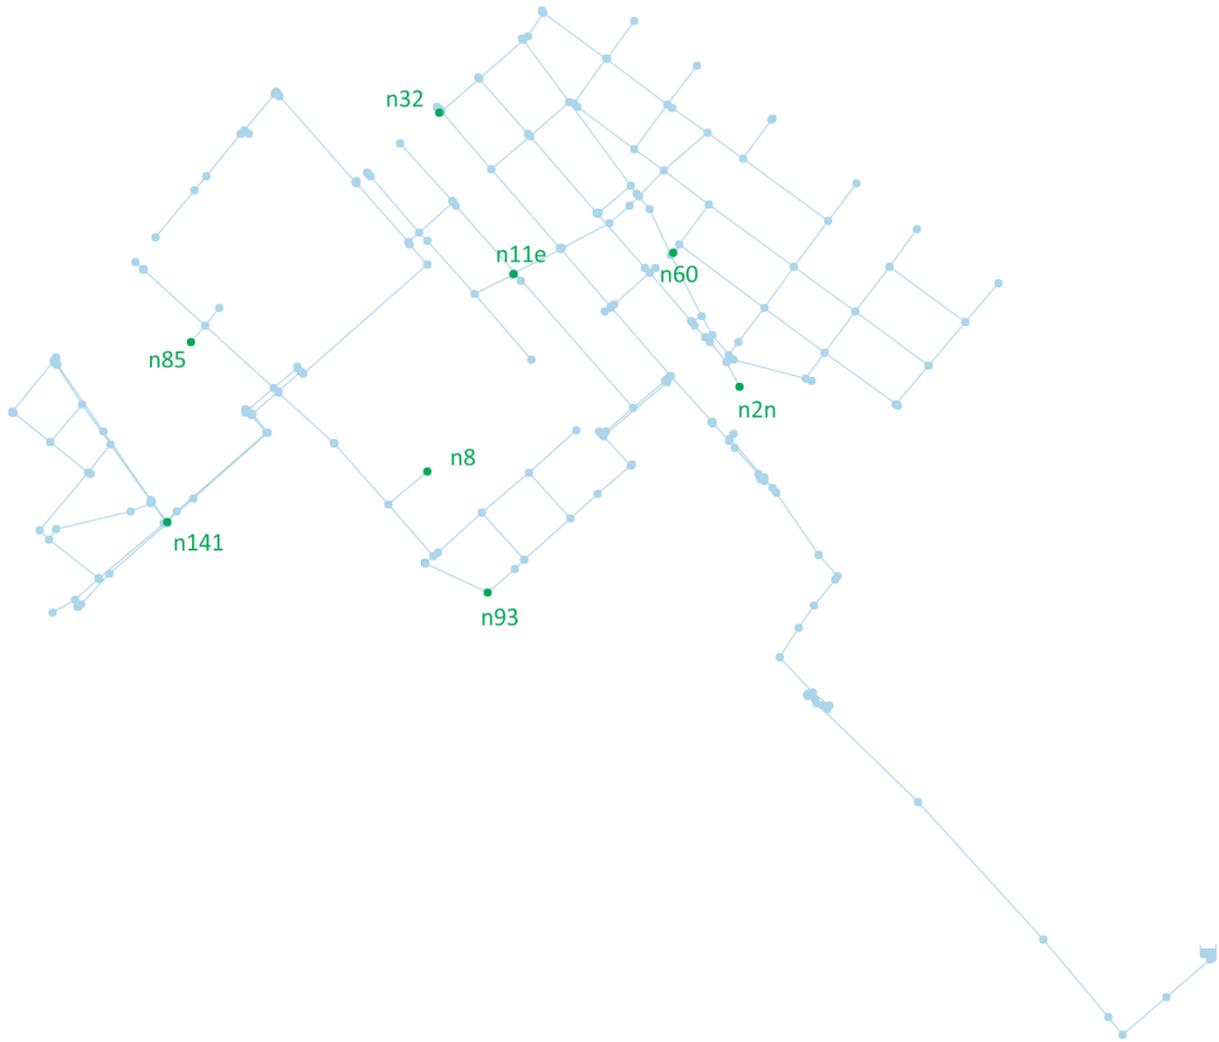


Figura 26 - Pontos de amostragem do setor Eliana

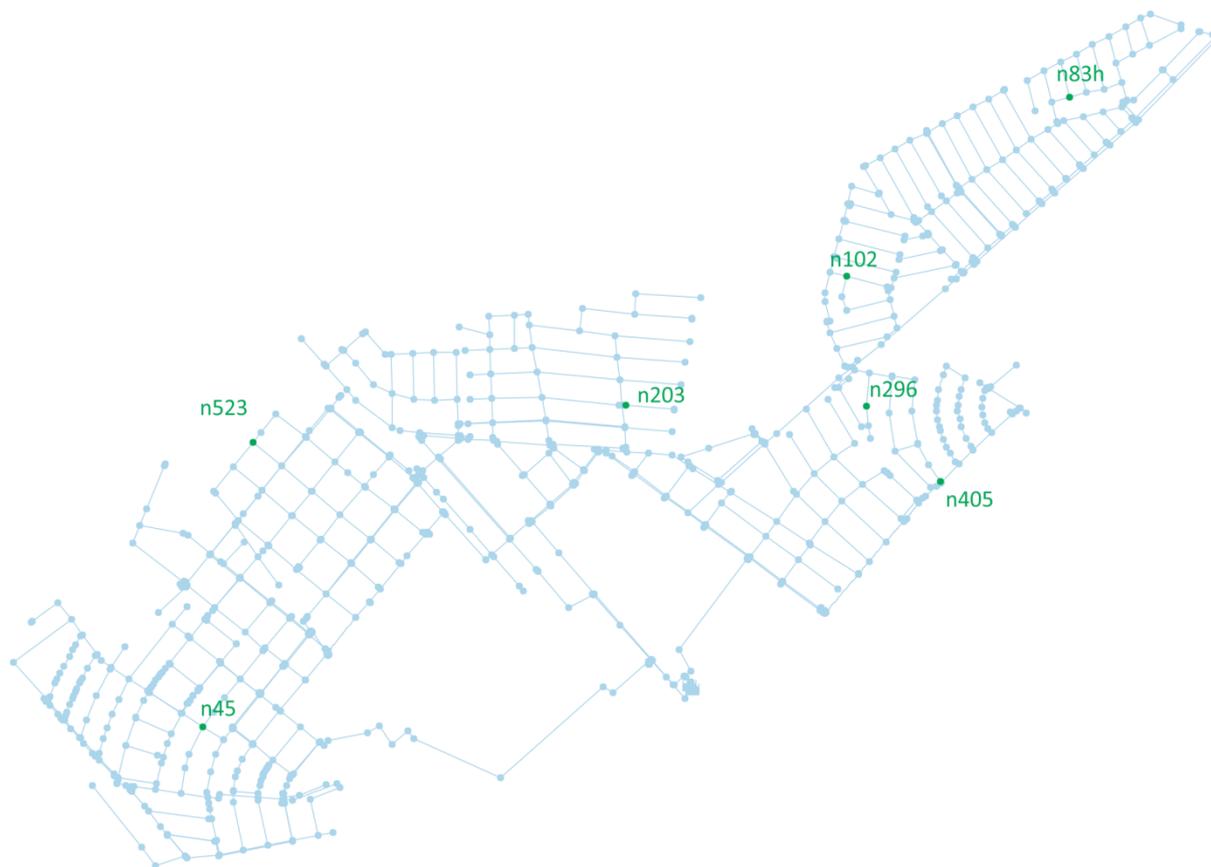


Figura 27 - Pontos de amostragem do setor Martinez

3.3 Aquisição de dados

As cargas de pressão foram registradas com o auxílio de dataloggers durante períodos de uma semana em cada setor. Foram utilizados 8 medidores de carga de pressão em cada setor. Os medidores foram configurados para registro dos dados em intervalos de 15 minutos. Idealmente, os medidores de carga de pressão deveriam ser instalados diretamente em pontos da rede de água para que não houvesse influência do consumo de água dos ramais prediais. Entretanto, isso não foi possível, devido à falta de pontos de controle nos setores em estudo.

Os medidores foram instalados nos ramais prediais. As campanhas de campo para o setor Iguatemi ZA foram efetuadas de 18 a 25 de março, no Iguatemi ZB, de 18 a 25 de fevereiro, no Martinez, de 25 de fevereiro a 4 de março, e no Eliana de 4 a 11 de março de 2013. A Figura 28 mostra os medidores em dois pontos de monitoramento.



Figura 28 – Sensores de pressão instalados nos ramais residenciais.

A Figura 29 ilustra um exemplo dos valores das cargas obtidas em determinado instante. Como a frequência de amostragem utilizada foi de 15 minutos, foram obtidos 5 valores por hora.

Para o cálculo da carga horária, notou-se que os valores menos enviesados para a calibração seriam os valores máximos de carga de pressão obtidos durante a hora de interesse, pois existem valores que são prejudicados durante o consumo que podem diminuir o valor médio da leitura. Através da Figura 29, nota-se a perceptível diferença entre os valores mínimos e máximos obtidos em determinadas horas devido ao consumo residencial. Embora os valores das medianas e médias apresentem valores próximos aos valores máximos, estes valores ainda são influenciados pelos valores de mínimos em diversos instantes.

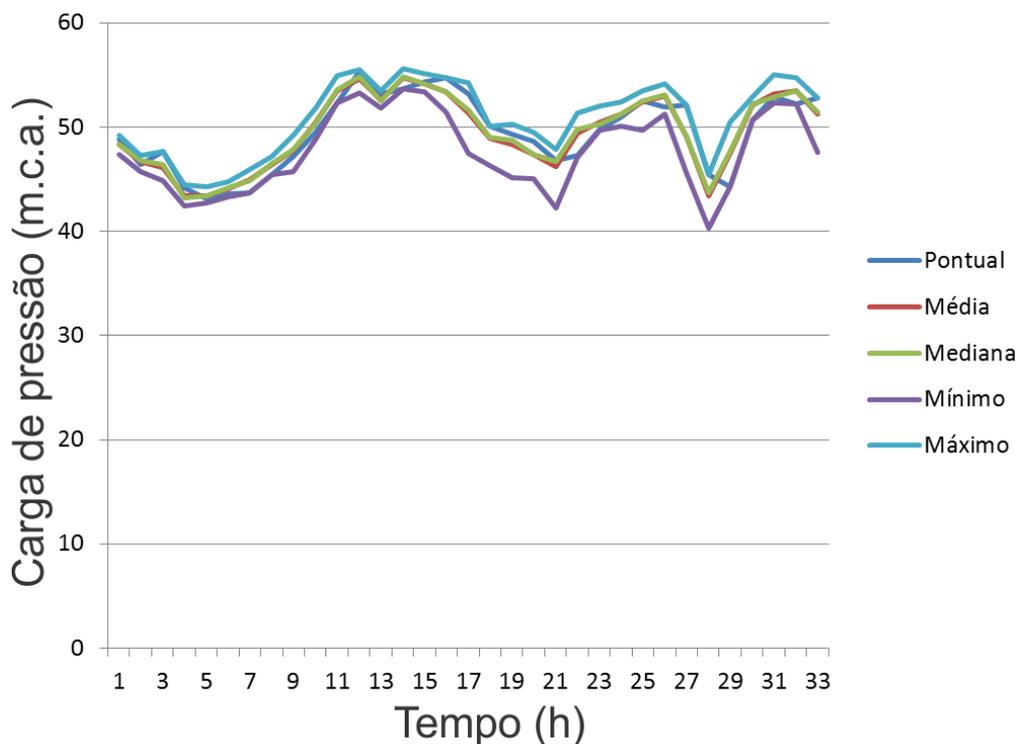


Figura 29 – Exemplo de cargas de pressão obtidas para um nó

Um dos medidores apresentou problemas no setor Iguatemi ZA e o ponto foi descartado. O mesmo problema ocorreu no setor Iguatemi ZB. Os dados foram coletados corretamente nos setores Eliana e Martinez. Entretanto, no setor Martinez, verificou-se que um dos pontos medidos não fazia parte do sistema por erro cadastral e este ponto também foi descartado para efeito de calibração.

3.3.1 Correção dos dados de Campo

Além do problema da inexistência de pontos de controle diretamente na rede, outras dificuldades também foram encontradas nos locais determinados pelo software de amostragem. Em diversas ocasiões não foi possível instalar os sensores nos locais desejados por diversos motivos, e.g. ausência de moradores nas residências, indisponibilidade de torneiras, residências inexistentes, etc.

Nestes casos, o procedimento adotado foi o de localizar a residência mais próxima possível do nó desejado. Através das coordenadas dos setores, criou-se um mapa com os setores de estudo para verificar a diferença nos dados das cargas de pressões entre os nós desejados e nós mais próximos monitorados (Figuras 30-33).

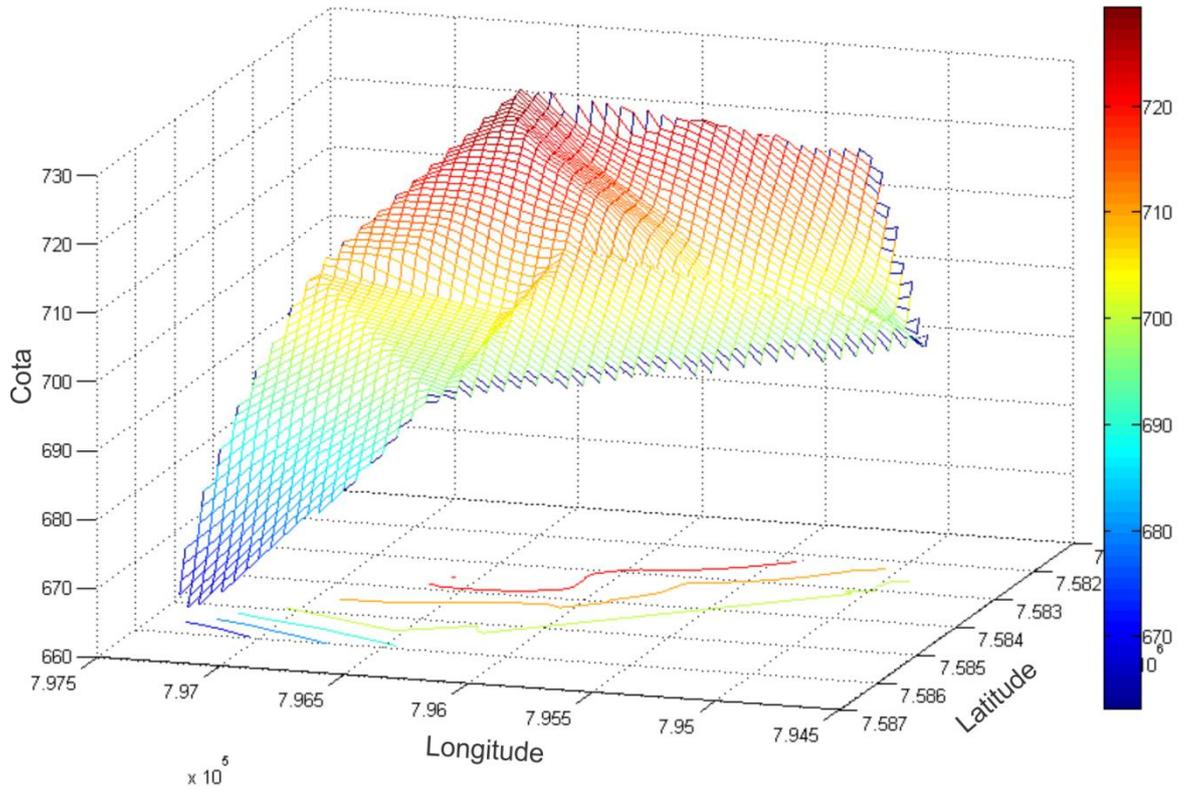


Figura 30 – Representação planialtimétrica do setor Iguatemi ZA

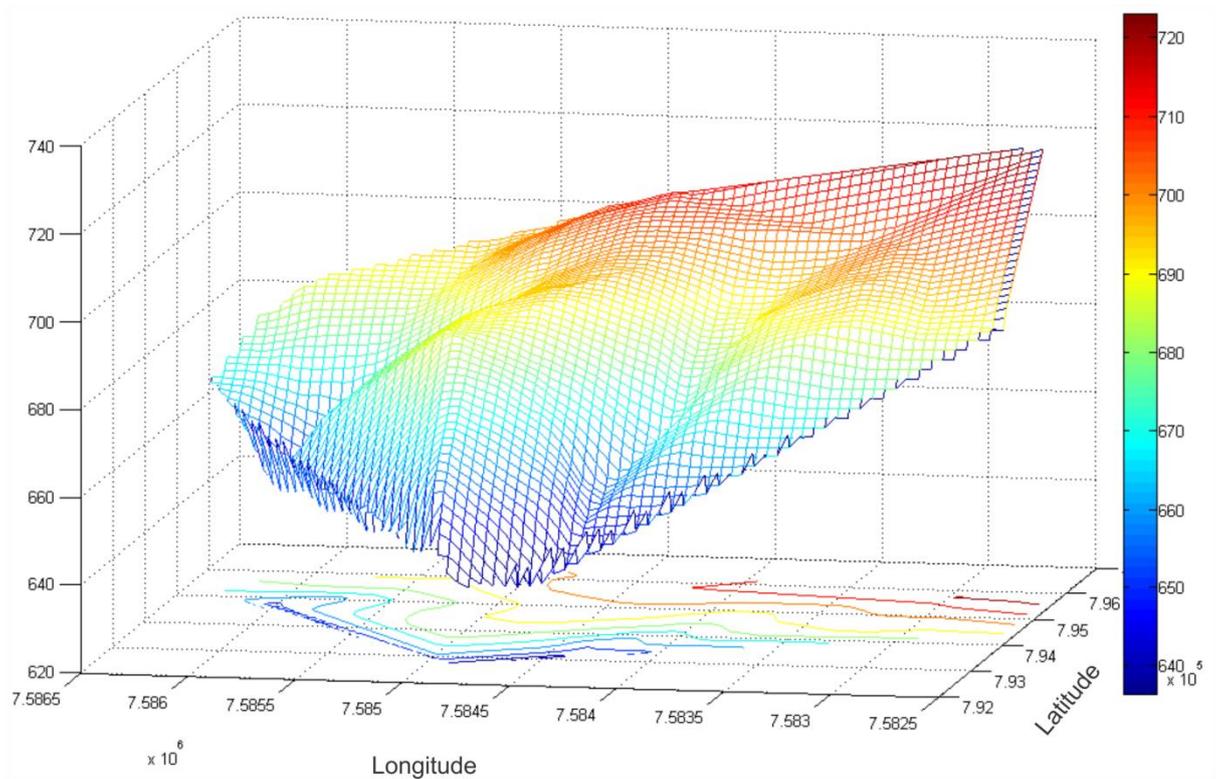


Figura 31 – Representação planialtimétrica do setor Iguatemi ZB

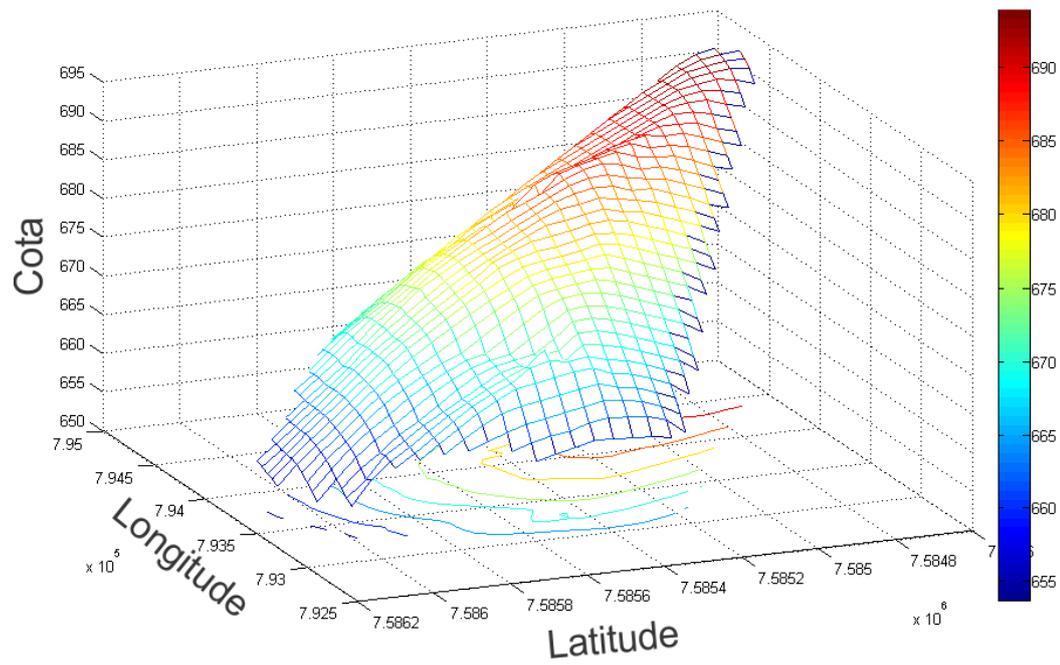


Figura 32 – Representação planialtimétrica do setor Eliana

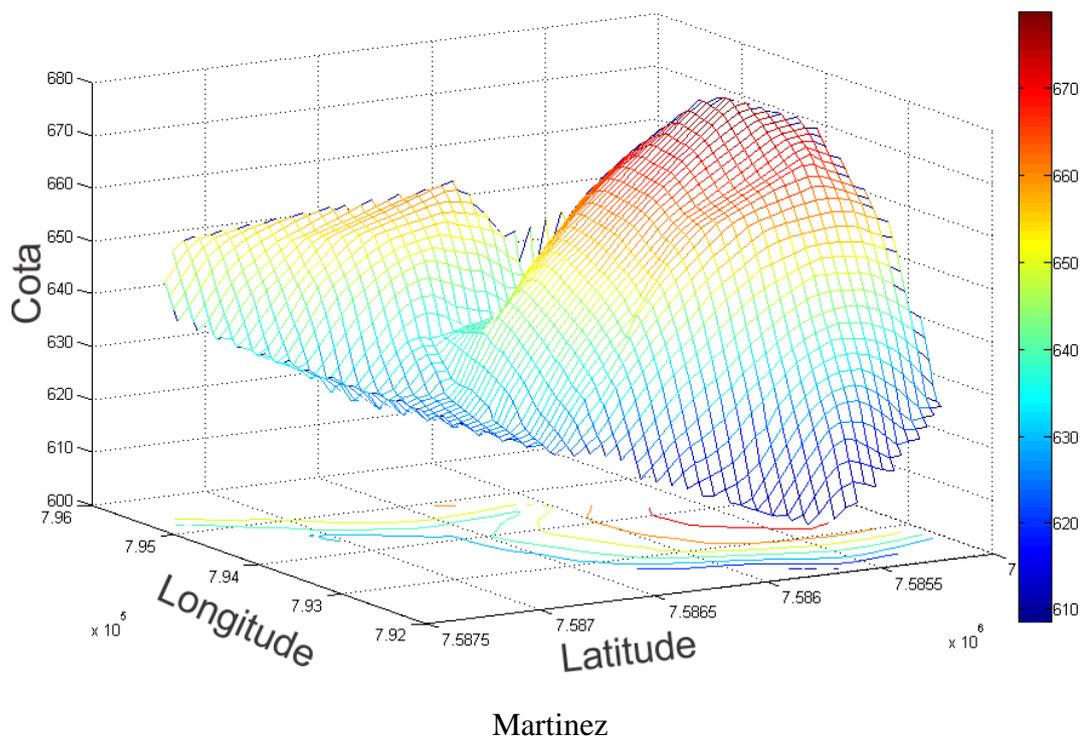


Figura 33 – Representação planialtimétrica do setor Martinez

Além da correção das cotas, outra interferência sistêmica foi inserida nos dados de carga de pressão. Os medidores foram conectados a registros posicionadas em diferentes alturas. Portanto, foi necessário subtrair os valores para redução da incerteza nos dados (Figura 34).



Figura 34 – Exemplos de correções nos valores dos dados

As Tabelas 10-13 listam as correções nos dados obtidos em campo.

Tabela 10 – Correções consideradas no setor Iguatemi ZA

Nó amostrado	Nó mais próximo	Observações	Correção cota (m)
n334	n264		0
n101	ok	Localizado em cima da pia - somar +-1,2m	1,2
n398	ok		0
n110	n109	No interior da pia (+- 1m)	0
N15	n48		0
N181	n265	não obteve leitura	-1.78
N276	ok		0,51
N50	n122		-0.24

Tabela 11 – Correções consideradas no setor Iguatemi ZB

Nó amostrado	Nó mais próximo	Observação	Correção cota (m)
n631	Ok	Sensor com erro de medição	0,23
n610	n404		1,48
n35f	Ok		0,34
n14a	n587		-0.71
n224	n226		0
n75	n57d	fixado a 1m de altura	3,31
n189	n192	fixado a 1m de altura	-1.85
n154	n37h		0,92

Tabela 12 – Correções consideradas no setor Eliana

Nó amostrado	Nó mais próximo	Obs	Correção cota (m)
n113	n32		1,52
n37	n11e		0,88
n60	ok		-1.16
n2n	ok		1,99
N155	n141		0,34
N92	n93		-0.3
N103	n8		0,75
N89	n85		0

Tabela 13 – Correções consideradas no setor Martinez

Nó amostrado	Nó mais próximo	Obs	Correção cota (m)
n255	n296		0,9
n102	ok		2,01
n5h	n405		0
n95	n83h		0
N531	n523	Protegido em uma caixa	0,5
N203	ok		0,46
N56	n45		0

3.4 Definição das arquiteturas das RNAs

Conforme mencionado na revisão, as redes neurais tradicionais possuem como limitação a necessidade de ajustes iniciais para a determinação das configurações ideais para cada problema em particular. Visando resolver esta limitação, novos modelos têm sido propostos para tornar as redes neurais auto-ajustáveis. Neste trabalho, duas redes neurais desse tipo foram implementadas e testadas: a DAN2 (*Dynamic Artificial Neural Network*), proposta por Ghiassi et al. (2005) e a AMGA (*Adaptive Merging and Growing Algorithm*), proposta por Islam et al. (2009). Ambas as redes foram desenvolvidas no programa Matlab, versão institucional fornecida pela USP. A rede neural DAN2 foi implementada utilizando a linguagem *script* do Matlab. A rede AMGA foi implementada seguindo as instruções de mesclagem e adição de neurônios, modificando a rede neural já existente na *toolkit* de redes neurais distribuída com o Matlab.

Conforme foi dito na revisão, os sistemas de calibração clássicos procuram identificar valores ótimos para as variáveis de decisão que visam a aproximar os dados de vazões e cargas de pressões obtidas em campo, com aqueles obtidos via simulações. No presente trabalho, as variáveis de decisão adotadas são coeficientes de rugosidades, parâmetros de vazamentos e coeficientes de perdas de carga localizadas.

Antes de serem utilizadas para a finalidade de calibração, inicialmente as redes neurais foram avaliadas quanto à sua capacidade de prever demandas de água, pois o teste poderia ser realizado facilmente. A análise completa dos resultados obtidos pelas RNAs foram publicados em Odan et. al 2012. Os testes com as redes neurais construtivas para fins de calibração somente seriam possíveis posteriormente com a aquisição dos dados de campo. Os detalhes da arquitetura das RNA para calibração, incluindo dados de entradas (medidas de campo ou simulações) e dados de saída (variáveis de decisão) são apresentados na Seção 3.5.

3.4.1 ADAPTIVE MERGING AND GROWING ALGORITHM (AMGA)

Islam et al. (2009) desenvolveram um algoritmo para construir RNAs denominado *Adaptive Merging and Growing Algorithm* (AMGA). O algoritmo usa mecanismos de união e adição de neurônios da camada intermediária, baseando-se no progresso e na habilidade de aprendizado dos neurônios dessa camada. A mescla é realizada entre neurônios com repostas correlacionadas entre si, enquanto que a adição divide o neurônio em dois, de modo a reaproveitar o treinamento anterior e reduzir o treinamento necessário após a modificação. Este algoritmo pode ser aplicado a diversos tipos de RNAs, sendo que neste trabalho será aplicado a RNA *feedforward* com algoritmo de treinamento Backpropagation, com o termo momentum, o qual confere maior velocidade ao treinamento sem prejudicar a estabilidade do mesmo. Tal termo é uma fração da alteração de peso anterior e é adicionado ao ajuste de pesos da equação descrita por Beale e Jackson (1990)

$$w_{ij}^{n+1} = w_{ij}^n + \Delta w_{ij}^n \quad (19)$$

em que w_{ij} é o peso sináptico entre o nó i e j , Δw_{ij} é a variação do peso e o índice n e $n+1$ correspondem número da iteração durante o treinamento. A variação do peso é dada pela regra delta generalizada, dada a seguir pela Equação 20:

$$\Delta w_{ij}^{n+1} = \eta \delta_j^n x_i^n \quad (20)$$

em que η é a taxa de aprendizagem no intervalo $[0,1]$, δ_j^n é o gradiente local de erro para o neurônio j .

Esta RNA será denominada RNA MOM-BP. Os passos utilizados pela AMGA são descritos a seguir:

1. Criar uma RNA de três camadas, com número de neurônios nas camadas de entrada e saída determinado pelo problema a ser modelado. O número de neurônios na camada intermediária é gerado aleatoriamente, assim como a matriz de pesos iniciais;
2. Inicializar o contador de ciclos $\mu_i = 0, i = 1, 2, \dots, M$, para cada neurônio da camada intermediária h_i , sendo M o número de neurônios da camadas intermediária. Este contador é utilizado para contabilizar o número de ciclos em que o neurônio foi treinado;
3. Treinar parcialmente a RNA para um número fixo de ciclos τ , especificado pelo usuário;
4. Incrementar a contagem de ciclos, expresso pela Equação 21, para $i = 1, 2, \dots, N$:

$$\mu_i = \mu_i + \tau \quad (21)$$

Sendo N o número de neurônios na camada intermediária. Inicialmente N e M são iguais;

5. Calcular o erro do conjunto de validação pela Equação 22, denominado Erro Quadrático Percentual Médio (Prechelt, 1994). Se o critério de parada é satisfeito, parar o treinamento, senão continuar:

$$E = 100 \frac{o_{\max} - o_{\min}}{KV} \sum_{v=1}^V \sum_{i=1}^K (Y_i(v) - Z_i(v))^2 \quad (22)$$

Em que o_{\max} e o_{\min} são, respectivamente, os valores máximos e mínimos para os quais a saída da RNA foi padronizada; V é o número de exemplos do conjunto de validação; K é o número de neurônios da camada de saída; $Y_i(v)$ e $Z_i(v)$ são, respectivamente, a saída produzida pela RNA e a saída desejada, do i -ésimo neurônio de saída para o v -ésimo exemplo do conjunto de validação;

6. Remover o rótulo (“label”) dos neurônios intermediários e calcular a significância η_i de cada neurônio intermediário h_i usando a fórmula empírica da Equação 23

$$\eta_i = \frac{\sigma_i}{\sqrt[3]{\mu_i}} \quad (23)$$

Em que σ_i é o desvio padrão da saída de cada neurônio h_i , para os exemplos do conjunto de treino, e μ_i é contador de ciclos;

7. Rotular os neurônios h_i como significativos (S) caso a significância de um ou mais desses neurônios seja maior que um mínimo definido pelo usuário. Notar que no máximo metade dos neurônios serão rotulados;
8. Calcular a correlação entre os neurônios rotulados S e os neurônios não rotulados, referente à saída produzida por tais neurônios intermediários para o conjunto de treino;
9. Realizar a mescla entre os neurônios rotulados e seu par mais correlacionado (h_a e h_b) e calcular a média entre o contador de ciclos de ambos os neurônios (no original, o contador é zerado). Os pesos dos neurônios modificados são dados pelas Equações 24 e 25:

$$w_{mi} = \frac{w_{ai} + w_{bi}}{2}, \quad i = 1, 2, \dots, p \quad (24)$$

$$w_{jm} = w_{ja} + w_{jb}, \quad i = 1, 2, \dots, q \quad (25)$$

em que p e q são os números de neurônios nas camadas de entrada e saída, respectivamente. Os pesos w_{ai} e w_{bi} são os i -ésimos pesos dos neurônios h_a e h_b , respectivamente, enquanto w_{mi} é o i -ésimo peso da camada de entrada e w_{mj} é o j -ésimo peso da camada de saída;

10. Retreinar a RNA modificada até que se obtenha erro menor ou igual ao da RNA anterior. Caso essa nova RNA consiga produzir um erro menor ou igual a RNA anterior, então prosseguir para o passo 11, caso contrário ir para o passo 12;
11. Atualizar o contador de ciclos conforme Equação 21;
12. Verificar o critério de adição de neurônio, conforme Equação 26. Se o critério for satisfeito, continuar, senão, retornar ao passo 3:

$$E(t) - E(t + \tau) \leq \varepsilon, \quad t = \tau, 2\tau, 3\tau \dots \quad (26)$$

em que $E(t)$ e $E(t + \tau)$ são os erros para as épocas (t) e $(t + \tau)$, respectivamente;

13. Adicione um neurônio intermediário à RNA, que consiste em dividir um neurônio existente em dois, sendo que o contador de ciclos para cada um desses neurônios será $\mu/2$. Os pesos dos neurônios divididos são dados pelas Equações 27-28:

$$w^1 = (1 + \alpha)w \quad (27)$$

$$w^2 = -\alpha w \quad (28)$$

em que w é o vetor de pesos pai, e w^1 e w^2 são os vetores pesos filhos. O coeficiente α é um valor fixo ou aleatório, que deve ser pequeno.

O treinamento é finalizado quando o erro do conjunto de validação (Equação 22) aumenta um determinado número de vezes consecutivas, que neste trabalho foi adotado como 3. Ao fim do treinamento, a arquitetura efetivamente usada é a que apresentou o menor erro do conjunto de validação.

3.4.2 Rede Neural Dinâmica (DAN2)

O outro modelo escolhido foi o DAN2 (*Dynamic Architecture for Artificial Neural Networks*), proposto por Ghiassi et al. (2005). Também foi escolhido por produzir resultados superiores às redes neurais convencionais em termos de velocidade de treinamento e fidelidade dos resultados. Além disso, suas camadas intermediárias são determinadas dinamicamente em tempo de execução ao invés de empiricamente tornando seu uso simplificado.

A idéia geral do modelo baseia-se no princípio de aprendizagem e acumulação de conhecimento em cada camada, propagando e ajustando o conhecimento para a próxima camada, e repetindo as etapas até que o desempenho desejado seja atingido. Segundo os próprios autores, a rede DAN2 classifica-se como um modelo puramente *feed-forward*. A arquitetura DAN2 é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Figura 35).

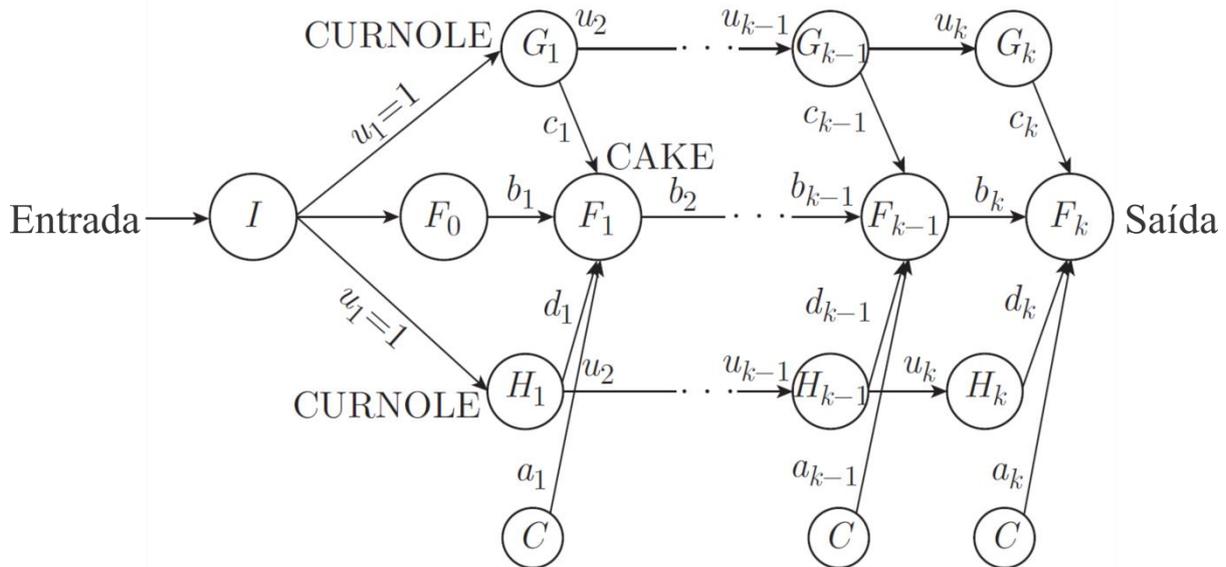


Figura 35 – Arquitetura do modelo DAN2 (Ghiassi et al. (2005)).

A camada de entrada é responsável por receber os padrões de treinamento. Uma vez que os nós de entrada são identificados, todas as observações são usadas simultaneamente para treinar a rede.

A próxima decisão de modelagem é a escolha do número de camadas ocultas e nós ocultos. Neste modelo, diferente das redes neurais clássicas, o número de camadas ocultas não é fixado a priori. Eles são gerados sequencialmente e dinamicamente até que o nível de precisão da resposta seja atingido. O modelo possui um número fixo de nós ocultos em cada camada.

Cada nó possui uma função específica para o treinamento da rede. Em cada camada oculta, a rede é treinada usando todas as observações em um conjunto de treinamento simultaneamente, de modo a minimizar os erros. O primeiro nó é uma constante de valor igual a 1, chamado de nó C. O segundo nó consiste em uma função que encapsula o elemento de conhecimento acumulado atual e é chamado de CAKE, do inglês (*Current accumulated knowledge element*). A função CAKE é calculada na camada inicial de modo diferente das camadas subsequentes. Na camada inicial é representada pela Equação 28:

$$F_0(X_i) = a_0 + \sum_{j=1}^m b_{0j} x_{ij} \quad (28)$$

E nas camadas ocultas é representada pela Equação 29:

$$F_k(X_i) = a_k + b_k F_{k-1}(X_i) + c_k \cos(\mu_k \cdot \alpha_i) + d_k \sin(\mu_k \cdot \alpha_i) \quad (29)$$

sendo: a_k, b_k, c_k, d_k e μ_k pesos de ajuste lineares do modelo DAN2; $F_k(X_i)$ é o valor da função CAKE na camada k (k -ésima iteração) para o conjunto de treinamento X_i ; $F_{k-1}(X_i)$ é o valor da função CAKE na camada anterior; $G_k(X_i)$ e $H_k(X_i)$ são as funções de transferência trigonométricas, descritas a seguir.

O terceiro e quarto nós representam o componente não linear residual atual do processo, capturado através de uma função de transferência usando um somatório ponderado e normalizado das variáveis de entrada. Esses nós são chamados de CURNOLE (*Current residual nonlinear element*). As funções $G_k(X_i)$ e $H_k(X_i)$ são expressas por $G_k = \cos(\mu_k \cdot \alpha_i)$ e $H_k = \sin(\mu_k \cdot \alpha_i)$. O produto $\mu_k \cdot \alpha_i$ define um ângulo entre o registro observado X_i e um vetor de referência R , definido como 1.

O ângulo e as funções trigonométricas correspondentes são utilizados para a combinação e transferência e, assim, são usados para medir a distância generalizada entre cada observação X_i e o vetor de referência R . O ângulo α_i pode ser calculado através das Equações 30 e 31:

$$\alpha_i = \cos^{-1}(R * X_i)_N \quad \text{para } i = 1, \dots, n \quad (30)$$

$$(R * X_i)_N = \frac{(R * X_i)}{\|R\| * \|X_i\|} \quad (31)$$

De modo simplificado, o algoritmo de treinamento é composto pelas seguintes etapas:

Seja uma matriz de entrada $X = \{X_i; i = 1, 2, \dots, n\}$ com n registros independentes de m atributos, sendo $X_i = \{x_{ij}; j = 1, 2, \dots, m\}$. Define-se também um vetor de referência $R = \{r_j; j = 1, 2, \dots, m\}$ como um vetor de valores constantes.

1. *Ajustar os coeficientes da camada linear inicial através da Equação 28, para os valores da matriz X , utilizando-se a regressão linear;*
2. *Caso o ajuste seja satisfatório, ou seja, a precisão esteja dentro do limite estipulado, o algoritmo pode ser finalizado. Caso contrário, inicia-se o ajuste não linear, adicionando-se camadas ocultas iterativamente, expressas pela Equação 29, até que as condições das Equações 32 e 33 sejam satisfeitas;*
3. *De posse da rede neural treinada, aplicar o modelo para os dados que se deseja prever.*

O ajuste não linear utiliza a técnica da projeção vetorial, projetando-se cada registro de observação em um vetor de referência para a normalização dos dados. A normalização consiste na determinação dos ângulos entre cada registro i e o vetor de referência. Tais ângulos são ajustados durante o treinamento e atualizados a cada iteração. Ghiassi et al. (2005) sugerem diversos métodos para busca dos melhores parâmetros de ajuste para o componente não linear. Neste trabalho, utilizou-se o algoritmo de Levenberg-Marquardt e todos os pesos foram ajustados simultaneamente em cada camada.

Para definir o critério de parada na fase de treinamento/validação, Ghiassi et al. (2005) recomendam a verificação de duas condições (Equações 32 e 33). A condição do primeiro erro (ε_1^*) visa evitar a falta de treinamento, verificáveis através da variação da diferença entre a soma do quadrado médio da previsão atual (SSE_k) e a anterior (SSE_{k-1}). A segunda avaliação (ε_2^*) é utilizada para evitar o treinamento excessivo, interrompendo o algoritmo, caso o erro quadrado médio do conjunto de treinamento (MSE_T) se distancie do erro quadrado médio do conjunto de validação (MSE_V). Os limites de ε_1^* e ε_2^* foram determinados experimentalmente.

$$\varepsilon_1 = (SSE_k - SSE_{k+1}) / SSE_k \leq \varepsilon_1^* \quad (32)$$

$$\varepsilon_2 = |MSE_T - MSE_V| / MSE_T \leq \varepsilon_2^* \quad (33)$$

Modelos de previsão

Para o processo de previsão, foram usados dados de consumo do setor Iguatemi, da cidade de Araraquara, SP. A série é composta por 6985 registros horários de consumo em litros por segundo. O processo pode ser dividido em 3 etapas: (i) treinamento da rede neural; (ii) validação e (iii) previsão.

O treinamento da rede neural consiste em treinar o modelo através do fornecimento dos padrões de entrada. Para o treinamento, foram utilizados 60% dos registros. A validação é um processo paralelo ao treinamento. Consiste na avaliação do treinamento com o uso de dados distintos dos usados no treinamento para verificar o bom ajuste do modelo. A validação impede que haja perda da generalidade pelo excesso de treinamento. Para a validação foram utilizados 20% dos dados. Por fim, a previsão propriamente dita foi feita e comparada com os 20% restantes dos dados.

A escolha do modelo de previsão baseou-se nos estudos de Odan e Reis (2012), em que o melhor modelo de previsão, para a próxima hora utilizou como dados de entrada o consumo defasado de 0, 1, 2 e 168 horas.

Critério de Avaliação

Para avaliar o desempenho dos modelos de previsão, utilizaram-se dois critérios, o Erro Absoluto Médio (do inglês Mean Absolute Error – *MAE*) e a Raiz do Erro Quadrático Médio (*Root Mean Square Error – RMSE*), expressos respectivamente pelas Equações 34 e 35:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (34)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (35)$$

em que y_i e \hat{y}_i são respectivamente os valores previstos e observados, e N é o número de dados avaliados.

Avaliação da previsão

Os modelos de previsão para a próxima hora foram avaliados para cinco treinamentos, que são apresentados na Tabela 14 e 15 e nas Figuras 36–38.

Na Figura 36 pode-se observar a evolução do erro em função do número de neurônios na camada intermediária para a rede neural AMGA. Para os cinco treinamentos, obteve-se uma média de 24 neurônios, que variou de 12 a 36. Para esse treinamento, o critério de parada foi atingido com 28 neurônios, sendo que o melhor resultado foi obtido com 22 neurônios. Cada treinamento foi realizado em menos de 40 minutos, por um computador Core 2 Duo (T6400) de 2.0 GHz, com 3 GB de memória RAM.

Devido à rapidez do algoritmo de aprendizagem do modelo DAN2, executou-se o treinamento da rede neural sem critério de parada para determinação dos valores dos erros. Todo o treinamento foi feito em 5,4 segundos em um computador com processador i7 2.2 GHz, 8 GB de memória RAM. A Tabela 14 lista os valores dos erros encontrados para cada camada até a iteração 5. Observa-se que não há melhora significativa para ε_l (Equação 32)

após a iteração 2. Os valores de ε_2 (Equação 33) permanecem relativamente constantes nas cinco iterações, embora observe-se que existe uma pequena diminuição no erro. Através da verificação do MAE e RMSE, observa-se que os modelos apresentam bons resultados logo na primeira iteração, sendo desnecessário prosseguir com o treinamento.

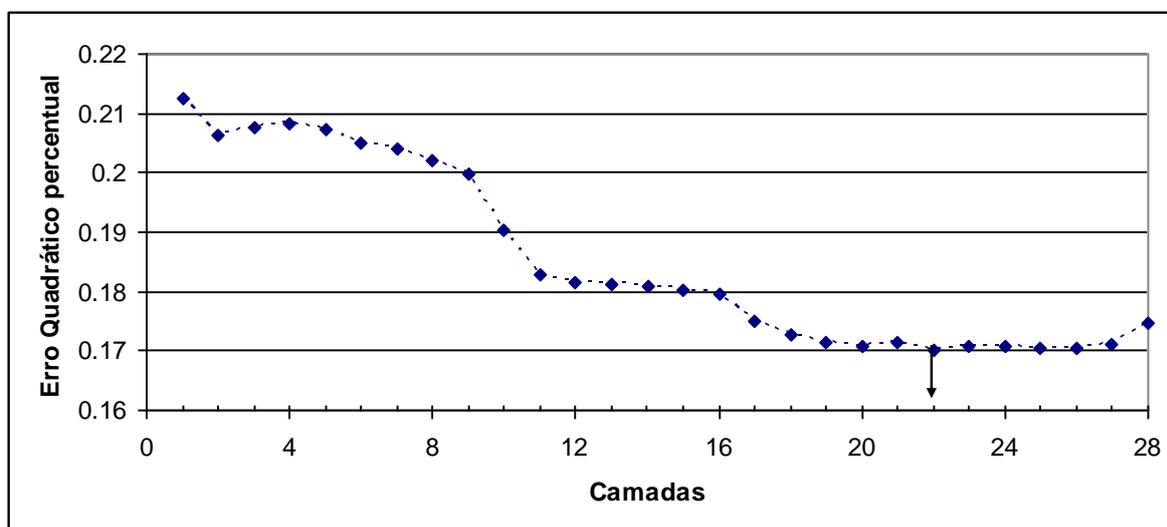


Figura 36 – Evolução do erro para a rede neural AMGA

Tabela 14 – Evolução do Erro em função do número de camadas k para a rede neural DAN2

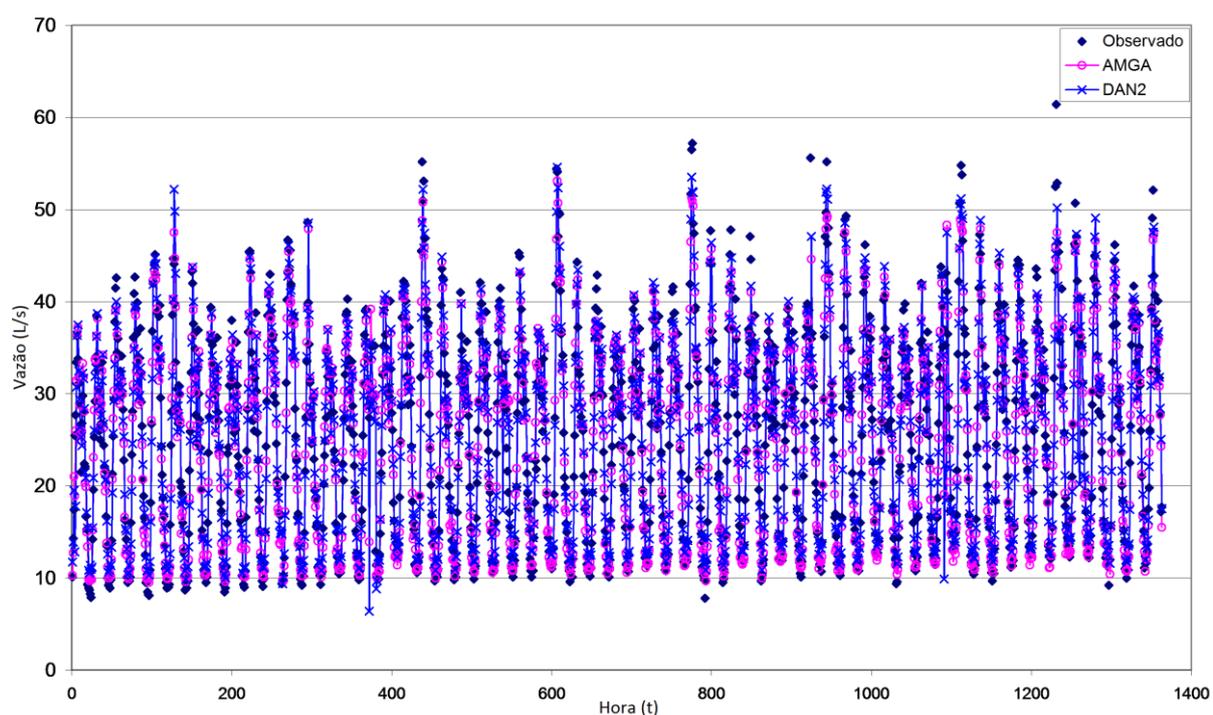
k	ε_1	ε_2	MAE_k (Treino)	MAE_k (Validação)	$RMSE_k$ (Treino)	$RMSE_k$ (validação)
1	1.0000096	1.9388577	3.38	3.48	0.08	0.13
2	0.0000585	1.9383737	3.39	3.49	0.08	0.13
3	0.0000970	1.9377212	3.39	3.50	0.08	0.13
4	0.0001350	1.9372125	3.40	3.50	0.08	0.13
5	0.0001726	1.9368575	3.40	3.51	0.08	0.13

A Tabela 15 mostra o erro encontrado na previsão final dos dados para ambas as RNAs. A previsão resultou em valores semelhantes aos encontrados no treinamento, embora, ao contrário do esperado, tenha apresentado erros menores do que com os dados utilizados no treinamento. Observa-se que a rede AMGA produziu melhores resultados que a DAN2.

Tabela 15 – Erro para a previsão das RNAs

Modelo	<i>MAE</i>	<i>RMSE</i>
AMGA	2.34	3.61
DAN2	3.24	3.62

A Figura 37 ilustra o resultado da previsão de demanda de toda a série de dados. Na Figura 38 apresenta-se um trecho de simulação escolhido arbitrariamente para melhor visualização da previsão, correspondente a sete dias de dados. Verifica-se que ambos os modelos apresentam comportamento similar. O modelo AMGA aproxima-se bem da demanda nos horários de menor consumo, enquanto que a DAN2 tende a superestimá-la. A previsão do modelo DAN2 aproxima-se melhor dos picos de consumo que o modelo AMGA, o qual tende a subestimar tais picos.

**Figura 37 – Previsão do consumo para a série completa**

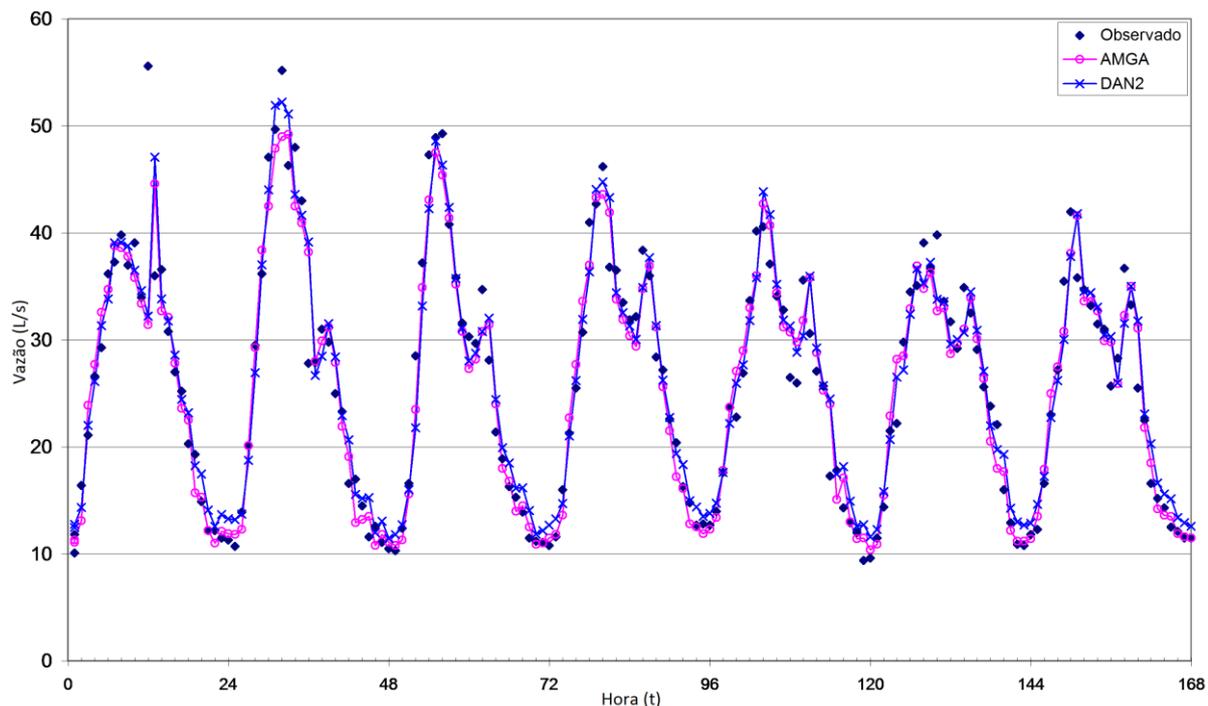


Figura 38 – Detalhe da previsão utilizando período de 7 dias

Depois de testadas, concluiu-se que as redes neurais AMGA e DAN2 foram implementadas corretamente e que funcionaram adequadamente para a tarefa de previsão de demandas, sendo que o modelo AMGA apresentou o melhor desempenho devido à sua maior capacidade de generalização, que se baseia em estratégias adaptativas, as quais, em tese, podem ser adaptadas a qualquer tipo de rede neural.

Finalmente, após finalizada esta etapa, partiu-se para a criação dos padrões de treinamento com a finalidade de calibração. A seção seguinte explica como as redes neurais artificiais foram concebidas para o processo de calibração.

3.5 Criação dos padrões de treinamento

Para que as redes neurais artificiais sejam capazes de adquirir conhecimento (“aprender”) do comportamento dos modelos de redes abastecimento de água, é necessário que lhes seja fornecido um conjunto de treinamento. O conjunto de treinamento consiste de exemplos contendo diversas entradas com valores variados e as respostas correspondentes produzidas pelo modelo de rede de abastecimento. Assim, um conjunto de exemplos com

uma ampla variação nos valores amostrais produz uma gama maior de resultados, melhorando a qualidade do aprendizado.

Ao contrário de um modelo caixa-preta (e.g. redes neurais), o modelo de simulação hidráulica Epanet é puramente matemático e baseia-se na resolução de equações hidráulicas. Sendo assim, pode-se afirmar que uma rede hidráulica que foi modelada com dados teóricos sem calibração, produz resultados satisfatórios para este cenário teórico, assumindo que as variáveis físicas que não são o objetivo da calibração estejam corretas. Ou seja, o modelo hidráulico produz respostas que são condizentes com as variáveis inseridas no modelo que se deseja calibrar. Deste modo, é razoável supor que variando-se os valores destas variáveis e executando simulações, produzem-se valores que podem ser usados como dados de treinamento para uma rede neural artificial. Isso se justifica, pois assim como outros métodos multiregressivos multivariados, após treinada, a RNA possui a habilidade de produzir as variáveis de decisão usando como entrada os valores observados.

3.5.1 Divisão das redes em zonas homogêneas

Sistemas de distribuição de água usualmente apresentam grandes quantidades de tubulações com coeficientes de rugosidade desconhecidos. Esta grande quantidade de tubulações torna inviável a determinação dos coeficientes para todos os trechos da rede. Portanto, o modelo deve ser simplificado, de modo a assumir que conjuntos de tubulações de características similares possuam a mesma rugosidade. O mesmo vale para os outros parâmetros desconhecidos da rede. Essa etapa é conhecida na literatura como parametrização e é importante tanto para fins de calibração, quanto para a redução da quantidade de cálculos computacionais. Mallick et al (2002) listam como critérios para divisão de trechos em grupos (1) idade e material da tubulação, (2) diâmetro da tubulação, (3) localização relativa, e (4) identificação de trechos críticos em termos de zonas de pressão. A escolha do melhor critério é feita de forma empírica e através da experiência do modelador.

A divisão das redes em grupos permite a redução drástica do espaço de busca, e, conseqüentemente, economia de recursos computacionais. O software gerador de padrões realiza a divisão automática da rede em grupos, utilizando como critério o coeficiente de rugosidade teórico dos trechos atribuída no momento da modelagem. Neste trabalho, os quatro setores de estudo (Iguatemi ZA, Iguatemi ZB, Eliana e Martinez) foram divididos de

acordo com o material da tubulação. Coincidentemente, cada um dos setores foi separado em três grupos.

Após a divisão em grupos, o software modifica as variáveis de decisão dentro do modelo hidráulico por valores sorteados aleatoriamente, generalizando cada elemento do grupo com os valores sorteados. Esta etapa é descrita a seguir.

3.5.2 Software gerador de padrões

A Figura 7 ilustra o primeiro algoritmo usado para a criação dos padrões, desenvolvido em C++ com auxílio da *toolkit* do Epanet. O algoritmo consiste na amostragem aleatória de valores para as variáveis de decisão dentro de intervalos válidos. O algoritmo substitui os valores pré-existent no modelo pelos valores amostrados. Em seguida, executa-se uma simulação com os novos valores e os resultados são armazenados em um arquivo, criando-se os padrões de treinamento. O mesmo procedimento é efetuado para cada uma das 4 redes e obtêm-se no final, quatro padrões de treinamento, que posteriormente, serão usados para o treinamento das 4 redes neurais.

Os modelos hidráulicos foram configurados para serem executados em período estendido de 24 horas, com passos de resolução de uma hora. Os valores para as simulações também foram obtidas a cada uma hora para criação dos padrões.

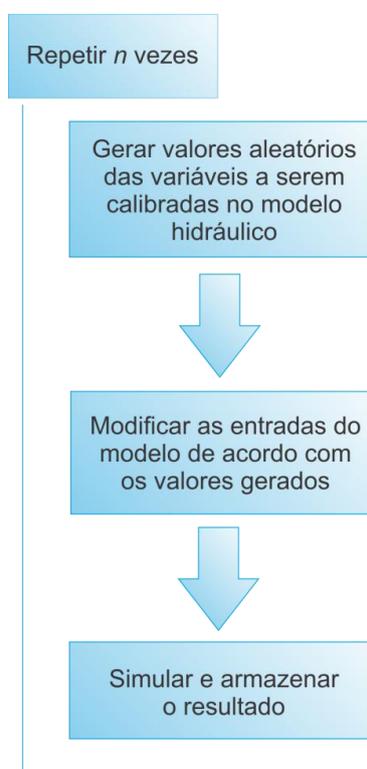


Figura 39 – Gerando padrões de treinamento

As variáveis utilizadas para a criação dos padrões estão listadas na Tabela 16. Todos os parâmetros constantes da tabela são vetores de duas ou três dimensões. Os índices representam a dimensão do vetor para cada rede de abastecimento, definidas como:

g : quantidade de grupos em que os trechos da rede foram divididos, segundo o critério adotado; n : quantidade de redes desejadas através das diversas combinações ; p : quantidade de pontos de monitoramento da variável de estado carga de pressão; q : quantidade de pontos de monitoramento da variável de estado vazão; l : quantidade de reservatórios; d : quantidade de padrões de consumo; t : instante da simulação dinâmica e g : quantidade de grupos em que a rede foi dividida.

Tabela 16 - Variáveis utilizadas para geração do padrão de treinamento.

Tipo	Parâmetros
Entradas	Coeficientes de rugosidades[g]/[n]
	Coeficientes de vazamento[g]/[n]
	Expoente de Vazamento[n]
	Perda de carga localizada[g]/[n]
Saídas	Carga de Pressão [p]/[t]/[n]
	Vazão[q]/[t]/[n]
	Nível do tanque[l]/[t]/[n]
	Padrões de consumo[d]/[t]/[n]
	Erro[t]/[n]

As variáveis separadas como “Entradas” são as variáveis(coef. de rugosidades, parâmetros de vazamentos e perdas de carga localizadas) que sofreram as alterações dentro do modelo hidráulico. E as variáveis separadas como “Saída”, são os valores obtidos da simulação de cada rede alterada. Os valores aleatórios são atribuídos ao modelo automaticamente. Efetua-se então a simulação para a rede modificada e armazena-se os resultados obtidos para cada instante de tempo em que a rede hidráulica foi modelada. Esses resultados são: vetores com as simulações de cargas de pressões horárias nos pontos de

interesse; vetores de vazões horárias nos pontos de interesse; Status de funcionamento da bomba; níveis dos reservatórios (ou padrões de variação de nível de reservatórios de nível fixo) padrões de consumo e vetores booleanos horários que são ativados como verdadeiro em caso de erro de simulação em determinada hora.

Nas primeiras tentativas da criação dos padrões e treinamento das redes neurais foram encontrados problemas não relatados usualmente na literatura científica e o algoritmo foi aprimorado. O primeiro problema foi que, devido à grande quantidade de entradas e saídas, a rede neural não seria viável caso utilizasse um conjunto de dados extenso. Testes realizados com 600 mil linhas de dados frequentemente ocasionavam o “congelamento” do processamento. Alguns estudos com redes neurais envolvem uma quantidade ainda maior de linhas, entretanto, com número reduzido de variáveis. O problema ocorria pois a rede neural necessitava carregar para a memória uma grande quantidade de dados simultaneamente, já que cada linha do conjunto de treinamento possui diversas variáveis de entrada e saída.

Além disso, a memória também era ocupada para a realização de diversos cálculos inerentes aos algoritmo de RNA, pois a quantidade de ligações (pesos sinápticos) é igual ao produto das variáveis de entradas, saídas e neurônios da camada intermediária, fazendo com que o número de variáveis cresça linearmente (este problema só ocorre com a RNA AMGA). Uma solução para este problema seria o carregamento *on demand* somente dos dados necessários para o treinamento em cada instante. Entretanto, essa solução compromete o tempo total de treinamento, pois o tempo de acesso ao disco rígido é muitas vezes mais lento do que o acesso direto à memória RAM.

Outro problema encontrado foi na geração das respostas do modelo hidráulico. Cada variável de entrada do modelo possui um intervalo de valores válidos. Entretanto, apesar de teoricamente válidos, se inseridos no modelo podem ocasionar erros na simulação. Por exemplo, valores extremos nos parâmetros de vazamentos que exigem mais água do que o fornecido pelo sistema. Este comportamento foi considerado problemático, pois levava o modelo hidráulico a soluções absurdas que comprometeriam o aprendizado da rede neural.

Estes dois problemas motivaram o estudo de um método de amostragem melhorado. Ao invés da seleção de variáveis através de números aleatórios, buscaram-se soluções que diminuíssem a quantidade de padrões de treinamento, sem comprometer a representatividade dos dados e que filtrassem somente os valores pertencentes às faixas de valores viáveis, eliminando os dois problemas simultaneamente.

O método de amostragem aleatória foi então substituído pelo método de amostragem por hipercubo latino (LHS – *Latin Hypercube Sampling*). O LHS é um método desenvolvido para escolher amostras mais significativas com número inferior de iterações se comparado com o método de Monte Carlo. A chave da amostragem por Hipercubo Latino é a estratificação das entradas e a adoção de uma lei de distribuição de probabilidade. O método força a obtenção de valores nos diversos estratos, recriando a distribuição de probabilidade de entrada (Figura 40).

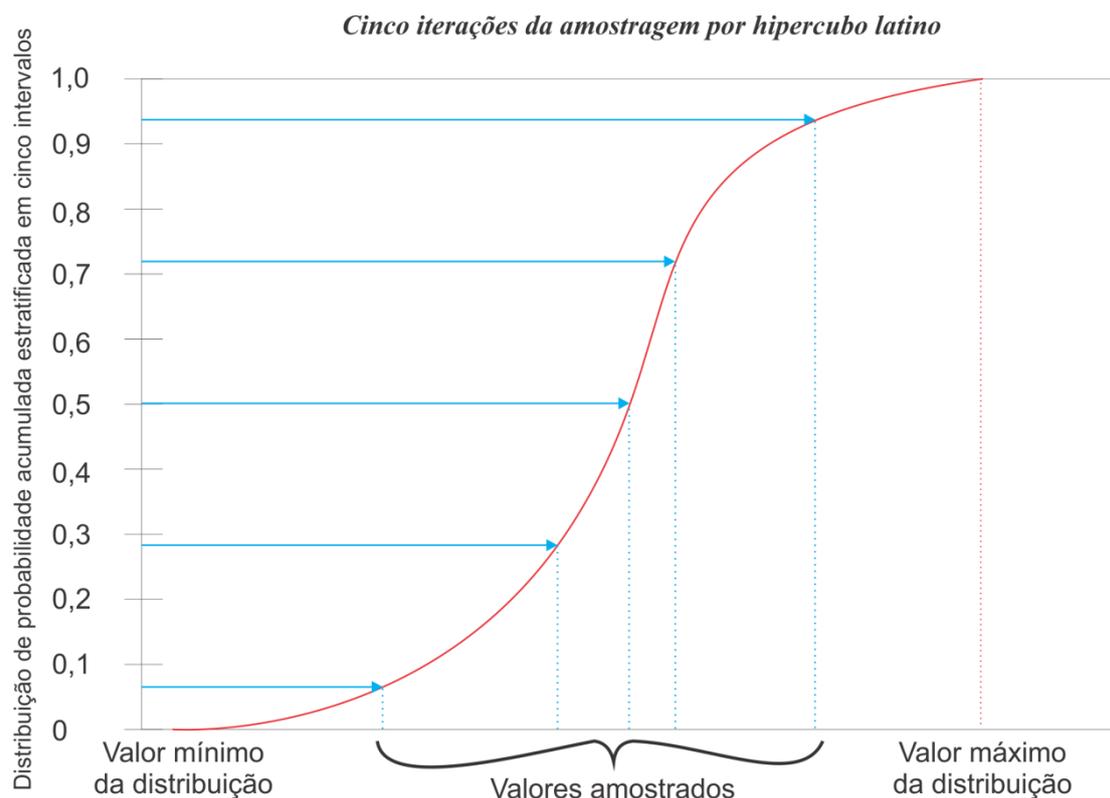


Figura 40 – Exemplo de estratificação de função distribuição acumulada em cinco intervalos.

Para a execução do software gerador de padrões, foram investigados intervalos reais possíveis que não gerassem erros de execução do modelo. Por exemplo, estudos demonstraram que expoentes de vazamento podem assumir valores a partir de 0,41 até valores extremos como 2,3 (Tabela 2). No entanto, a simulação dos modelos hidráulicos próximos aos limites máximos da literatura frequentemente ocasionam erros na resolução do sistema.

Assim, o programa foi modificado para que ao invés de utilizar variáveis aleatórias, fossem utilizados valores amostrados pelo LHS e, posteriormente, combinados para a criação

dos modelos modificados. Primeiro determinou-se a função densidade de probabilidade de ocorrência de erro de cada variável de decisão (pré-requisito para o uso do LHS). Para cada variável de entrada (coef. de rugosidades, parâmetros de vazamentos, perdas de carga localizadas) efetuou-se o seguinte procedimento separadamente, conforme ilustrado na Figura 41:

1. Amostragem os números internamente ao intervalo válido para a variável de decisão desejada usando LHS.
2. Substituir as variáveis do modelo pelos valores amostrados.
3. Efetuar a simulação hidráulica e obter os resultados de cargas de pressões e vazões.
4. Obter o código de erro da simulação.
5. Se não houve erro, salvar todas as entradas e saídas no conjunto de treinamento, caso contrário continuar.
6. Repetir o processo até que um número desejado de padrões seja obtido.

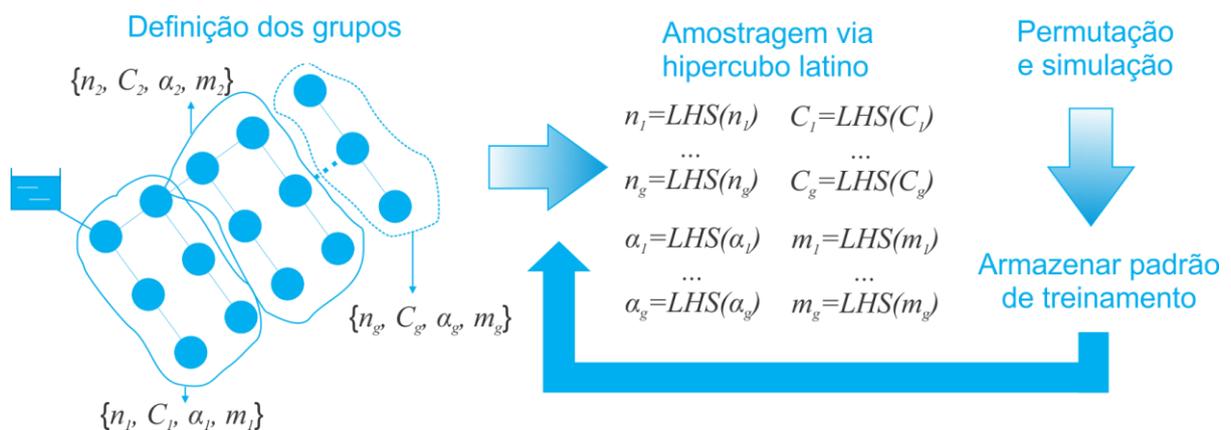


Figura 41 – Esquema de geração de padrões: g : quantidade de grupos gerados; n_i : coeficiente de rugosidade para o i -ésimo grupo; C_i : coeficiente de vazamento para o i -ésimo grupo; α : expoente de vazamento; m_i : coeficiente de perda localizada.

O resultado da execução do procedimento descrito para a variável “perdas de carga localizadas” pode ser visualizado na Figura 42.

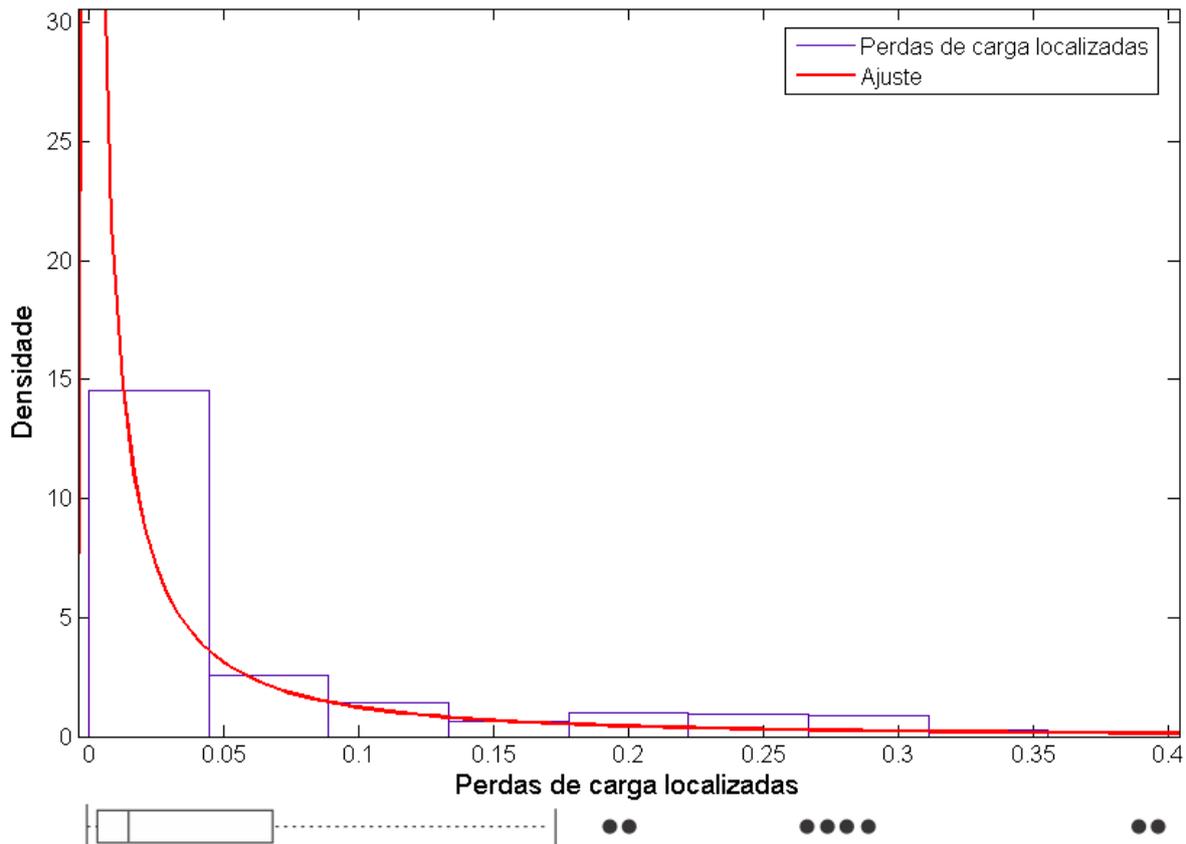


Figura 42 – Função densidade de probabilidade da não ocorrência de erros de simulação para a variável Perda de Carga.

O parâmetro “perda de carga localizada” pode assumir valores altos quando usado pontualmente em um nó. Entretanto, observa-se que as simulações tiveram comportamento melhor quando essa variável apresentava valores próximos a zero. Sabe-se que tal variável precisa assumir valores positivos. Observando o histograma obtido, pode-se notar que as frequências obtidas aproximam-se de uma distribuição lognormal (Equação 36).

$$f(x|\mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}; x > 0$$

$$\mu = \log \frac{m^2}{\sqrt{\frac{v}{m^2} + 1}} \quad (36)$$

$$\sigma = \sqrt{\log \frac{v}{m^2} + 1}.$$

Sendo:

x : variável aleatória. μ e σ : média e desvio padrão da distribuição normal.

m e v : média e variância da distribuição lognormal.

Determinados os parâmetros m e v , gerou-se uma curva para verificar a qualidade do ajuste (Figura 42).

Em seguida, calcularam-se as probabilidades de ocorrência (Figura 43). Verifica-se que os pontos obtidos tem uma boa aderência no início da curva, mas existe um desvio nos dados no final da curva. Este desvio não é problemático para o método LHS, pois o método também sorteia pontos extremos.

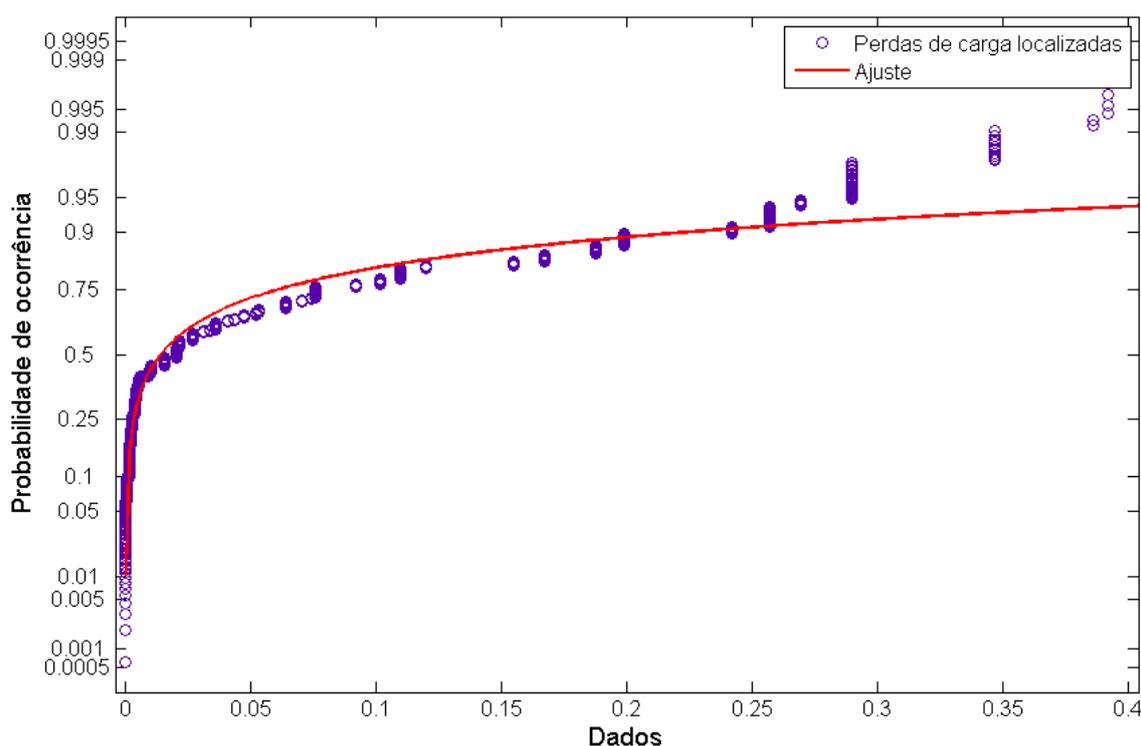


Figura 43 – Gráfico da probabilidade de ocorrência de erros de simulação para os coeficientes de perdas localizadas e do ajuste da função.

A Figura 44 ilustra o resultado da função de probabilidade acumulada (CDF) para a distribuição probabilística calculada (lognormal). Através do CDF foi possível amostrar os valores para a perda de carga. Observa-se que o crescimento do CDF é acentuado no início do gráfico e atenua-se à medida que os valores crescem.

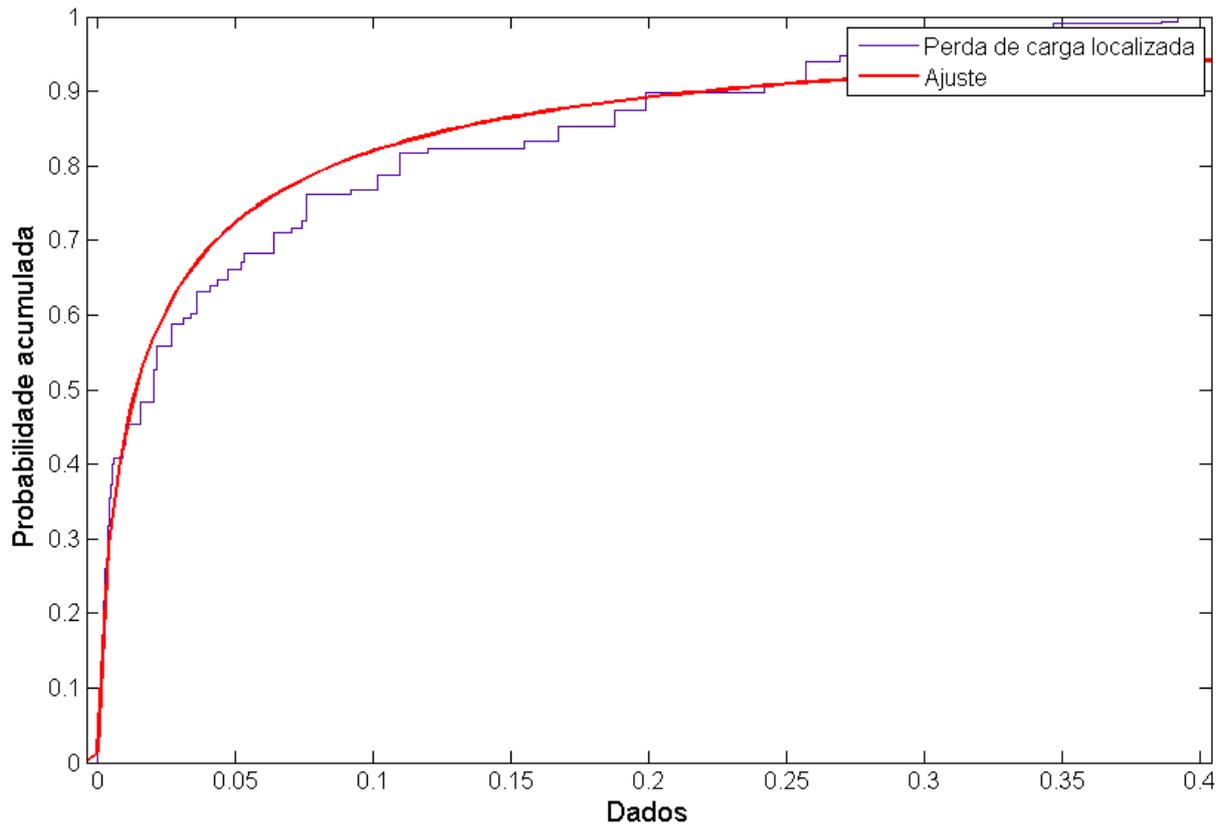


Figura 44 – Função de Probabilidade Acumulada para valores de Perda de Carga com não ocorrência de erros na simulação.

O mesmo processo foi efetuado para o coeficiente de rugosidade. Apesar de pequenas variações nas frequências obtidas, assumiu-se que o coeficiente de rugosidade é um parâmetro que pode assumir valores livremente. Assim sendo, os valores amostrados para o coeficiente de rugosidade que não apresentaram erro de simulação aproximaram-se de uma distribuição uniforme (Figura 45). Neste caso, a função de probabilidade acumulada apresenta-se como uma reta e a implementação da amostragem consiste na combinação dos próprios valores do coeficiente de rugosidade no intervalo válido, divididos de forma equidistante.

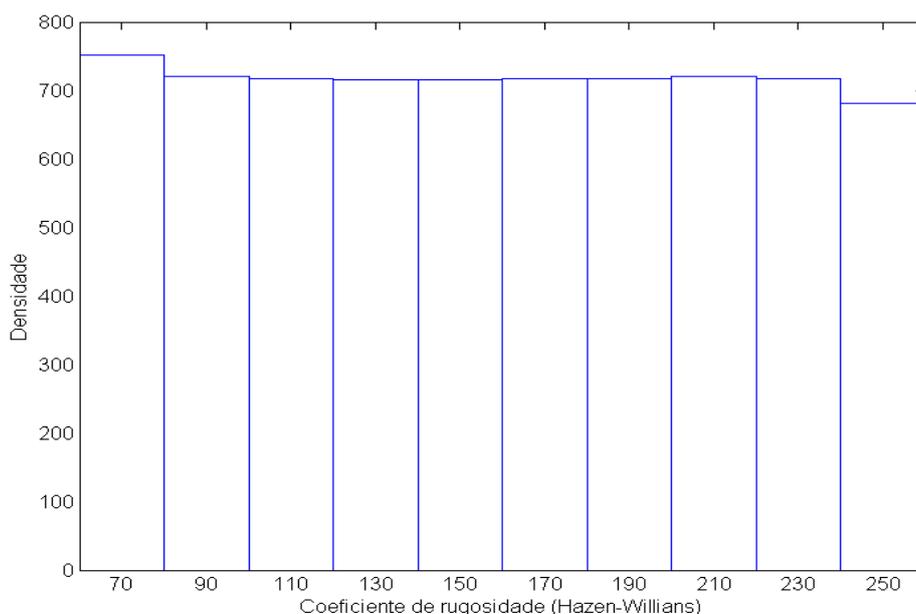


Figura 45 - Função densidade de probabilidade para o parâmetro coeficiente de rugosidade

A função densidade de probabilidade e sua respectiva densidade acumulada são mostradas nas Figuras 46 e 47. Assim como o parâmetro perda localizada, os coeficientes de vazamentos apresentaram maior concentração nos primeiros intervalos (próximos a zero). A curva de ajuste de probabilidade acumulada mostrou boa aderência nos primeiros valores e, posteriormente, uma aceleração na inclinação da curva superior à frequência dos valores gerados pelo modelo.

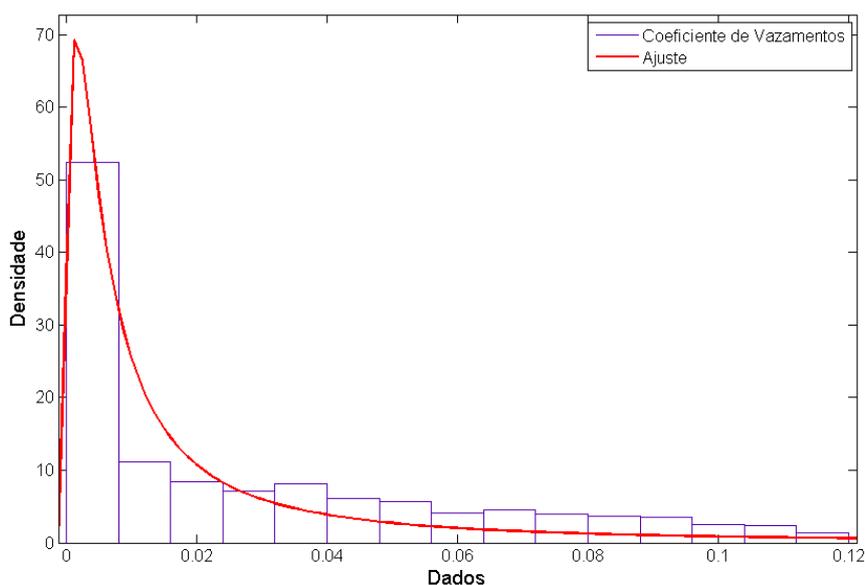


Figura 46 – Função densidade de probabilidade para o parâmetro coeficiente de vazamento.

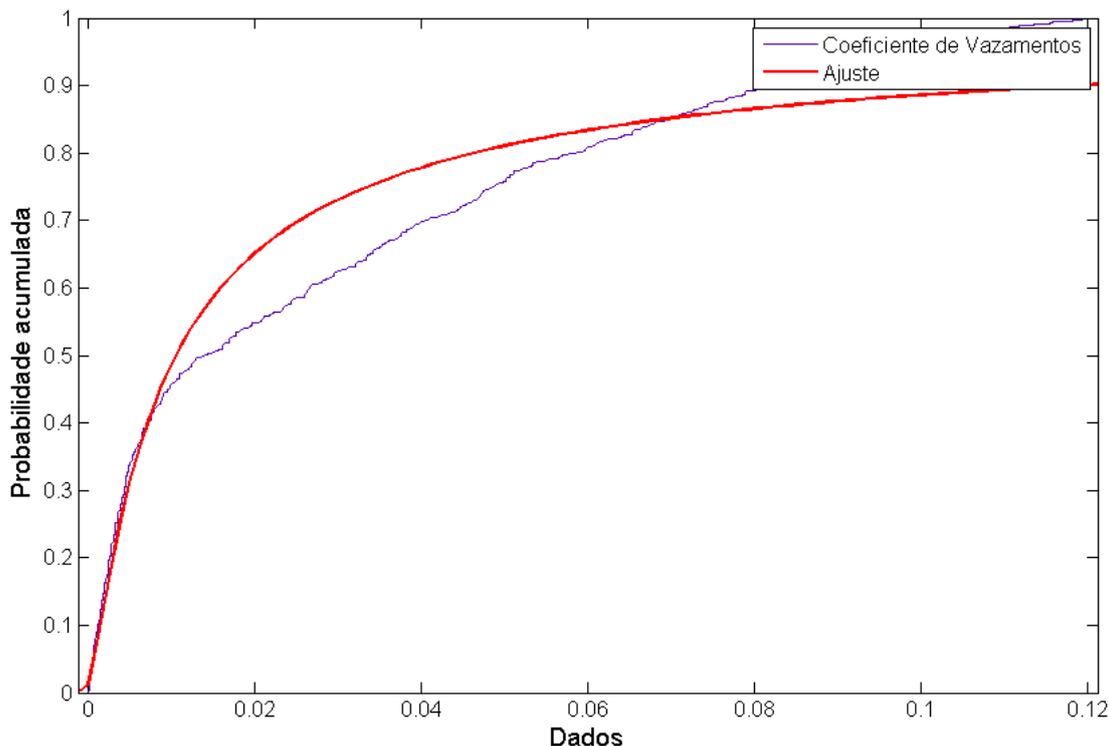


Figura 47 – Função densidade acumulada para o parâmetro coeficiente de vazamento.

3.6 Descrição dos métodos de calibração

A calibração dos setores foi efetuada de três maneiras diferentes. A primeira maneira, foi com o auxílio das redes neurais artificiais que foi o método inicialmente proposto neste trabalho. A segunda maneira foi mesclando as redes neurais artificiais e os algoritmos genéticos. Além disso, calibraram-se os modelos através do método usualmente utilizado na literatura, por meio de algoritmos genéticos para fins de comparação.

Calibração via redes neurais artificiais

As etapas anteriores descreveram o processo de aquisição dos dados e o processo para geração de padrões de treinamento. A Tabela 16 lista as variáveis que foram modificadas para a realização das simulações. Essas variáveis de entrada são as variáveis que se deseja calibrar. Para o treinamento da rede neural, os valores são invertidos. O objetivo da rede neural nesta etapa é, com base nos valores simulados, ser capaz de extrair conhecimento do modelo hidráulico (através dos padrões de treinamento) para reproduzir as variáveis de decisão que melhor se adequem a estes valores.

A Figura 48 mostra as entradas e saídas das redes neurais usadas para o treinamento. Duas redes neurais (DAN2 e AMGA) foram treinadas para cada rede hidráulica, resultando em 8 RNAs.



Figura 48 – Dados de entradas e saídas para o treinamento das RNAs.

As variáveis de entrada são todas transientes. Os valores para estas variáveis são obtidos no momento da simulação ou informados durante a fase de modelagem e consistem de vetores tridimensionais. A primeira dimensão é o índice que armazena o identificador da posição da variável específica. Foram obtidos via simulação: p pontos de monitoramento de carga de pressão, q pontos de monitoramento de vazão, l níveis de tanque no início do intervalo de tempo de simulação. As outras dimensões representam o tempo no instante t (em horas) para cada simulação e o índice n que representa as variações de cada modelo de rede. A variável Erro representa o registro de quando existe ocorrência de erro de simulação para o instante t . A variável de erro é disparada pelo Epanet sempre que ocorre alguma singularidade hidráulica, como cargas de pressões negativas ou falta de água no reservatório.

As variáveis de saídas são vetores bidimensionais. Elas são as variáveis físicas permanentes do modelo hidráulico que estão sujeitas à calibração neste trabalho. Os valores para coeficientes de rugosidades, coeficientes de vazamento e perdas de carga localizadas foram agrupadas em g grupos para cada qual das n configurações de rede.

Os padrões produzidos via simulação hidráulica foram divididos em 70% para treinamento, 15% para validação e 15% para o teste para todas as redes e a performance foi avaliada através do erro médio quadrado (MSE). A divisão do conjunto de testes não era necessário, pois os testes reais a serem utilizados são os dados medidos em campo. Entretanto, optou-se por criar o subgrupo de testes por conveniência, pois foi utilizada funções pré-definidas pelo pacote de redes neurais do Matlab para a implementação da RNA AMGA.

Depois de treinadas, as redes neurais estão aptas para, utilizando os dados de campo, prever os valores dos parâmetros de calibração (Figura 49). Os valores registrados em campo e o padrão de consumo são propagados para a obtenção das saídas.



Figura 49 – Representação do uso das RNA para a calibração

Para a obtenção das variáveis de decisão pela RNA, são utilizados as matrizes de dados obtidos em campo (cargas de pressões e vazões), além dos padrões de níveis dos reservatórios e padrões de consumo. As matrizes contêm os dados discretizados, hora a hora, de um período de 24 horas. Em um sistema livre de incertezas, a rede neural treinada deveria produzir como resposta, a mesma saída independente do instante em que os dados de campo relativos às variáveis de estado foram monitoradas. Entretanto, como não existe sistema ideal, as redes neurais produzem 24 conjuntos de resultados de variáveis de decisão (um conjunto de resultados para cada hora em que os dados de campo são informados) que podem variar dependendo do instante simulado. Estes 24 conjuntos de variáveis são inseridos novamente no modelo hidráulico, gerando 24 novos modelos por setor. O software então avalia o conjunto com menor erro médio, descartando os demais conjuntos.

A RNA pode ser comparada a uma função composta por coeficientes capaz de produzir uma ou mais saídas. Embora o conjunto de treinamento possua valores dentro de intervalos físicos especificados, não existe garantia de que as saídas produzidas estejam dentro dos limites válidos. Portanto, o software também é responsável por converter as saídas para intervalos válidos, quando necessário, de acordo com a Equação 37. Caso uma variável de saída x (i.e. coeficientes de rugosidades, coeficientes e expoentes de vazamentos, perdas localizadas) esteja fora dos limites, ela é convertida para o valor válido mais próximo; e, em caso contrário, o valor calculado é mantido.

$$x := \begin{cases} \text{Se } x < x_{\min}, & x_{\min} \\ \text{Se } x > x_{\max}, & x_{\max} \\ \text{Senão,} & x \end{cases} \quad (37)$$

3.6.1 Calibração via algoritmos genéticos

A calibração via algoritmos genéticos é um dos métodos mais utilizados na literatura atual. Este método consiste em minimizar o desvio encontrado entre os valores simulados

pelo modelo hidráulico e os dados medidos em campo, buscando os melhores valores para as variáveis de decisão. A Equação 38 mostra a função objetivo utilizada nesse sistema:

$$\text{Min. FO} = \sum_{j=1}^{n_h} w_h \frac{(H_j - H_j^*)^2}{(\sum_{i=1}^{n_h} H_i^*)^2} + \sum_{j=1}^{n_f} w_f \frac{(F_j - F_j^*)^2}{(\sum_{i=1}^{n_f} F_i^*)^2}$$

s.a.:

$$n_{\min} < n < n_{\max} \quad (38)$$

$$C_{\min} < C < C_{\max}$$

$$\alpha_{\min} < \alpha < \alpha_{\max}$$

$$m_{\min} < m < m_{\max}$$

Sendo:

H_j e H_j^* : Cargas de pressão simuladas e registradas em campo respectivamente para o nó j da rede.

F_j e F_j^* : Vazões simuladas e registradas em campo respectivamente para o trecho j da rede.

n_h : Quantidade de nós monitorados.

n_f : Quantidade de trechos monitorados.

w_h e w_f : pesos atribuídos aos desvios de carga de pressão e vazão.

n : coeficiente de rugosidade.

C : coeficiente de vazamento.

α : expoente de vazamento.

m : coeficiente de perda de carga localizada.

$variavel_{\min}$, $variavel_{\max}$: intervalos fisicamente válidos que a variável pode assumir para limitar o espaço de busca pelo algoritmo de otimização.

A função objetivo consiste na minimização da soma ponderada dos quadrados das diferenças adimensionalizadas entre as cargas de pressões simuladas e observadas (H e H^*) e entre vazões simuladas e observadas (F e F^*). As duas parcelas são divididas pelo quadrado da soma dos valores de cada conjunto de medições para que a função objetivo se torne

independente do sistema de unidades. Do ponto de vista estatístico, a função objetivo FO representa o logaritmo negativo da função de máxima verossimilhança das cargas de pressões e vazões de valores computados sob algumas hipóteses restritivas (Tucciarelli e Termini 1998). Os pesos w_h e w_f são o inverso da variância dos dois grupos de erros relativos.

O sistema de calibração foi desenvolvido em linguagem C++ em conjunto com a biblioteca de algoritmos genéticos GALib (WALL, 1996). Para realizar a calibração através dos algoritmos genéticos, as redes de abastecimento foram divididas usando os mesmos grupos utilizados para a calibração através de redes neurais. O software de calibração lê os dados de carga de pressão e vazão observadas em campo a partir de arquivos texto. Os arquivos texto foram padronizados para serem lidos através do software de calibração, conforme o Quadro 1. O arquivo relaciona cada nó existente na rede com o grupo ao qual ele pertence. O mesmo processo foi realizado relacionando os trechos da rede com os grupos.

Quadro 1 – Definição do formato do arquivo que caracteriza os grupos

```
; linhas iniciadas com ";" são comentários ignorados pelo
; software
; Variaveis do arquivo:
; g: quantidade de grupos;
; a: quantidade de nós
; gi: identificador do i-ésimo grupo
; i={1,a}
; idi: Identificador do nó pertencente ao i-ésimo grupo.
; j={1,n}

n g1 g2 ... gn
id1 g1
...
ida gn
```

Além disso, os dados registrados em campo foram armazenados em um arquivo de banco de dados no formato Microsoft Access. O arquivo contém o instante da medição dividido em horas, o valor médio horário e o identificador do nó ou trecho da observação.

O processo de calibração através de algoritmos genéticos pode ser esquematizado na Figura 50. O fluxograma do lado esquerdo tem início com a modelagem e a aquisição dos dados. Estas duas etapas são as mesmas etapas da nova metodologia proposta no presente trabalho. Depois, o programa fica em um processo iterativo buscando as melhores soluções que visam minimizar a função objetivo (Equação 38) até que a condição de parada seja atingida.

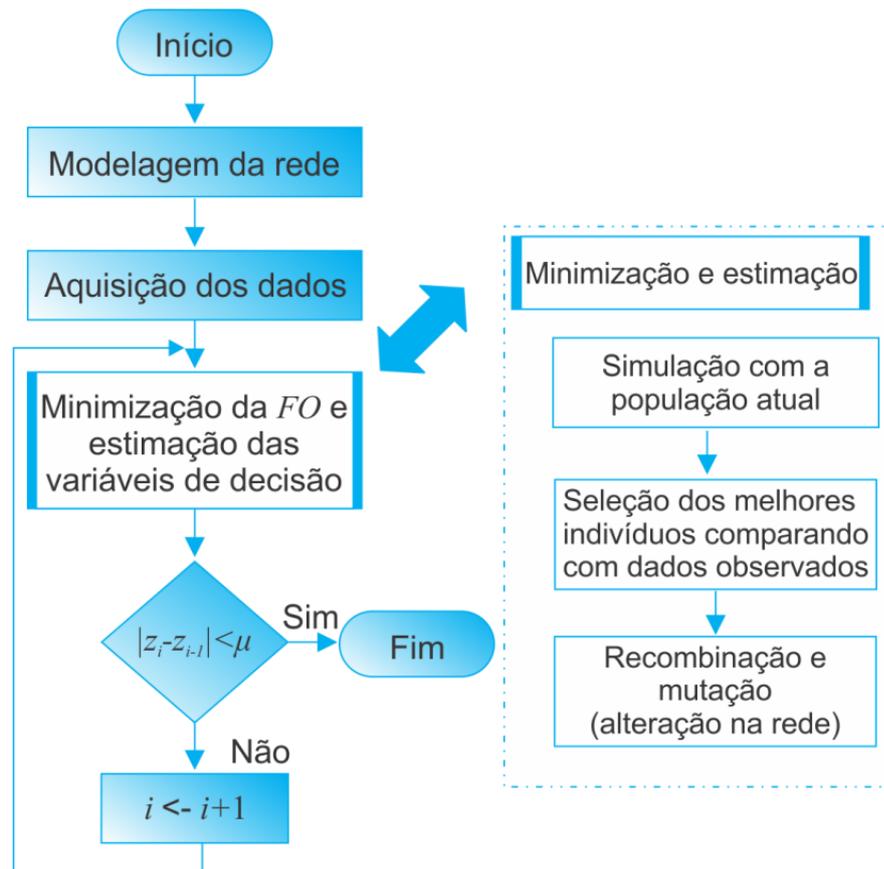


Figura 50 – Fluxograma da calibração através de A.G.

Foram utilizados o esquema de AG *Steady-state* (populações sobrepostas), algoritmo de seleção *RouletteWheel* (seleção da roleta), operador de crossover *PartialMatchCrossover* (método do mapeamento parcial) e operador de mutação *SwapMutator*. Os parâmetros de execução do AG foram população inicial: 100; 500 gerações; probabilidade de crossover de 80%; probabilidade de mutação: 1% e taxa de substituição populacional de 60%. Cada uma das redes foi calibrada três vezes, e os melhores resultados obtidos de cada calibração foram utilizados para apresentação dos resultados finais.

3.6.3 Calibração híbrida (RNA + AG)

O terceiro método consiste na calibração híbrida. Este método utiliza as saídas obtidas pela redes neurais treinadas para iniciar a calibração através de algoritmos genéticos partindo de soluções melhores do que se fossem obtidas através da busca inicialmente aleatória em todo espaço de soluções.

Conforme explicado na Seção 3.6.1, a calibração puramente através das redes neurais artificiais produz 24 conjuntos de resultados (correspondentes a 24 horas de simulação) que

posteriormente são avaliados para a escolha do melhor. Entretanto, para o método híbrido, não existe necessidade de avaliar o melhor resultado. O software verifica e exclui conjuntos repetidos (r : número de conjuntos excluídos), obtidos através das redes neurais. Os conjuntos remanescentes constituirão parte da população inicial dos algoritmos genéticos. Este, por sua vez, ao invés de gerar um conjunto inicial de n soluções aleatórias, gera $(n - 24 + r)$ soluções aleatórias, sendo $24 - r$ conjuntos produzidos pela rede neural.

A Figura 51 ilustra o método de calibração híbrido. Inicialmente, obtêm-se os valores através da rede neural artificial e excluem-se os eventuais conjuntos repetidos r . Em seguida, o algoritmo genético gera uma população aleatória de $n - 24 + r$ elementos, totalizando n elementos que serão utilizados como população inicial. Em seguida, o processo de calibração é efetuado normalmente através do algoritmo genético.

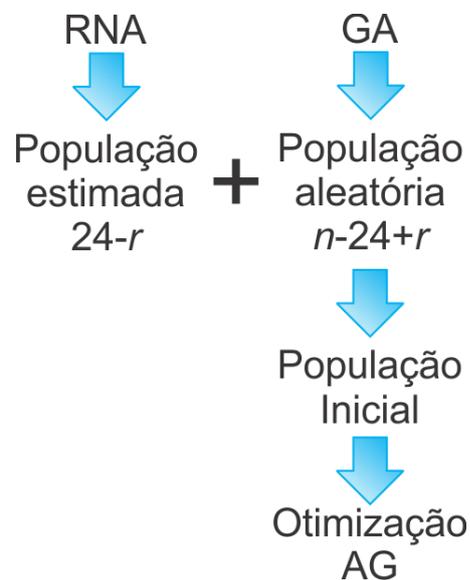


Figura 51 – Esquema de funcionamento do método de calibração híbrido

Cada setor de abastecimento foi calibrado três vezes utilizando o método híbrido e os melhores resultados obtidos via calibração para cada setor foi escolhido para ilustrar os resultados obtidos.

4 RESULTADOS E DISCUSSÃO

No presente capítulo são apresentados e discutidos os resultados obtidos utilizando os diferentes métodos. Os resultados são apresentados para cada uma das quatro redes de abastecimento, segundo os diferentes métodos de calibração usados e, no final, é feita a comparação entre cada um dos métodos.

4.1 Calibração via redes neurais

Para a calibração utilizando somente redes neurais artificiais, foram treinadas oito redes neurais construtivas, sendo uma rede neural do tipo DAN2 e uma rede neural AMGA para cada modelo de rede.

Apesar de a rede neural DAN2 apresentar resultados satisfatórios no teste de previsão de demanda, o mesmo comportamento não se verificou para a calibração. Conforme visto na revisão, os autores do método DAN2 aplicaram a rede neural a diversos dados, mas somente para o problema específico de previsão de séries temporais.

Os testes realizados durante o desenvolvimento deste trabalho demonstraram que o algoritmo de aprendizado da rede DAN2 não é apto para reproduzir satisfatoriamente o comportamento de modelos hidráulicos. Observou-se que o processo de treinamento era interrompido logo nas primeiras iterações, indicando que prosseguir com o treinamento implicaria em perda de generalização dos pesos sinápticos. Assim, essa rede neural pouco treinada se mostrou incapaz de reproduzir saídas aproveitáveis. Portanto, o trabalho prosseguiu com a utilização apenas da rede neural AMGA, omitindo os resultados produzidos via DAN2.

O treinamento das redes neurais AMGA levaram em média, menos de 15 minutos para cada um dos setores. A Figura 52 mostra o progresso do treinamento e validação para o setor Iguatemi ZA. Visualmente, verifica-se boa aderência no treinamento e validação dos dados. O resultado do Teste acompanhou a tendência do treinamento e da validação. Entretanto, conforme foi dito, este teste faz parte dos 15% do conjunto de treinamento que foi reservado previamente. O teste real da calibração foi a propagação dos dados registrados em campo nas RNA, que é discutida posteriormente.

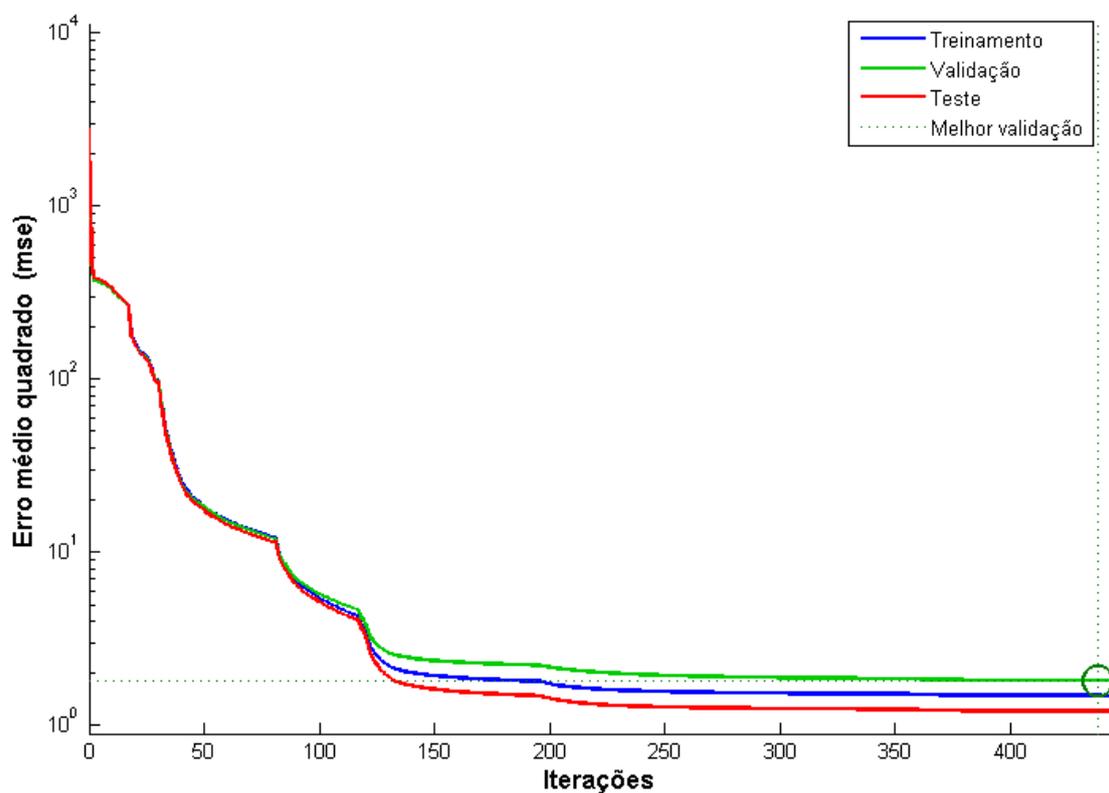


Figura 52 – Evolução do erro quadrado médio ao longo das iterações para o setor Iguatemi ZA

A Figura 53 mostra as curvas de ajuste entre o conjunto de treinamento e a rede neural treinada. Observa-se que a rede neural é capaz de reproduzir com boa eficiência o modelo hidráulico.

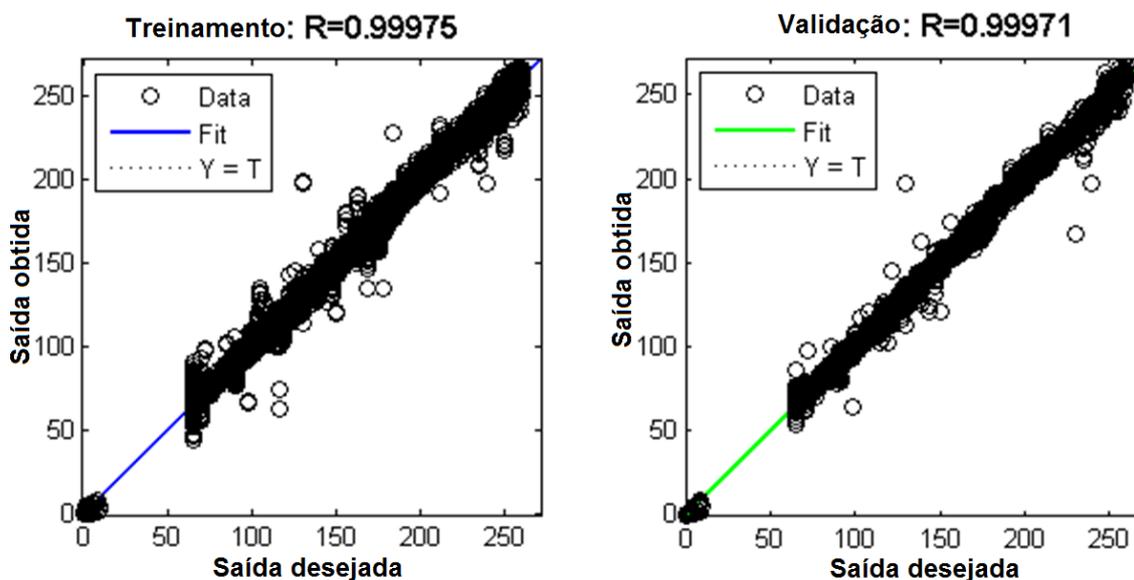


Figura 53 – Regressão entre os padrões de treinamento e os resultados obtidos pela RNA (Iguatemi ZA)

O resultado foi semelhante para o setor Iguatemi ZB. Verifica-se através da Figura 54 que a distância final entre as curvas de treinamento e validação foram menores, assim como o erro quadrado médio.

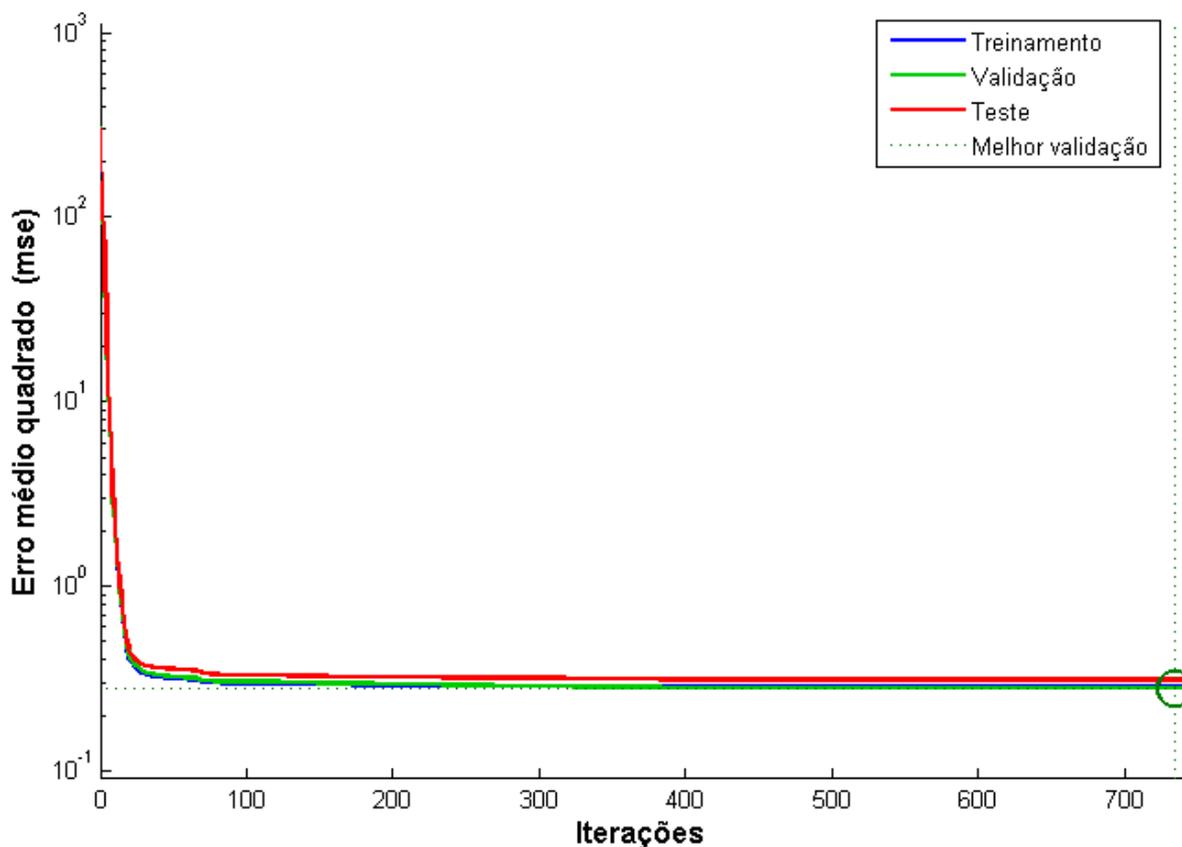


Figura 54 – Evolução do erro quadrado médio ao longo das iterações para o setor Iguatemi ZB

A Figura 55 mostra o resultado da regressão entre os padrões de treinamento e as saídas da rede neural treinada para as variáveis de decisão do setor Iguatemi ZB. Apesar da maioria dos dados se ajustarem a uma única linha de tendência, verifica-se um segundo padrão que indica insensibilidade nos coeficientes de rugosidades dentro do conjunto de treinamento. Isso ocorreu porque o Epanet produziu resultados similares para conjuntos de variáveis de decisão de valores distintos. Tais resultados são gerados a partir do Epanet quando o método de resolução não é capaz de produzir resposta para as variáveis de decisão informadas, gerando cargas de pressões negativas ou próximas a zero.

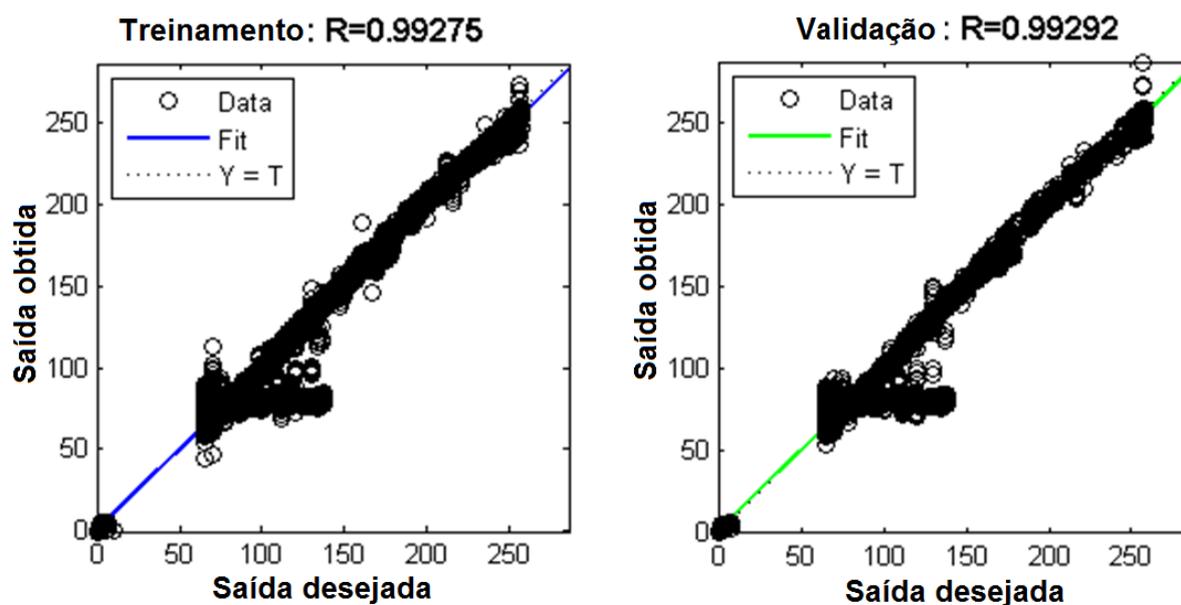


Figura 55 – Regressão entre os padrões de treinamento e os resultados obtidos pela RNA (Iguatemi ZB)

Assim como nas redes anteriores, o treinamento do setor Eliana apresentou bons resultados. Para o setor Eliana, houve a menor diferença do MSE entre o treinamento e a validação dos dados.

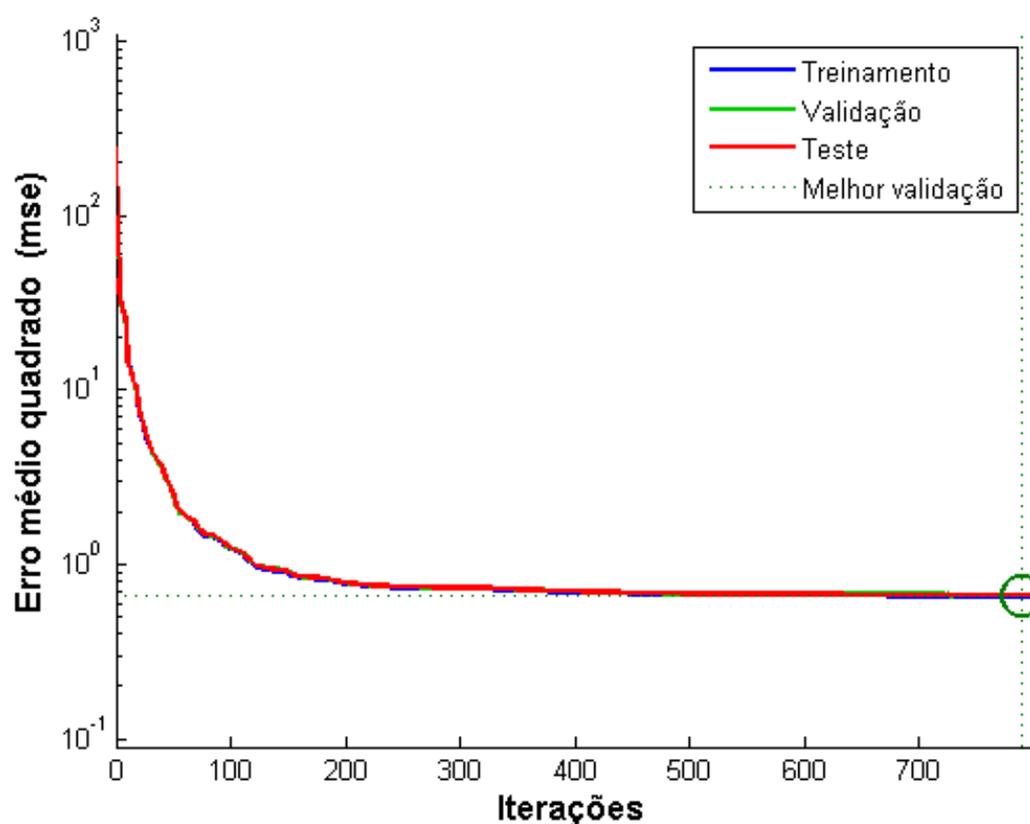


Figura 56 – Processo de treinamento da RNA para o setor Eliana.

Entre todas as redes treinadas, no setor Eliana, o coeficiente R, que mede o grau de ajuste entre o conjunto de treinamento e a saída da RNA treinada foi o mais próximo de 1 para o treinamento e validação.

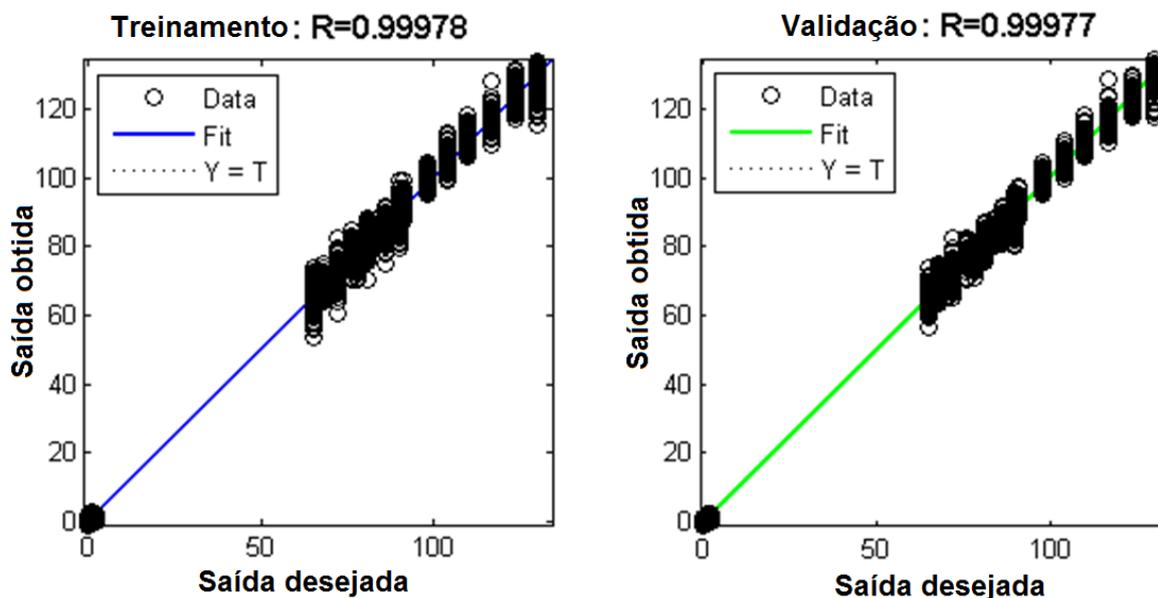


Figura 57 – Evolução do erro quadrado médio ao longo das iterações para o setor Eliana.

O setor Martinez foi o que apresentou maior erro no treinamento. O erro pode ser melhor percebido na Figura 59. Apesar do R próximo a 1, verificam-se padrões verticais nos dados. Estes padrões são causados porque as respostas produzidas pelo modelo hidráulico mostraram-se relativamente constantes ao longo do tempo. Esta informação não indica necessariamente erro na modelagem, pois o setor Martinez possui a menor variação na carga de pressão por ser abastecido por um reservatório apoiado. Entretanto, a produção recorrente de diferentes padrões de resposta conferem dificuldade de generalização à RNA treinada com esses dados.

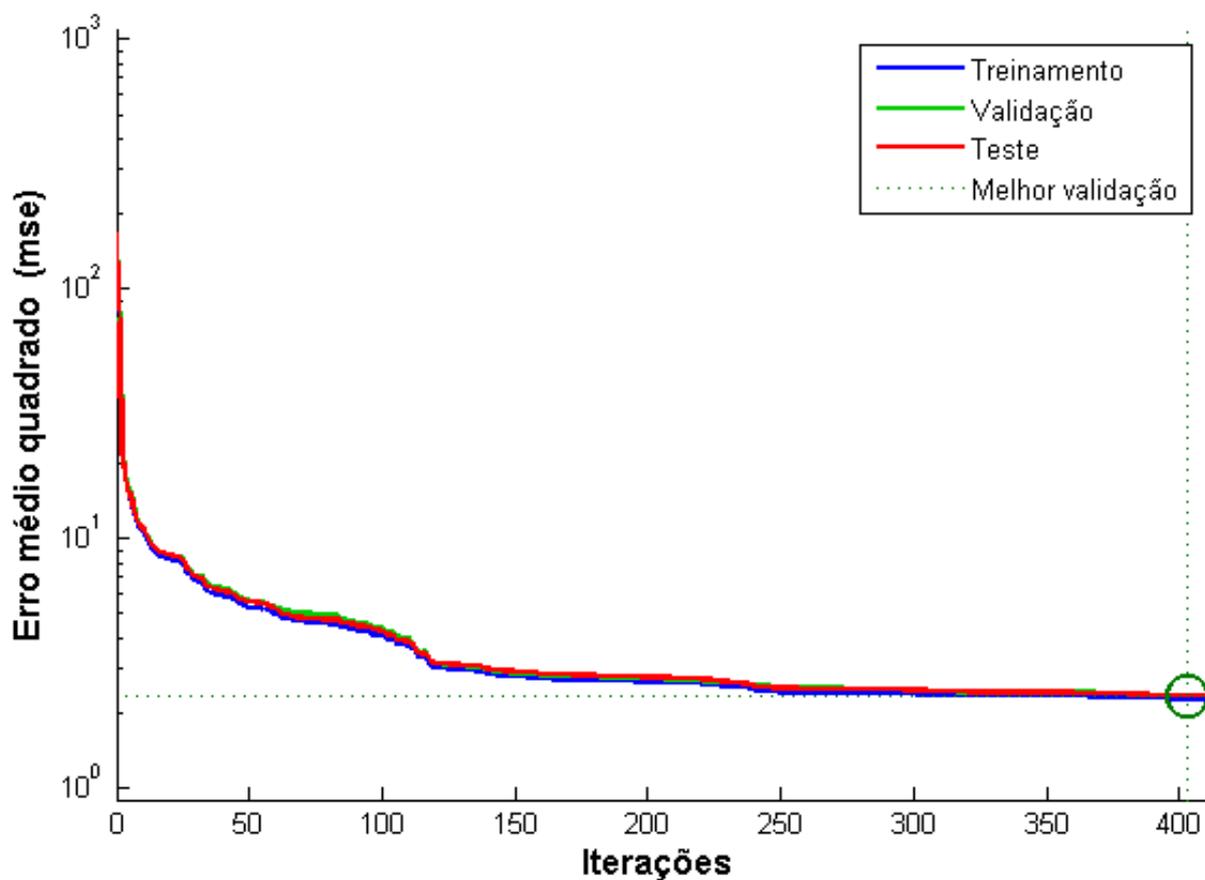


Figura 58 – Evolução do erro quadrado médio ao longo das iterações para o setor Martinez

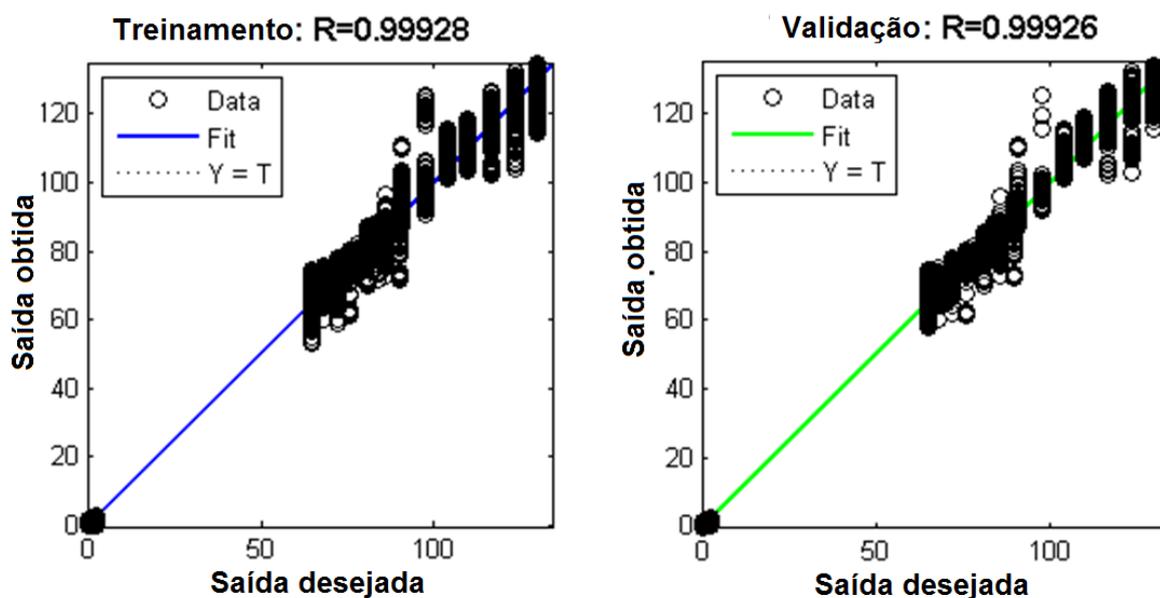


Figura 59 – Regressão entre os padrões de treinamento e os resultados obtidos pela RNA (Martinez)

Finalizados os treinamentos, as redes neurais estariam, em tese, aptas à calibração usando dados reais. Os dados de campo foram propagados pela rede neural para a obtenção das respostas (valores calibrados). A Tabela 17 lista os valores obtidos. As colunas G1, G2 e G3 representam os grupos em que o setor Iguatemi ZA foi dividido. A Tabela apresenta 24 linhas de dados para cada variável de decisão, resultado da propagação dos dados horários. Observa-se que os valores dos coeficientes de rugosidades apresentam valores semelhantes ao longo das horas. O grupo G1 de tubulações, por exemplo, apresenta diversos valores com coeficientes iguais a 65 para a rugosidade (menor valor permitido pelo software), mostrando que a rede neural foi ajustada para ampliar a perda de carga e assim concordar com os dados de campo. A rede neural identificou valores moderados para as perdas localizadas, reforçando os resultados da amostragem por hipercubo latino e apenas para as tubulações do grupo G1 foram estimados coeficientes de vazamentos.

Tabela 17 - Saídas obtidas para o setor Iguatemi Zona Alta

Hora	<i>Coef. rugosidade</i>			<i>Coef. Vazamento</i>			<i>Perda localizada</i>			α
	G1	G2	G3	G1	G2	G3	G1	G2	G3	
1	65	150	65	1,45	0	0	0,001481	0,000859	0,000230	0,462
2	65	150	150	1,37	0	0	0,001347	0,000880	0,000365	0,441
3	65	150	65	1,48	0	0	0,001446	0,000851	0,000258	0,460
4	65	150	150	1,45	0	0	0,001458	0,000888	0,000243	0,455
5	65	150	65	1,14	0	0	0,001250	0,000847	0,000516	0,435
6	65	150	150	1,45	0	0	0,001443	0,000933	0,000218	0,454
7	65	150	65	1,71	0	0	0,001361	0,000741	0,000285	0,468
8	71	127	65	1,25	0	0	0,001472	0,000852	0,000194	0,497
9	150	150	150	0,00	0	0	0,000000	0,003898	0,001671	0,644
10	65	148	65	1,40	0	0	0,001521	0,000845	0,000152	0,482
11	65	150	65	1,43	0	0	0,001560	0,000853	0,000121	0,474
12	65	148	65	1,33	0	0	0,001513	0,000854	0,000155	0,486
13	65	139	65	1,34	0	0	0,001535	0,000861	0,000149	0,480
14	65	150	65	0,91	0	0	0,001297	0,000872	0,000456	0,452
15	65	150	65	1,40	0	0	0,001503	0,000839	0,000176	0,482
16	65	150	65	1,65	0	0	0,001574	0,000828	0,000131	0,448
17	65	150	65	1,37	0	0	0,001499	0,000844	0,000185	0,481
18	65	147	65	1,36	0	0	0,001509	0,000847	0,000162	0,486
19	65	133	65	1,33	0	0	0,001524	0,000859	0,000147	0,484
20	65	150	65	1,39	0	0	0,001485	0,000834	0,000178	0,486
21	65	150	65	1,17	0	0	0,001484	0,000880	0,000247	0,466
22	65	150	65	1,43	0	0	0,001519	0,000851	0,000186	0,470
23	65	150	150	1,75	0	0	0,001443	0,001049	0,000155	0,395
24	65	150	65	1,51	0	0	0,001505	0,000840	0,000203	0,463

Os resultados da calibração utilizando redes neurais para o setor Iguatemi ZB são resumidos na Tabela 18. O setor foi dividido em três grupos utilizando como critério, o material das tubulações. Assim como no setor Iguatemi ZA, a rede neural atribuiu um grande peso para o coeficiente de rugosidade de um dos grupos, neste caso o G2. Além disso, foram identificados valores para os coeficientes de vazamentos de todos os grupos e valores relativamente altos para α , mostrando a tendência do modelo neural a aumentar as vazões através do ajuste dos vazamentos.

Tabela 18 - Saídas obtidas para o setor Iguatemi Zona Baixa

Hora	Coef. rugosidade			Coef. vazamento			Perda localizada			α
	G1	G2	G3	G1	G2	G3	G1	G2	G3	
1	71	65	150	1,1452	0,1634	1,2554	0,0034	0,0023	0,0038	0,8083
2	71	75	150	1,4080	0,0646	1,1430	0,0034	0,0020	0,0035	0,7391
3	70	65	150	1,1537	0,1487	1,2650	0,0035	0,0029	0,0040	0,7666
4	70	65	150	1,2080	0,1100	1,2156	0,0036	0,0028	0,0040	0,7537
5	70	65	150	1,1478	0,1299	1,2506	0,0035	0,0031	0,0040	0,7831
6	70	65	150	1,2543	0,1219	1,2579	0,0032	0,0037	0,0037	0,8242
7	71	65	150	1,5411	0,1738	1,3114	0,0033	0,0032	0,0033	0,7987
8	71	65	150	1,4995	0,1925	1,3322	0,0031	0,0039	0,0033	0,8126
9	71	65	150	1,6540	0,1960	1,3344	0,0031	0,0040	0,0030	0,7764
10	71	65	150	1,3834	0,5543	1,7865	0,0028	0,0039	0,0027	0,8173
11	71	65	150	1,8812	0,1986	1,3276	0,0032	0,0039	0,0027	0,7445
12	71	65	150	1,1477	1,0590	2,4555	0,0025	0,0026	0,0022	0,8636
13	71	65	150	1,8047	0,3202	1,4920	0,0031	0,0033	0,0028	0,7877
14	71	65	150	1,7903	0,1975	1,3392	0,0032	0,0035	0,0030	0,7718
15	71	65	150	1,6000	0,2758	1,4458	0,0031	0,0033	0,0033	0,8205
16	72	65	150	1,6928	0,1073	1,2222	0,0032	0,0039	0,0033	0,7931
17	71	65	150	1,1156	0,9065	2,2506	0,0026	0,0031	0,0028	0,9040
18	71	65	150	0,2606	1,9102	3,5556	0,0016	0,0024	0,0018	1,0001
19	70	65	150	0,9402	1,1604	2,6005	0,0021	0,0026	0,0022	0,9070
20	71	65	150	1,8085	0,2062	1,3536	0,0031	0,0030	0,0030	0,7848
21	71	78	150	1,5479	0,2537	1,4060	0,0031	0,0024	0,0030	0,8160
22	71	65	150	1,3817	0,2485	1,4011	0,0031	0,0027	0,0034	0,8391
23	71	65	150	1,3305	0,2008	1,3318	0,0032	0,0027	0,0036	0,8341
24	71	65	150	1,0286	0,2713	1,4081	0,0033	0,0026	0,0039	0,8518

Para o setor Eliana, os resultados (Tabela 19) também tenderam a diminuir a carga de pressão com o aumento da perda de carga nos grupos G1 e G3, e a atribuição de vazamento somente no grupo G1. Embora os coeficientes de vazamentos tenham sido atribuídos somente a esse grupo, a ordem de magnitude deste foi bem superior aos dos outros setores, revelando que a rede modelada original subestima a vazão real.

Tabela 19 - Saídas obtidas para o setor Eliana

Hora	Coef. rugosidade			Coef. vazamento			Perda localizada			α
	G1	G2	G3	G1	G2	G3	G1	G2	G3	
1	65	150	65	9,152215	0	0	0,000936	0,002322	0,001121	0,5
2	65	150	65	9,145697	0	0	0,000936	0,002322	0,00112	0,5
3	65	150	65	9,154829	0	0	0,000936	0,002322	0,00112	0,5
4	65	150	65	9,170018	0	0	0,000936	0,002321	0,001121	0,5
5	65	150	65	9,188113	0	0	0,000936	0,002321	0,001121	0,5
6	65	150	65	9,086688	0	0	0,000944	0,002313	0,001123	0,5
7	65	150	65	8,690233	0	0	0,00095	0,002344	0,001116	0,5
8	65	150	65	9,002861	0	0	0,00095	0,002337	0,001121	0,5
9	65	150	65	9,144368	0	0	0,00094	0,002321	0,001122	0,5
10	65	150	65	8,857109	0	0	0,000944	0,002333	0,001118	0,5
11	65	150	65	8,625371	0	0	0,000943	0,002334	0,001114	0,5
12	65	150	65	8,817518	0	0	0,000963	0,002355	0,001118	0,5
13	65	150	65	9,011882	0	0	0,000941	0,00233	0,00112	0,5
14	65	150	65	9,055037	0	0	0,000943	0,002324	0,001122	0,5
15	65	150	65	10,19464	0	0	0,000932	0,002281	0,00114	0,5
16	65	150	65	8,932913	0	0	0,000944	0,002333	0,001119	0,5
17	65	150	65	8,570157	0	0	0,00095	0,002345	0,001114	0,5
18	65	150	65	8,805004	0	0	0,000943	0,002336	0,001117	0,5
19	65	150	65	9,149432	0	0	0,000958	0,002337	0,001125	0,5
20	65	150	65	8,469804	0	0	0,000951	0,002351	0,001112	0,5
21	65	150	65	8,963037	0	0	0,000953	0,00234	0,001121	0,5
22	65	150	65	9,072643	0	0	0,000959	0,002343	0,001123	0,5
23	65	150	65	9,148785	0	0	0,000936	0,002322	0,001121	0,5
24	65	150	65	9,217357	0	0	0,000937	0,002321	0,001122	0,5

Assim como os demais setores, o setor Martinez apresentou um dos grupos com valores elevados para os coeficientes de perda de carga localizada (G3), conforme indicações da Tabela 20. No modelo hidráulico, todos os nós são relacionados através das equações hidráulicas e uma alteração nas variáveis de decisão afetam todo o sistema de modo previsível. Assim, um sistema de calibração pode ser programado de modo encontrar o menor erro médio entre os pontos de interesse, ou até mesmo privilegiar a calibração de determinados pontos através do uso de pesos. A rede neural artificial, no entanto, funciona como um modelo caixa-preta em que não se sabe exatamente o que está sendo efetuado neste tipo de modelo. Pela observação das calibrações das diversas redes, pode-se concluir que a rede neural não busca o erro médio para todos os pontos, mas privilegia pontos, provavelmente os pontos mais sensíveis em detrimento dos demais.

Tabela 20 - Saídas obtidas para o setor Iguatemi Martinez

Hora	Coef. rugosidade			Coef. vazamento			Perda localizada			α
	G1	G2	G3	G1	G2	G3	G1	G2	G3	
1	72	150	65	0,0000	1,2132	0,0000	0,0002	0,0000	0,0034	1,2145
2	70	143	65	0,0000	1,1838	0,0000	0,0001	0,0001	0,0037	1,1975
3	69	134	65	0,0000	1,1112	0,0000	0,0002	0,0002	0,0038	1,1974
4	69	128	65	0,0000	1,1778	0,0000	0,0001	0,0001	0,0038	1,1866
5	66	103	65	0,2630	1,0041	0,0000	0,0003	0,0000	0,0038	1,1388
6	65	102	150	0,7926	0,1868	0,0000	0,0012	0,0000	0,0034	0,8101
7	66	141	136	1,0073	0,4999	0,0000	0,0012	0,0000	0,0031	0,9827
8	67	150	79	0,8572	0,7360	0,0000	0,0011	0,0000	0,0027	1,0837
9	69	150	65	0,0446	0,9407	0,0000	0,0008	0,0000	0,0028	1,1801
10	73	150	65	0,0000	1,3065	0,0000	0,0004	0,0000	0,0029	1,2052
11	71	150	65	0,0000	1,2597	0,0000	0,0005	0,0000	0,0028	1,1958
12	75	150	65	0,0000	1,2541	0,0000	0,0005	0,0000	0,0028	1,2483
13	75	150	65	0,0000	1,2038	0,0000	0,0005	0,0000	0,0028	1,2520
14	73	150	65	0,0000	1,2617	0,0000	0,0005	0,0000	0,0028	1,2199
15	71	150	65	0,0000	1,2396	0,0000	0,0005	0,0000	0,0029	1,2059
16	69	150	65	0,1800	0,9624	0,0000	0,0007	0,0000	0,0029	1,1745
17	70	150	65	0,0000	1,1431	0,0000	0,0005	0,0000	0,0030	1,2004
18	68	150	65	0,8860	0,3384	0,0000	0,0015	0,0000	0,0026	1,0291
19	73	150	65	0,0000	1,2196	0,0000	0,0004	0,0000	0,0030	1,2268
20	76	150	65	0,0000	1,2168	0,0000	0,0005	0,0000	0,0027	1,2817
21	74	150	65	0,0000	1,2215	0,0000	0,0004	0,0000	0,0029	1,2375
22	74	150	65	0,0000	1,2017	0,0000	0,0004	0,0000	0,0030	1,2363
23	72	150	65	0,0000	1,1944	0,0000	0,0004	0,0000	0,0032	1,2236
24	73	150	65	0,0000	1,2152	0,0000	0,0003	0,0000	0,0032	1,2301

4.2 Calibração via algoritmos genéticos

Os parâmetros obtidos através da calibração via algoritmos genéticos diferiram bastante daqueles identificados pelo primeiro método. A calibração tradicional através de algoritmos genéticos mostrou-se superior à calibração através de redes neurais artificiais puramente.

Conforme discutido, a calibração através dos algoritmos genéticos altera parâmetros diretamente no modelo hidráulico, sendo possível controlar de modo mais preciso, não só o erro total, mas o erro individual de cada nó e trecho da rede com dados observados. Diferentemente, a rede neural não está sujeita às restrições físicas e busca ajustar o modelo para as condições dadas, com menor controle sobre cada parâmetro.

A Tabela 21 lista os resultados obtidos para o setor Iguatemi ZA. Ao contrário da calibração através da RNA, o algoritmo genético diminuiu a perda de carga dos grupos, aumentando o fator de Hazen-Willians e mantendo nula a perda de carga localizada.

Tabela 21 – Parâmetros calibrados para o setor Iguatemi ZA.

Parâmetros	Grupo	Grupo	Grupo
	1	2	3
Coef. rugosidade inicial	130	90	70
Coef. rugosidade calibrada	193	192	193
Coeficiente de vazamento inicial	0	0	0
Coeficiente calibrado	0,21	0,98	0
Perda de carga localizada inicial	0	0	0
Perda de carga localizada calibrada	0	0	0
Expoente de vazamento inicial		0,5	
Expoente de vazamento calibrado		0,5	

Nota-se que para o setor Iguatemi ZB os coeficientes de rugosidades calibradas aproximam-se dos valores originais (Tabela 22). Outro fator importante foi a não inserção de vazamentos, ao contrário da RNA (o expoente encontrado é desprezado, pois o coeficiente é aproximadamente igual a zero). Apesar do resultado superior do algoritmo genético quando comparado aos da RNA, o vazamento encontrado na RNA é mais realístico pois na prática não existe rede sem vazamento. Entretanto, mesmo a atribuição de pequenos valores para os vazamentos levam ao incremento da vazão para valores superiores aos das vazões observadas, devido à grande quantidade de nós, fazendo com que o algoritmo genético privilegie os coeficientes de vazamento iguais a zero.

Tabela 22 – Parâmetros calibrados para o setor Iguatemi ZB.

Parâmetros	Grupo	Grupo	Grupo
	1	2	3
Coef. rugosidade inicial	130	90	70
Coef. rugosidade calibrada	122	103	87
Coeficiente de vazamento inicial	0	0	0
Coeficiente calibrado	0	0	0
Perda de carga localizada inicial	0	0	0
Perda de carga localizada calibrada	24,61	18,44	25
Expoente de vazamento inicial		0,5	
Expoente de vazamento calibrado		0,5	

A calibração da rede Eliana, produziu os resultados listados na Tabela 23, com valores mais próximos dos valores teóricos da literatura, com pequenas diferenças para os coeficientes de rugosidade e perda de carga localizada, e valores baixos para os vazamentos nos grupos 1 e 2.

Tabela 23 – Parâmetros calibrados para o setor Eliana.

Parâmetros	Grupo	Grupo	Grupo
	1	2	3
Coef. rugosidade inicial	130	90	70
Coef. rugosidade calibrada	135	85	149
Coeficiente de vazamento inicial	0	0	0
Coeficiente calibrado	0,2	0,1	0
Perda de carga localizada inicial	0	0	0
Perda de carga localizada calibrada	2,72	2,89	0
Expoente de vazamento inicial		0,5	
Expoente de vazamento calibrado		0,5	

O setor Martinez foi o que apresentou a maior diferença entre os valores teóricos e os valores calibrados. A calibração através da RNA também foi a que apresentou menor uniformidade para as variáveis de decisão obtidas ao longo do tempo (Tabela 24).

Tabela 24 – Parâmetros calibrados para o setor Martinez

Parâmetros	Grupo	Grupo	Grupo
	1	2	3
Coef. rugosidade inicial	130	70	90
Coef. rugosidade calibrada	190	119	85
Coeficiente de vazamento inicial	0	0	0
Coeficiente calibrado	0	0,1	6
Perda de carga localizada inicial	0	0	0
Perda de carga localizada calibrada	0	0	0
Expoente de vazamento inicial		0,5	
Expoente de vazamento calibrado		0,5	

4.3 Calibração híbrida

Os quatro setores (Iguatemi Zona Alta, Iguatemi Zona Baixa, Eliana e Martinez) foram calibrados utilizando três métodos (calibração tradicional via algoritmos genéticos, calibração via redes neurais e calibração híbrida).

As calibrações realizadas usando redes neurais artificiais resultaram piores valores, demonstrando que o método utilizado individualmente não é viável, ou que necessita de aprimoramentos.

A Tabela 25 lista os resultados obtidos para cada setor, assim como o tempo de calibração. A coluna “Min. FO” representa o valor da função objetivo (Equação 38) e o “Tempo” representa o tempo de processamento computacional da calibração. Não se considerou o tempo de treinamento da RNA porque ele é efetuado apenas uma vez, enquanto espera-se que a calibração seja realizada periodicamente, como um procedimento rotineiro. Os resultados da calibração realizada utilizando o método híbrido foram superiores para os

setores Iguatemi ZA, Iguatemi ZB e Martinez, mas inferiores para o setor Eliana. Quanto menor o valor de “Min. FO”, menor o erro, ou seja, melhor é a concordância entre os valores registrados em campo e os correspondente valores resultantes da calibração. No entanto, os valores de “Min. FO” são particulares para cada rede, ou seja, um número menor para o “Min. FO” para a calibração de uma rede não significa, necessariamente, que a calibração para esta rede seja melhor do que um “Min. FO” que obteve valor maior em outra rede.

A quantidade de pontos de monitoramento e a magnitude dos dados de campo influenciam nos valores finais da minimização da função objetivo. Além disso, os gráficos exibidos na sequência ilustram que a pequena diferença de erro entre a calibração via método tradicional e via método híbrido são bastantate pequenas. Sendo assim, a maior vantagem do método híbrido é, de fato, a velocidade com que a calibração é realizada para todas as redes testadas.

Tabela 25 – Resultado da calibração dos setores com diferentes métodos

Setor	Algoritmos Genéticos		Redes neurais		Método híbrido	
	Min. FO	Tempo	Min. FO	Tempo	Min. FO	Tempo
Iguatemi ZA	0,93274	12h45min	3,8794	-	0,9327	26m14s
Iguatemi ZB	2,6347	6h16min	6,4213	-	2,5688	1h09min
Eliana	2,99406	2h37min	8,326	-	3,02914	2min12s
Martinez	1,3204	9h23min	28,887	-	1,1764	2h40min

A Figura 60 ilustra o processo de minimização do erro da função objetivo para o setor Iguatemi ZA. A linha vermelha indica a convergência da calibração através do método híbrido e a linha azul, a calibração utilizando algoritmos genéticos. Através do gráfico, pode-se verificar visualmente que as soluções iniciais inseridas através das redes neurais oferecem uma grande vantagem no processo de otimização e possibilitam a finalização da calibração com economia do tempo de processamento.

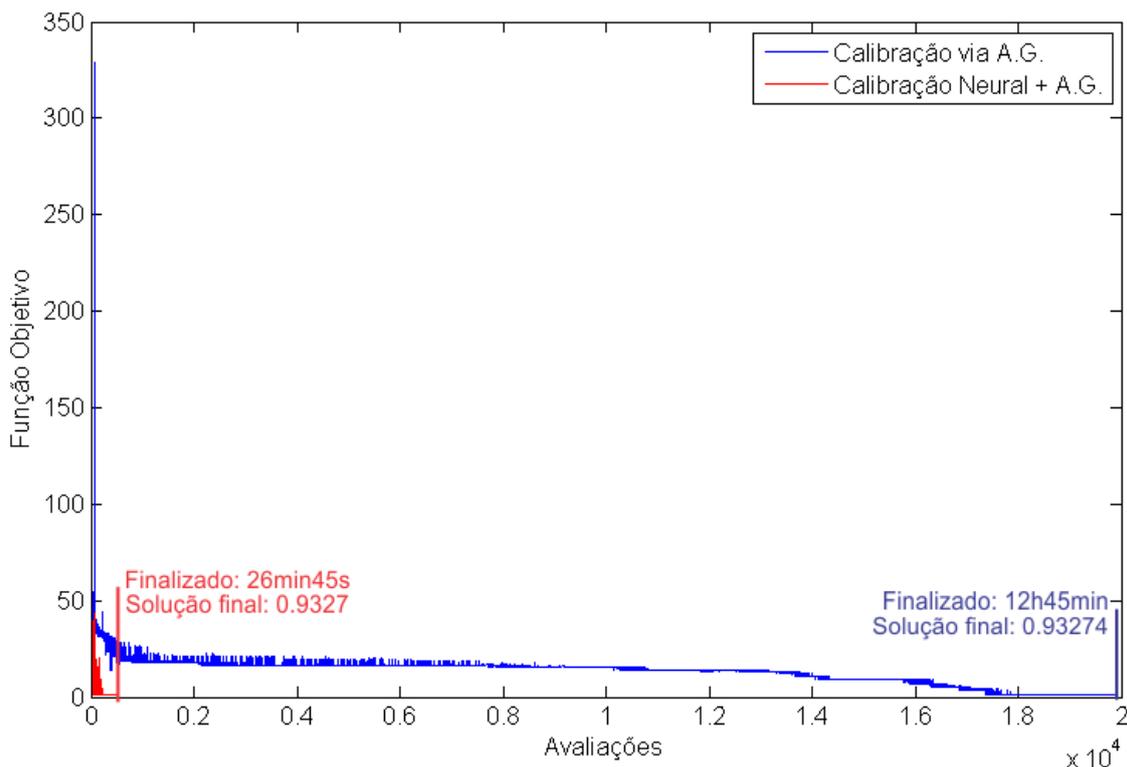


Figura 60 - Convergência da calibração – Iguatemi ZA

As Figuras 61-67 possibilitam a visualização das diferenças entre valores de carga de pressão obtidos através dos três métodos de calibração estudados e os correspondentes valores observados. A calibração utilizando redes neurais (linha verde) apresenta o pior desempenho para todos os pontos calibrados, enquanto os métodos tradicional (linha vermelha) e híbrido (ciano) alternam-se com valores muito próximos aos valores medidos em campo. A Figura 68 permite a visualização dos resultados da calibração em termos da vazão de entrada do setor. Verifica-se então uma diferença maior entre a calibração através dos AG e do método híbrido, sugerindo a potencialidade do método híbrido em produzir resultados melhores quando comparados aos do método tradicional (AG). A área sombreada nas figuras representa o limite adotado no Reino Unido para que os resultados dos modelos sejam considerados bem calibrados. Para os limites, foram utilizados intervalos de ± 5 m.c.a. dos valores de cargas de pressões obtidas em campo. Conforme visto na revisão, este valor está no limite do intervalo para modelos serem considerados bem calibrados utilizando dados de qualidade. Para todos os pontos calibrados, as simulações obtidas através do modelo calibrado via método híbrido mantiveram-se dentro dos limites aceitáveis. A calibração através do AG também manteve-se dentro dos limites aceitáveis, com resultados bastante

semelhantes às obtidas pelo método híbrido, com exceção de dois instantes, às 18h e 19h nos nós n48 (Figura 61) e n398 (Figura 67), quando as cargas de pressões ficaram abaixo do limite esperado.

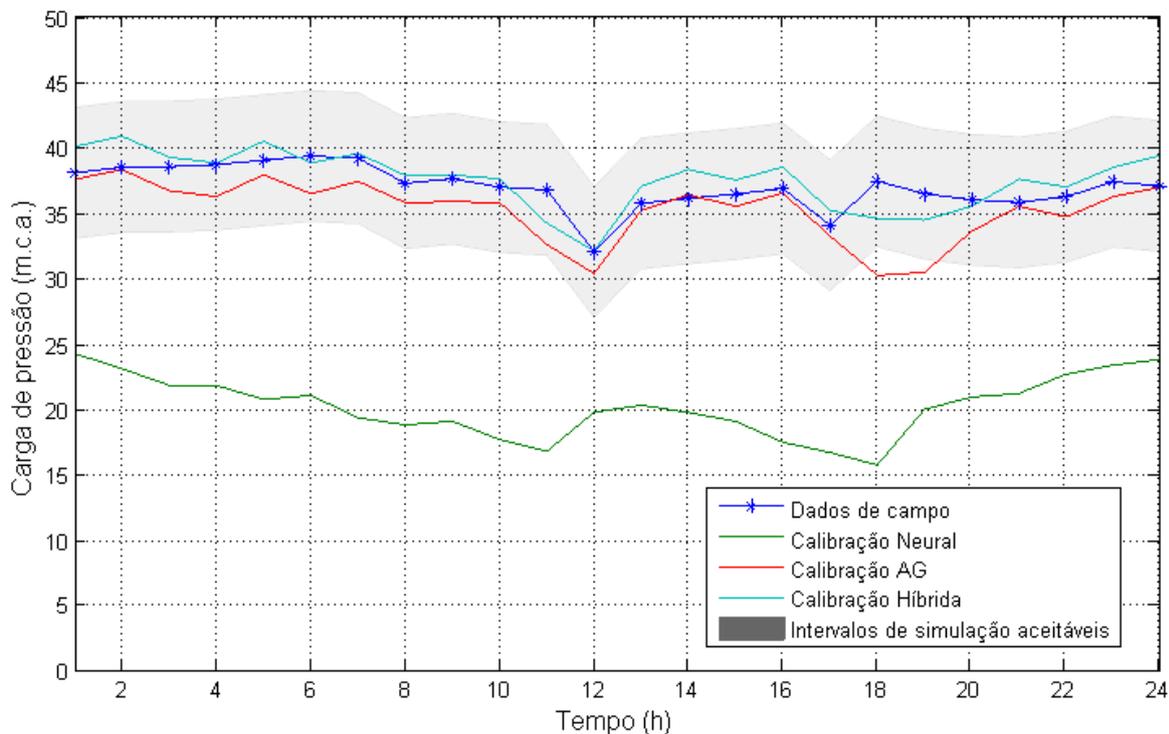


Figura 61 – Iguatemi ZA – Calibração do Nó 48

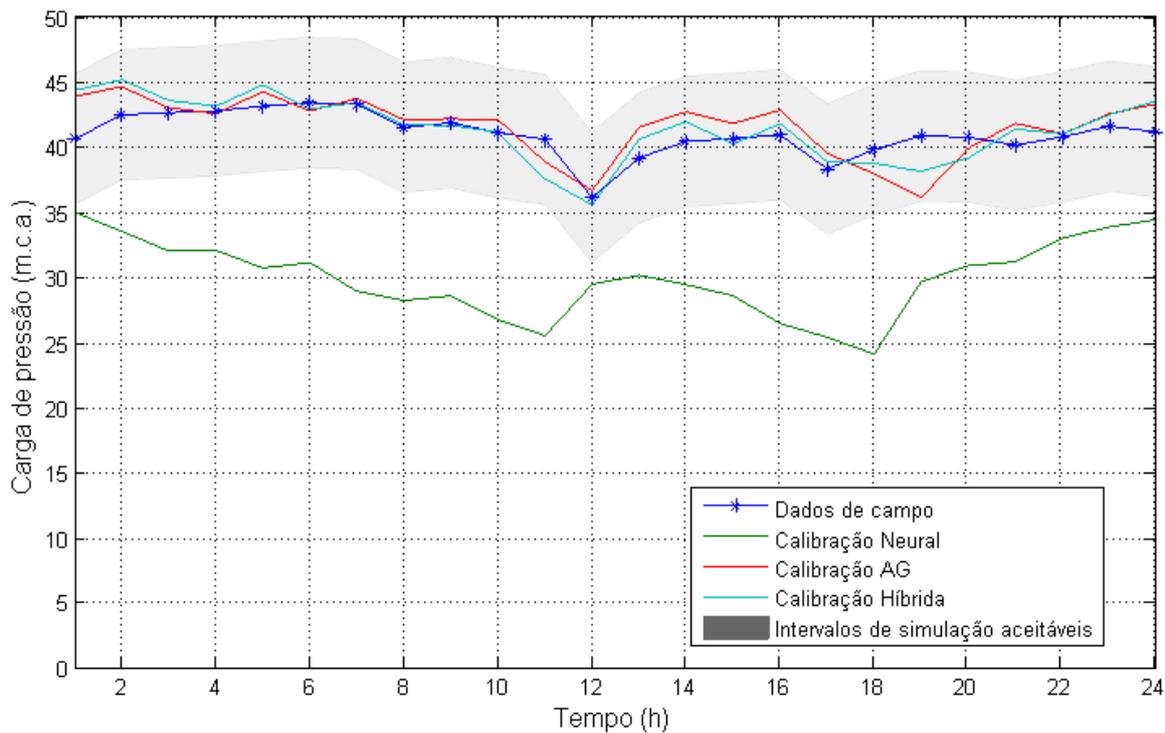


Figura 62 – Iguatemi ZA – Calibração do Nó 101

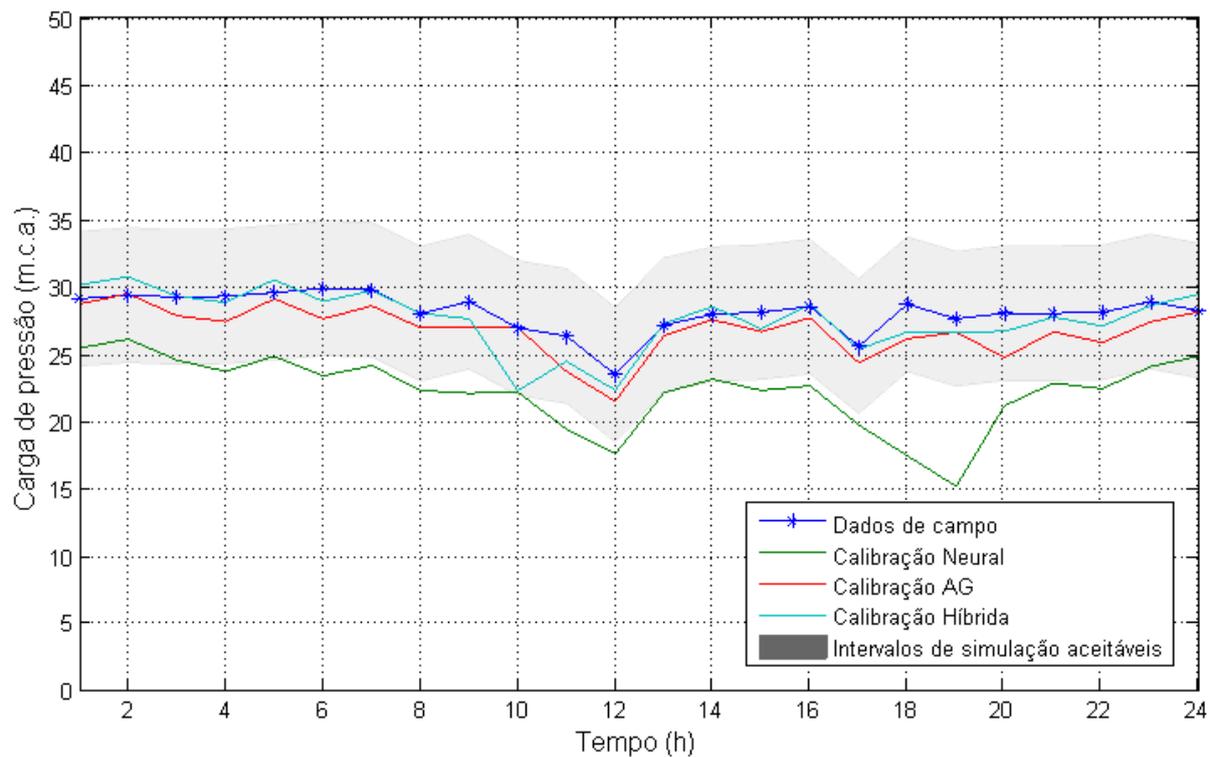


Figura 63 – Iguatemi ZA – Calibração do Nó 109

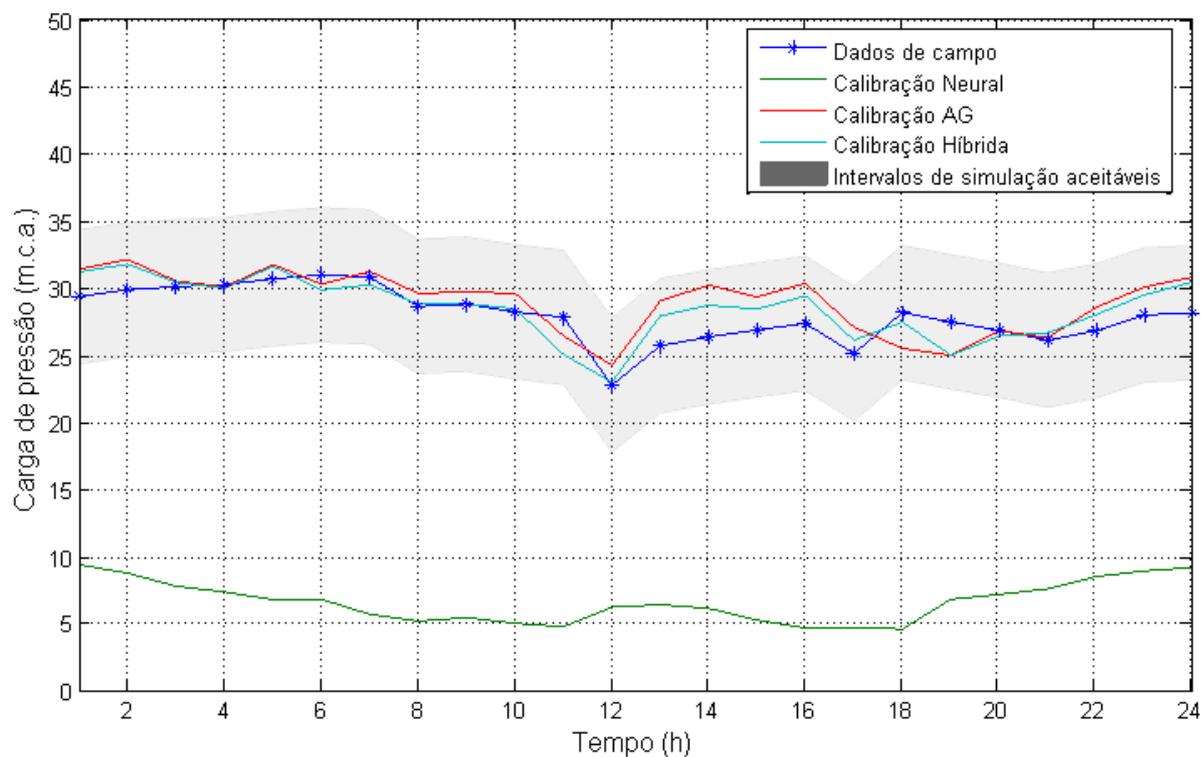


Figura 64 – Iguatemi ZA – Calibração do Nó 122

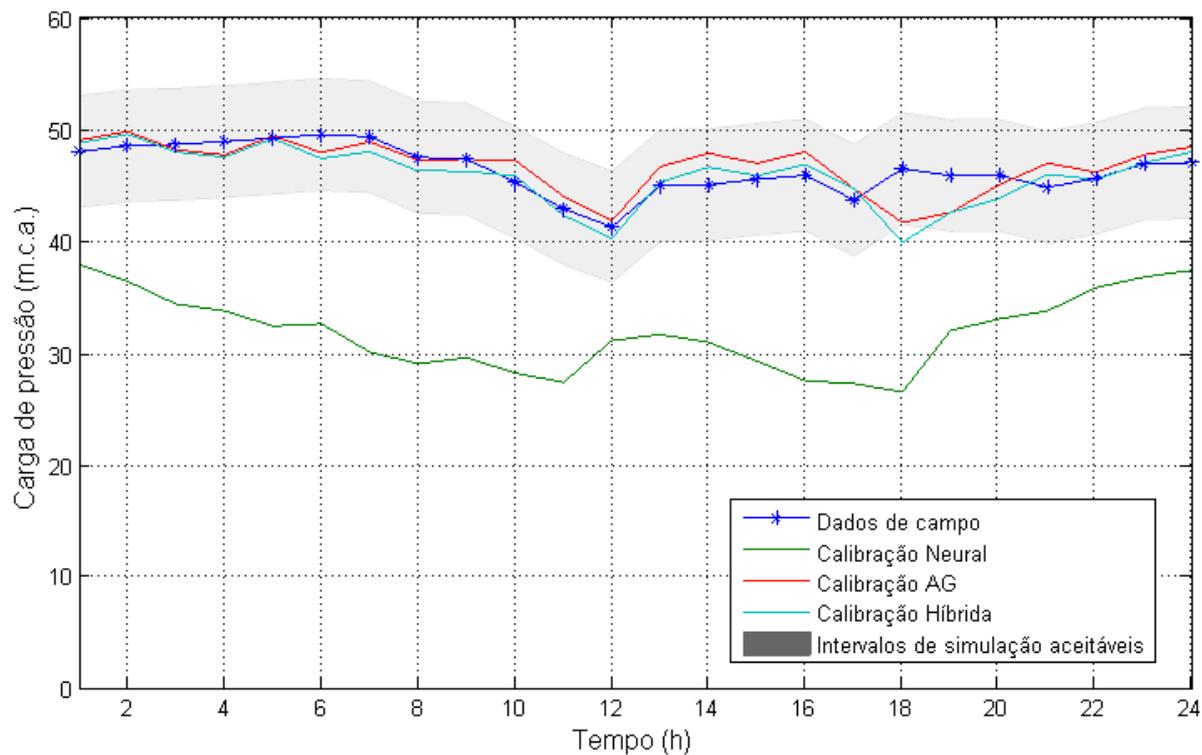


Figura 65 – Iguatemi ZA – Calibração do Nó 264

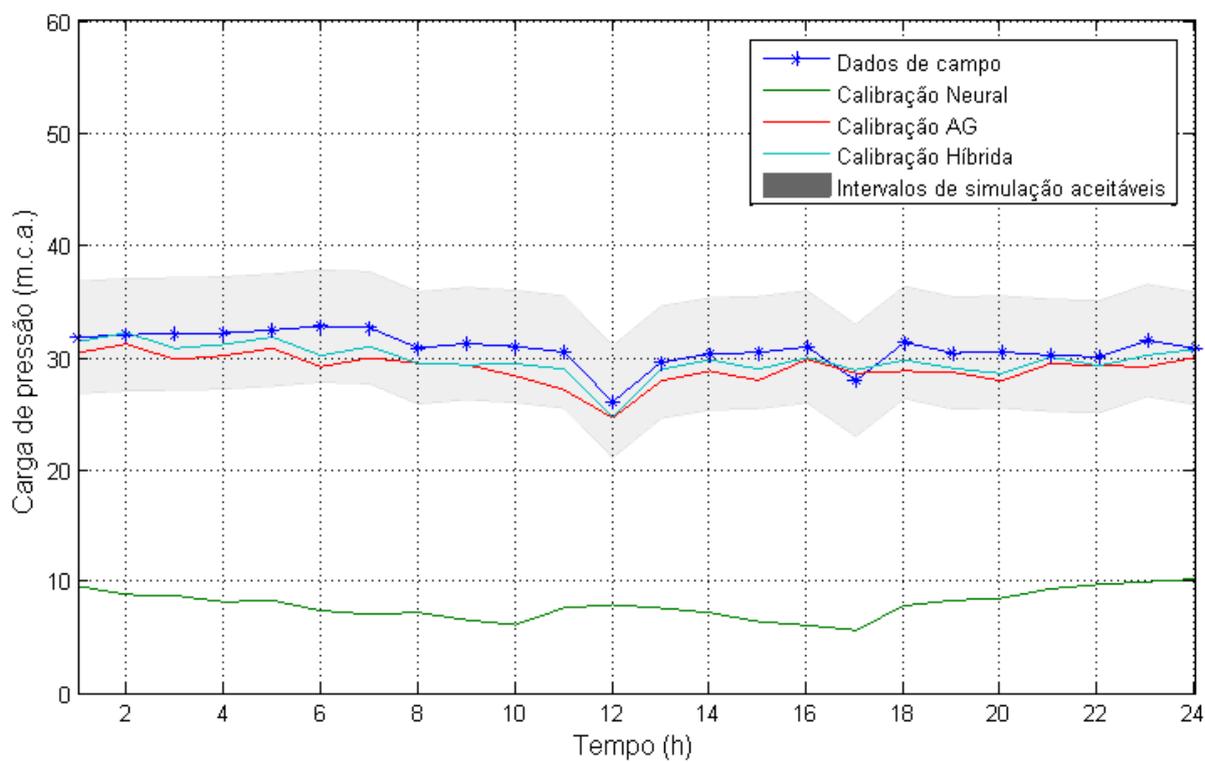


Figura 66 – Iguatemi ZA – Calibração do Nó 276

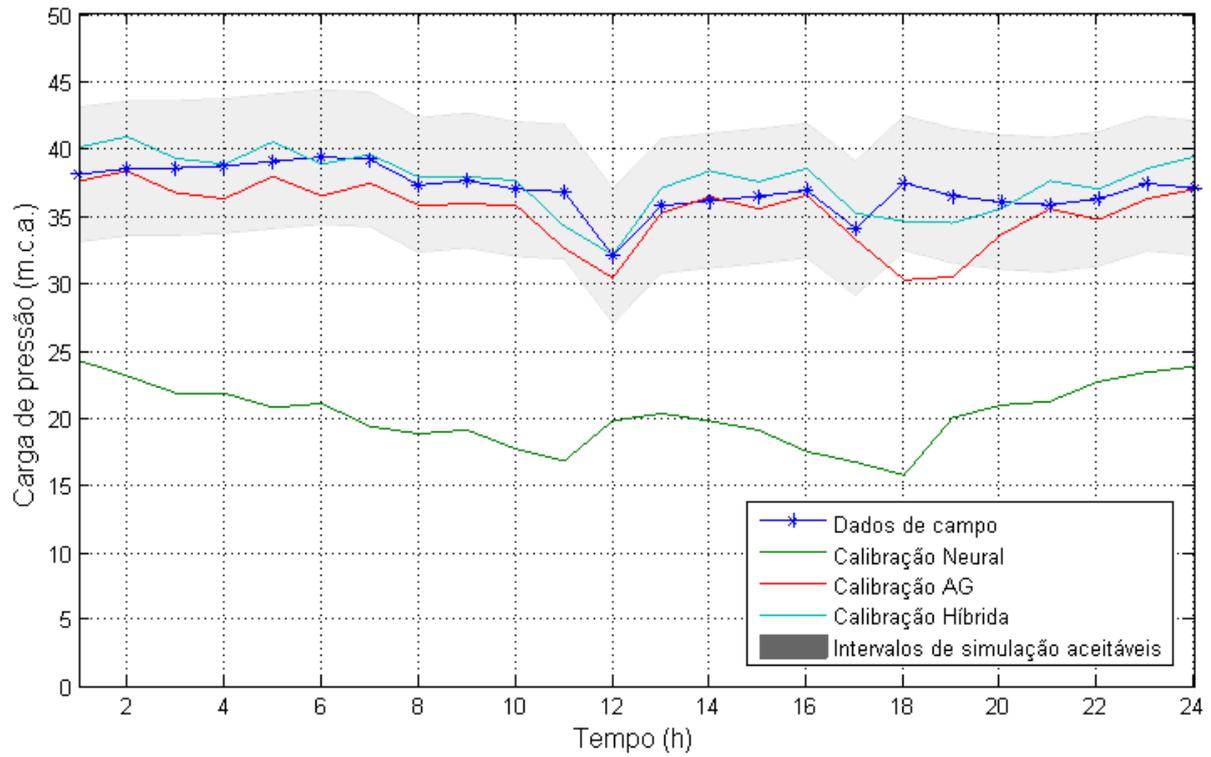


Figura 67 – Iguatemi ZA – Calibração do Nó 398

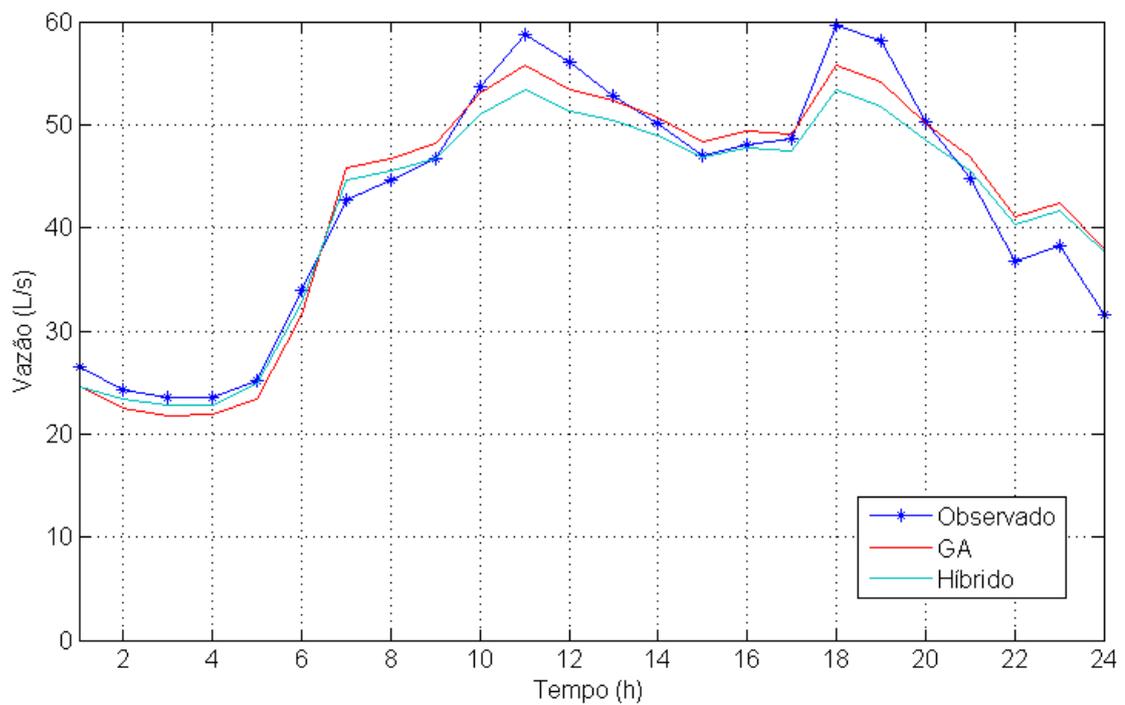


Figura 68 – Iguatemi ZA – Calibração do Trecho 5

A Figura 69 mostra o gráfico de correlação do resultado das calibrações em termos de variáveis de estado utilizando os três métodos. Analisando o gráfico observa-se que a maior correlação (R) é entre os valores obtidos entre o algoritmo genético e o método híbrido ($R=0.9168$). Esse resultado é esperado, pois ambos os métodos utilizam o algoritmo genético e as mesmas equações de resolução hidráulica. O dado de maior interesse é o valor mais próximo a 1 na primeira linha. Neste caso, verifica-se que a melhor correlação é entre o valor Observado e a calibração híbrida. A calibração através de AG também foi satisfatória, embora apresente um ruído nos valores e a calibração através da RNA apresenta baixa correlação com os valores observados. Os valores dos coeficientes podem ser melhor visualizados na Tabela 26.

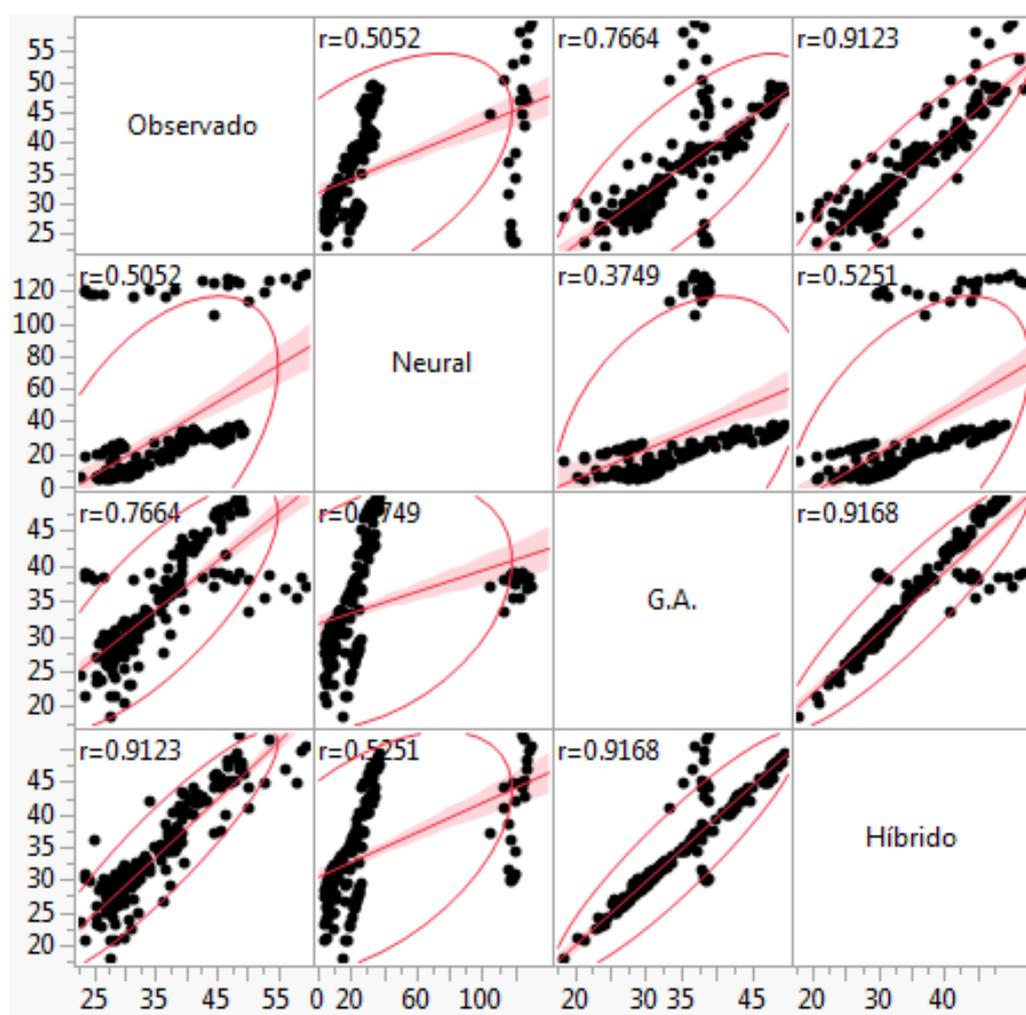
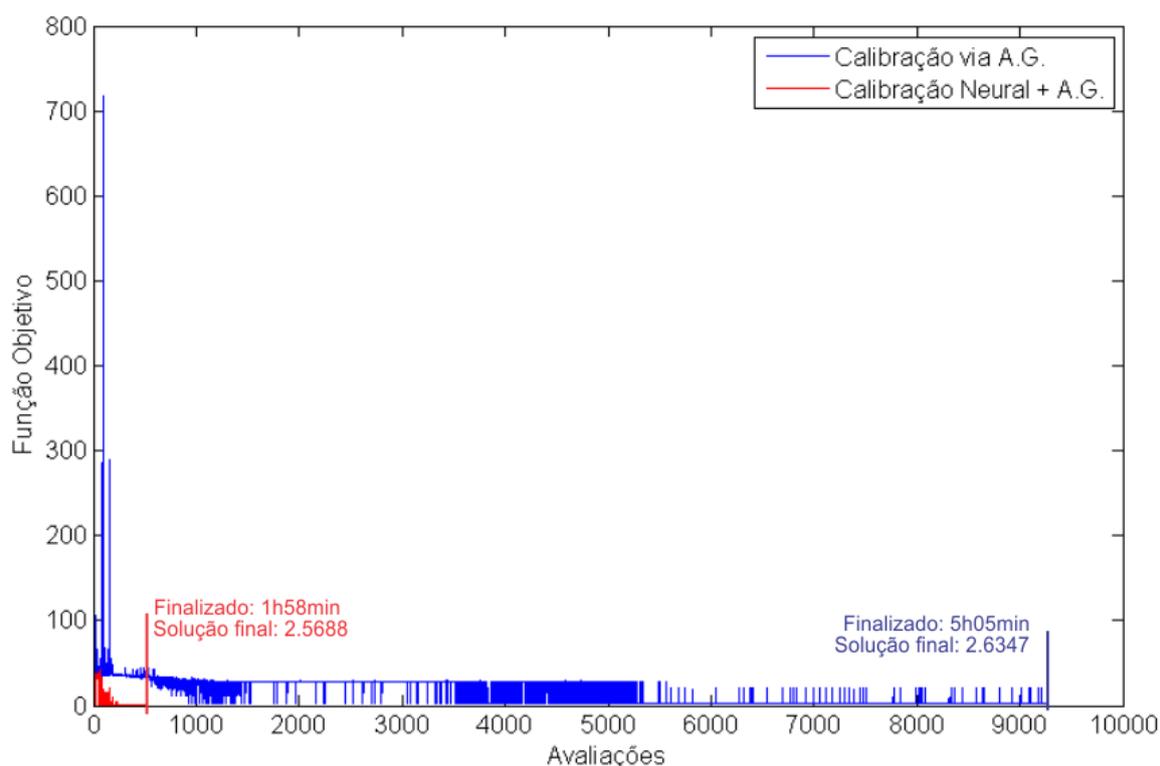


Figura 69 – Gráfico de regressão multivariada do setor Iguatemi ZA

Tabela 26 - Matriz de correlação esparsa para o setor Iguatemi ZA

	Observado	Neural	A.G.	Híbrido
Observado	1,0000	0,5052	0,7664	0,9123
Neural	0,5052	1,0000	0,3749	0,5251
A.G.	0,7664	0,3749	1,0000	0,9168
Híbrido	0,9123	0,5251	0,9168	1,0000

A Figura 70 mostra o processo de calibração para o setor Iguatemi ZB. A calibração através do método híbrido (linha vermelha) já se inicia com soluções iniciais melhores, enquanto a calibração através dos algoritmos genéticos (linha azul) inicia-se com altos valores para a função objetivo e só atinge o valor ótimo depois de 5h05min de processamento.

**Figura 70 - Convergência da calibração – Iguatemi ZB**

As Figuras 71-78 mostram os resultados das calibrações para os pontos monitorados do setor. Em geral, os resultados das calibrações foram satisfatórios através dos métodos dos algoritmos genéticos (linha vermelha) e através do método híbrido (linha verde). O nó 226

(Figura 75) constituiu uma exceção, para o qual a carga de pressão calibrada apresentou diferenças de até 10 m.c.a. em relação aos valores observados, para alguns horários. As simulações produzidas para o nó 587 (Figura 77) ajustaram-se bem para a maior parte dos horários, com exceção das 13h e 19h. Nesses dois horários, ocorreram quedas bruscas na carga de pressão que não puderam ser representadas pelos modelos calibrados. Como esses horários correspondem aos horários de pico de consumo de água, os valores de carga de pressão medidos em campo podem estar sofrendo influência do consumo de água na residência onde medidor foi instalado. Diferentemente das cargas de pressões, a vazão calibrada através do AG apresentou diferenças significativas em relação a calibração híbrida. A calibração pelo método híbrido aproximou-se mais dos valores observados, entretanto a vazão foi subestimada por todos os métodos utilizados.

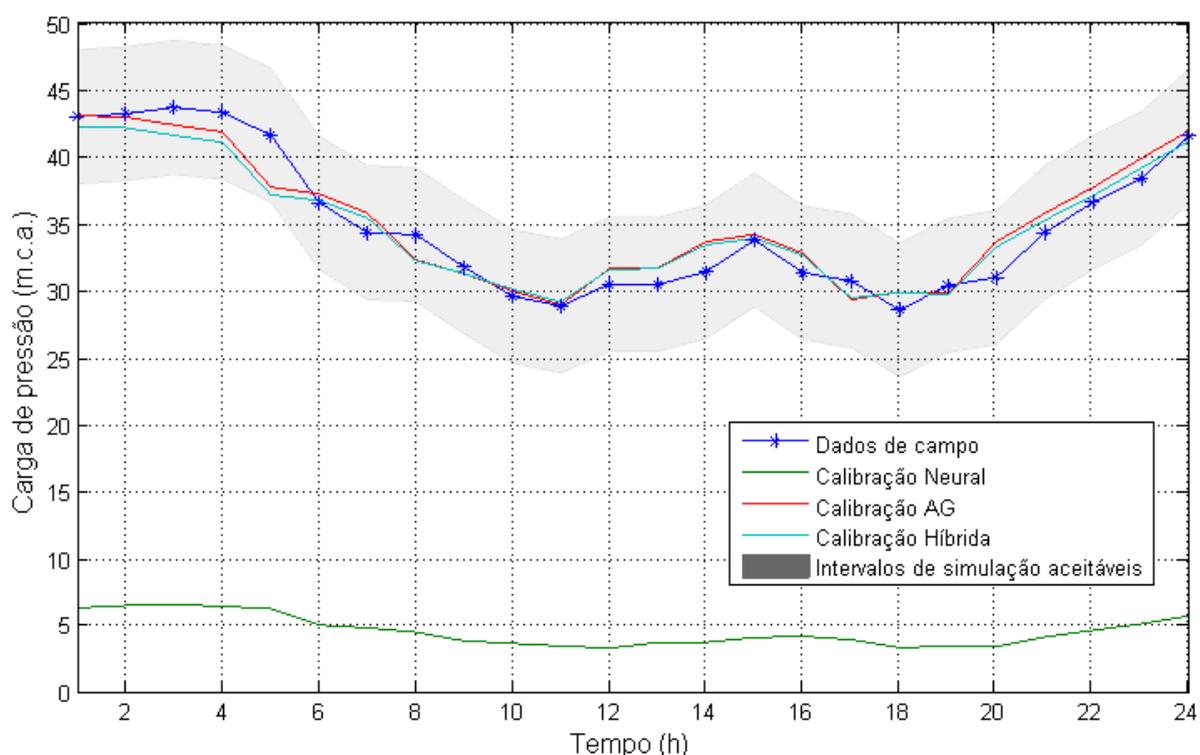


Figura 71 - Iguatemi ZB – Calibração do Nó n35f

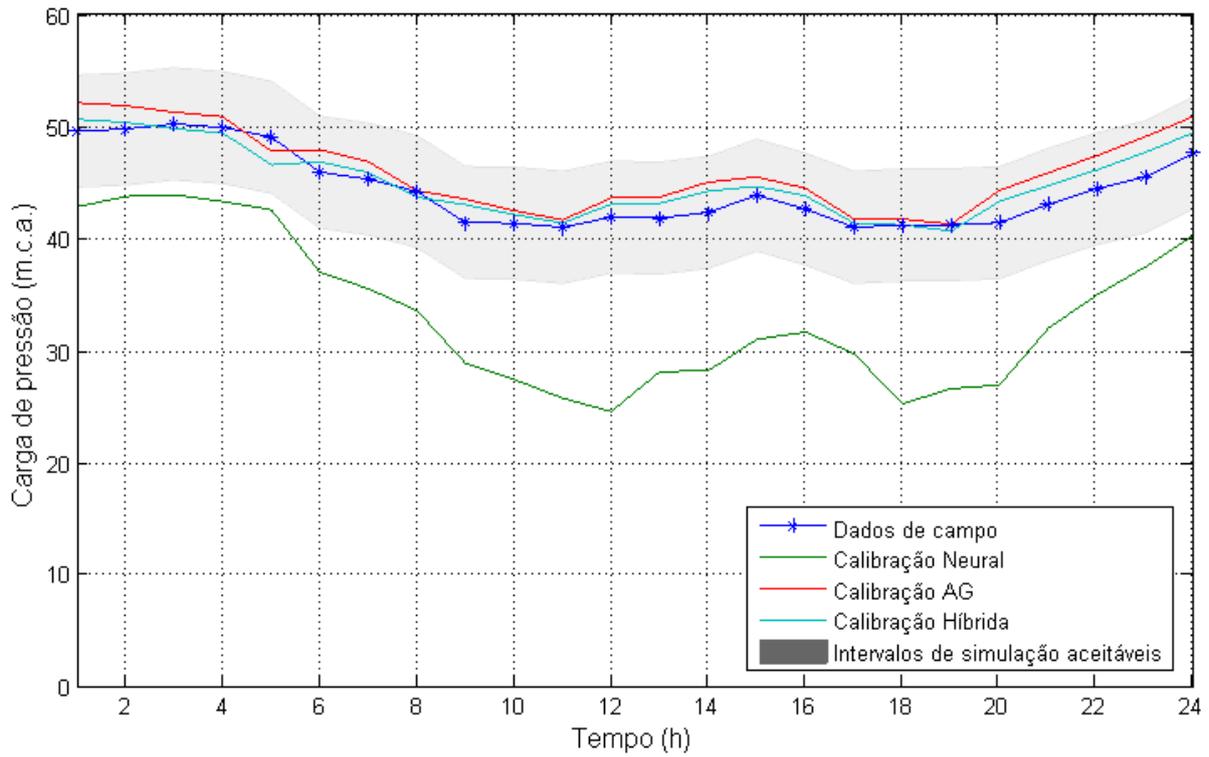


Figura 72 - Iguatemi ZB – Calibração do Nó n37h

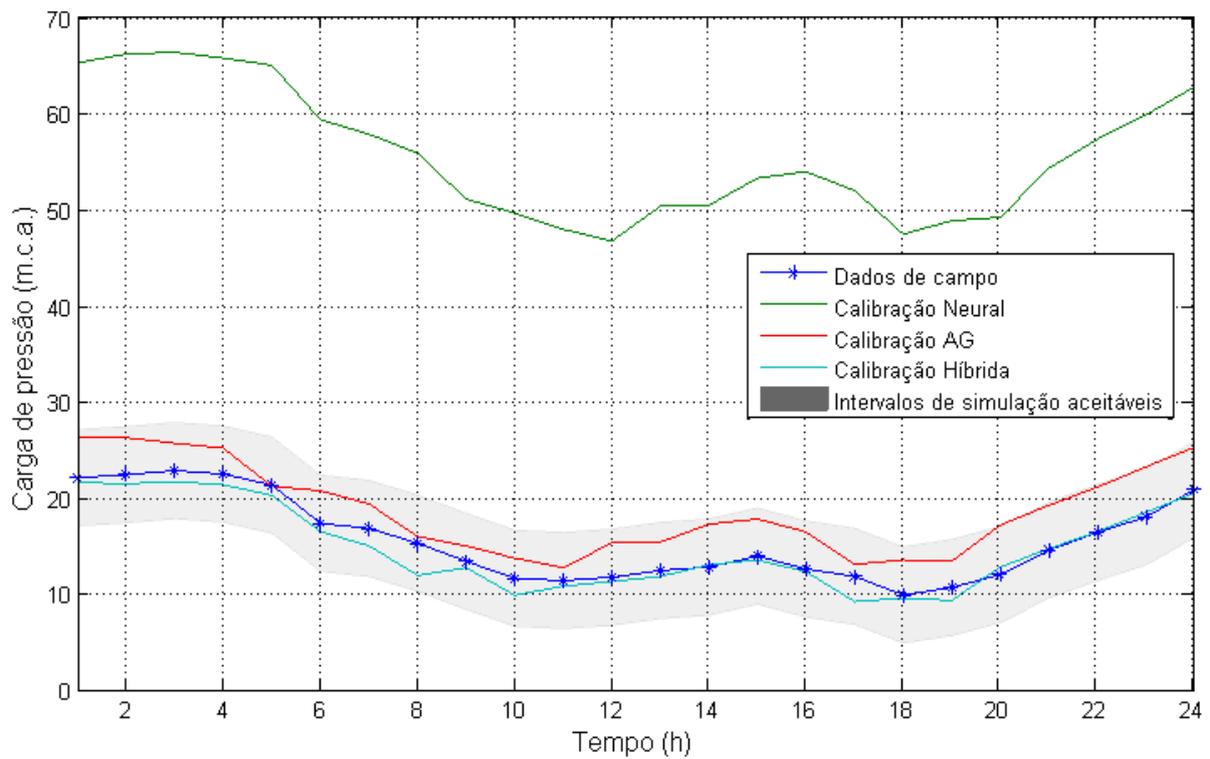


Figura 73 - Iguatemi ZB – Calibração do Nó n57d

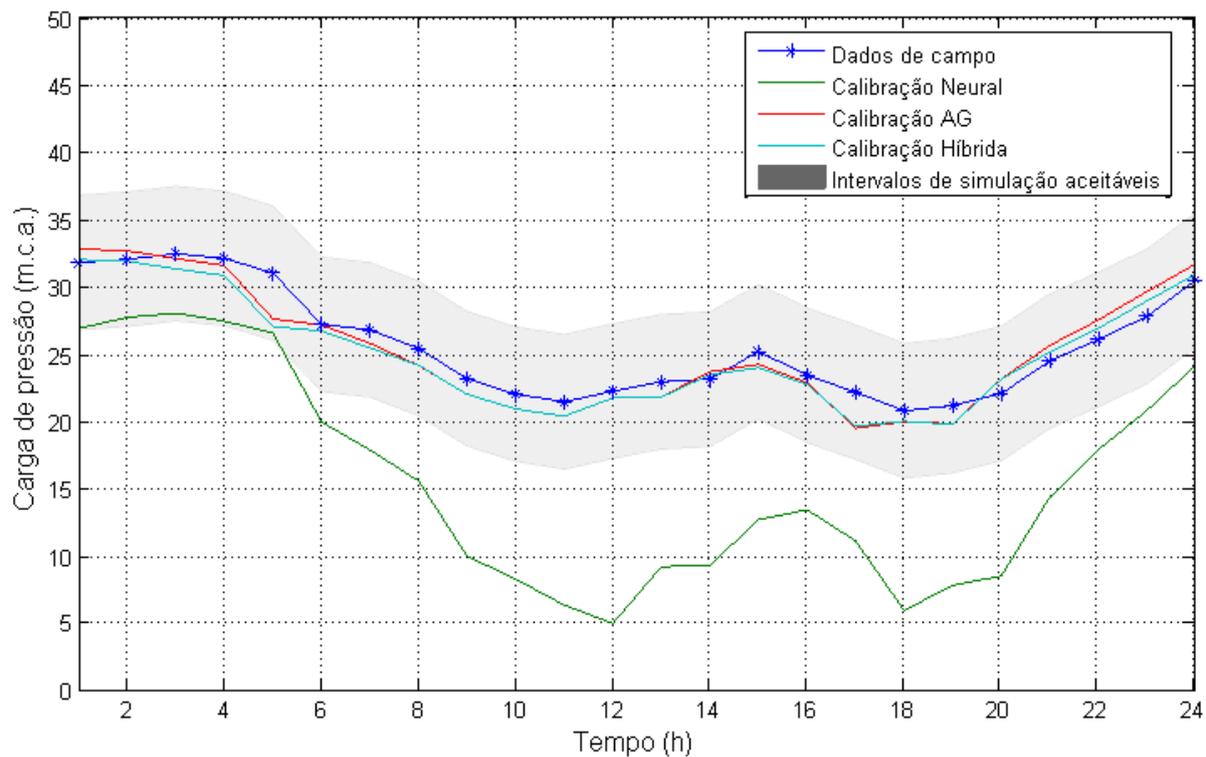


Figura 74 - Iguatemi ZB – Calibração do Nó n192

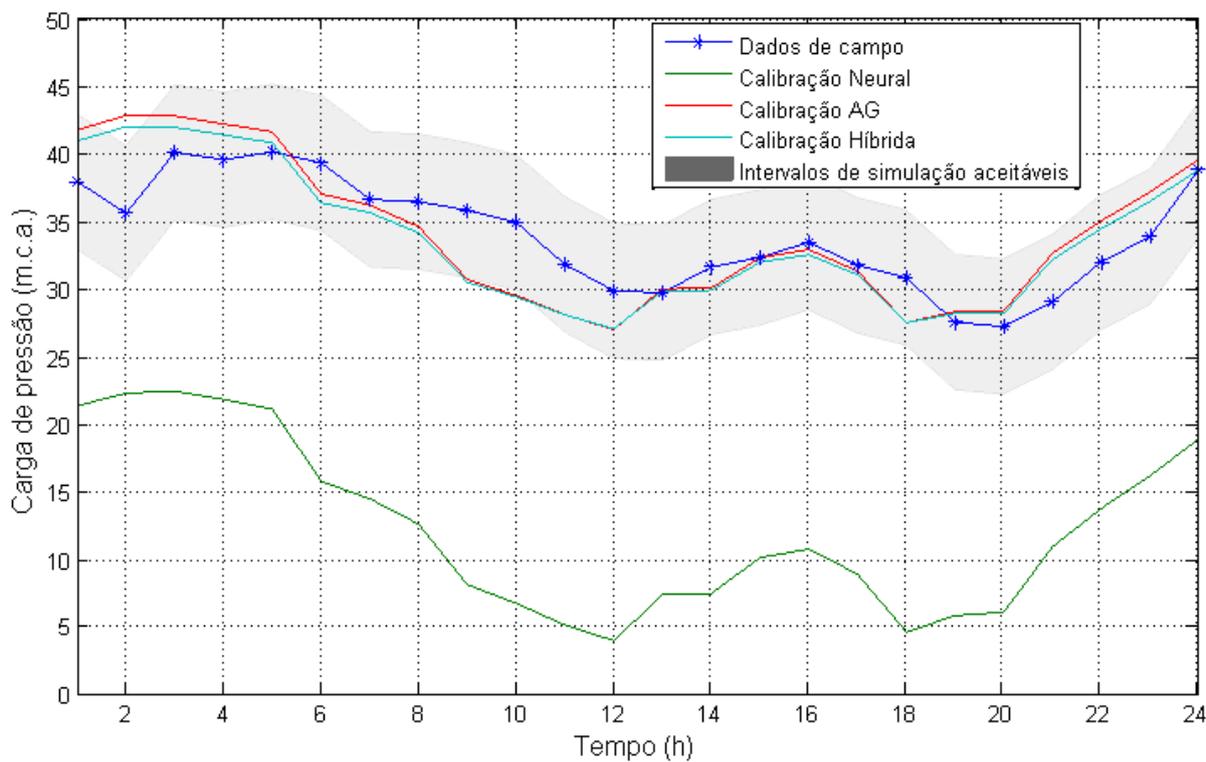


Figura 75 - Iguatemi ZB – Calibração do Nó n226

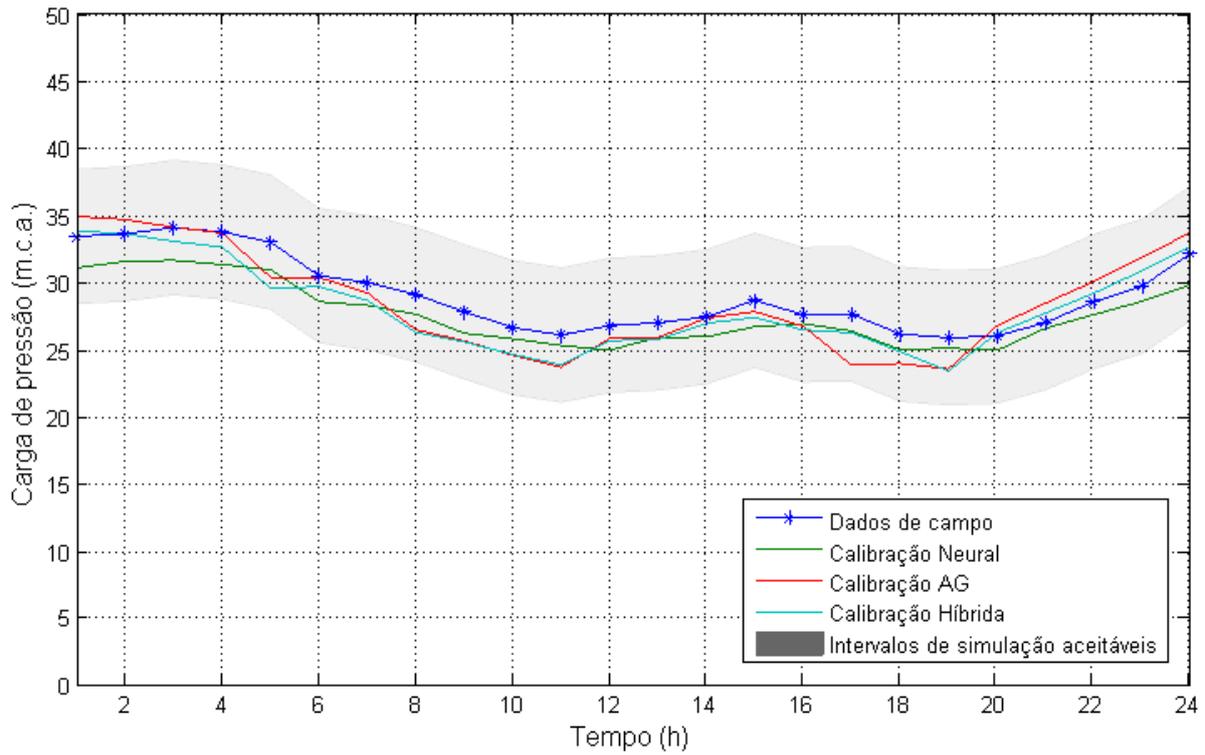


Figura 76 - Iguatemi ZB – Calibração do Nó n404

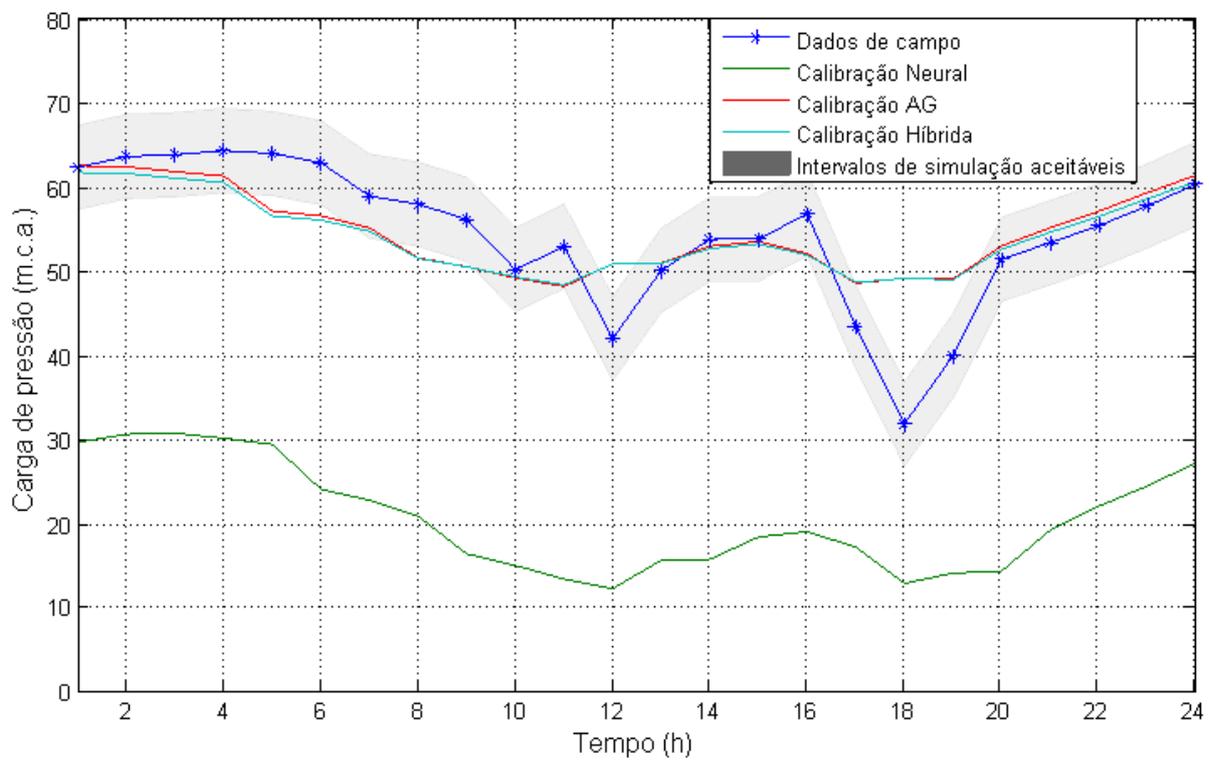


Figura 77 - Iguatemi ZB – Calibração do Nó n587

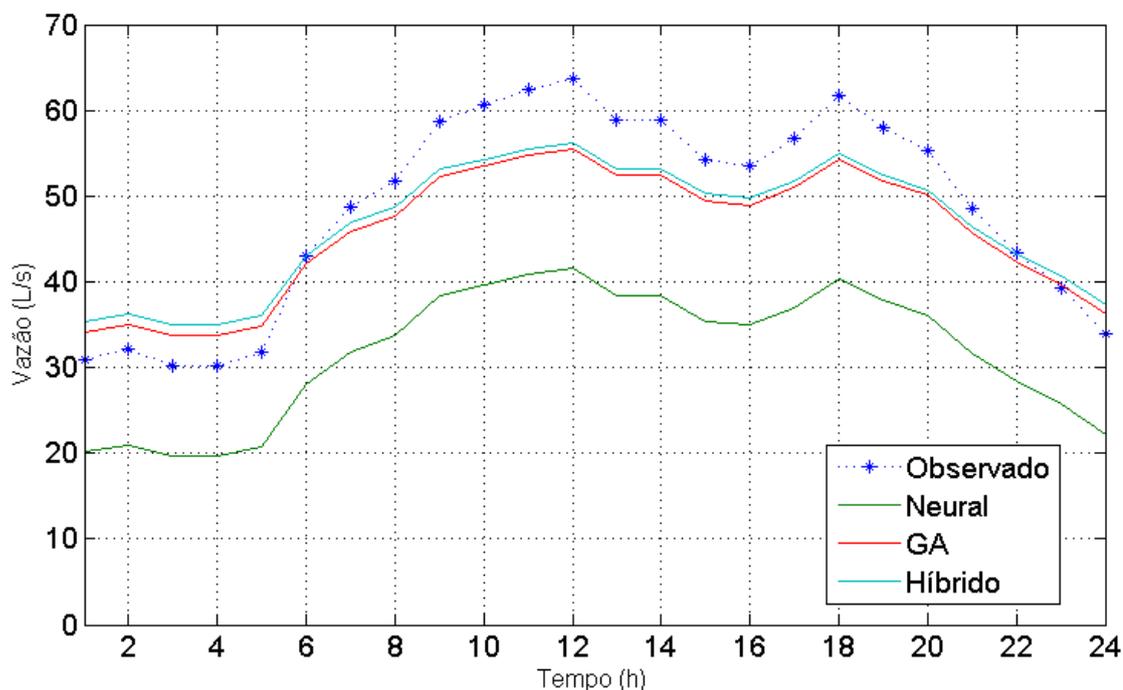


Figura 78 - Iguatemi ZB – Calibração do Trecho 5

A gráfico de correlação entre as variáveis (Figura 79) resume as calibrações para o setor Iguatemi ZB através dos diferentes métodos. Verifica-se que o melhor ajuste aos dados observados foi produzido pelo método híbrido. Apesar disso, tanto a calibração através de AG, quanto pelo método híbrido foram bastante semelhantes em termos da reprodução das cargas de pressão. Essa relação é expressa através da forte correlação entre as duas variáveis. Apesar da correlação entre os valores observados e obtidos através das RNA, esta correlação é exibida através de mais de um padrão, fazendo com que a correlação entre os dados mostrados, quando analisados simultaneamente, sugira a aleatoriedade dos dados.

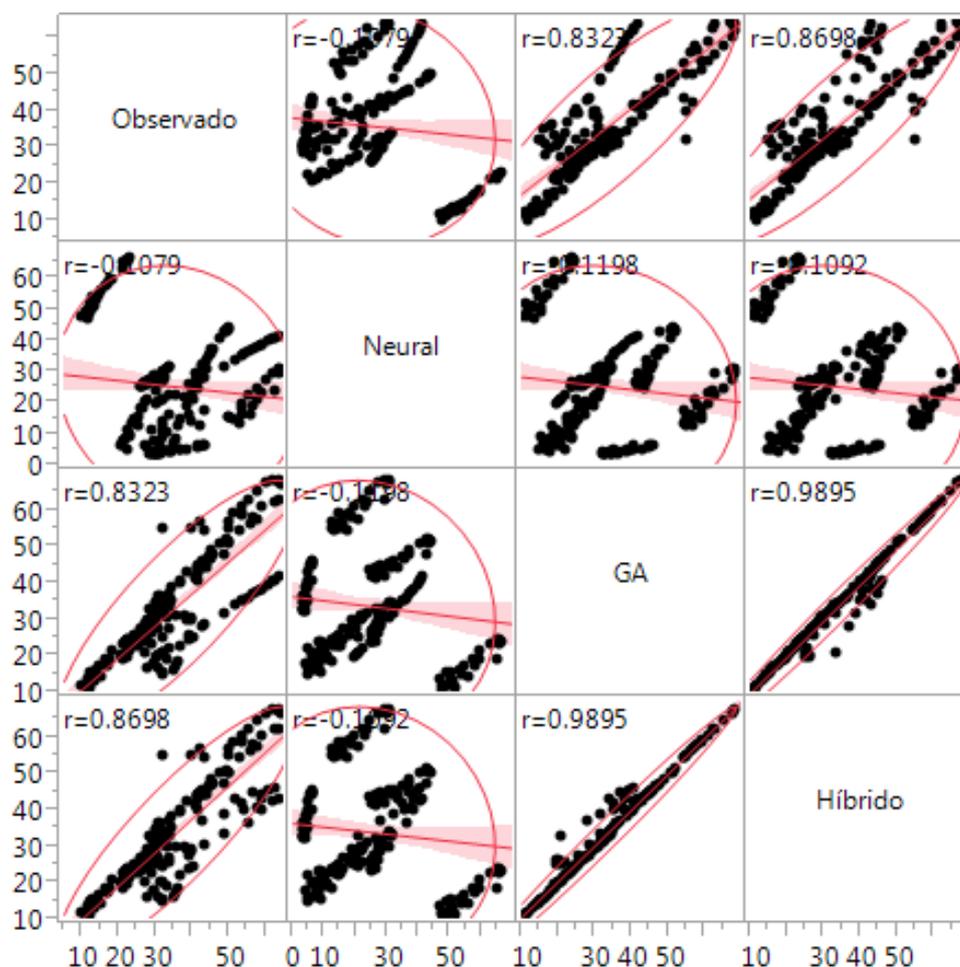


Figura 79 – Gráfico de regressão multivariada do setor Iguatemi ZB

Tabela 27 - Matriz esparsa de correlações entre os resultados em termos de variáveis de estado obtidos para o setor Iguatemi ZB

	Observado	Neural	A.G.	Híbrido
Observado	1,0000	0,1079	0,8323	0,8698
Neural	0,1079	1,0000	0,1198	0,1092
A.G.	0,8323	0,1198	1,0000	0,9895
Híbrido	0,8698	0,1092	0,9895	1,0000

A Figura 80 ilustra a evolução do valor da função objetivo ao longo das iterações durante o processo de calibração do setor Eliana através de algoritmos genéticos e através do método híbrido. Este setor foi o que consumiu o menor tempo de processamento para a realização das calibrações. A calibração através do método dos algoritmos genéticos foi concluída em 2h37min (linha azul) e usando o método híbrido em 2min12s (linha vermelha).

A função objetivo atingiu o menor valor através da calibração via AG. Entretanto, os gráficos das calibrações demonstram que a diferença de erro entre o AG e o método híbrido são desprezíveis.

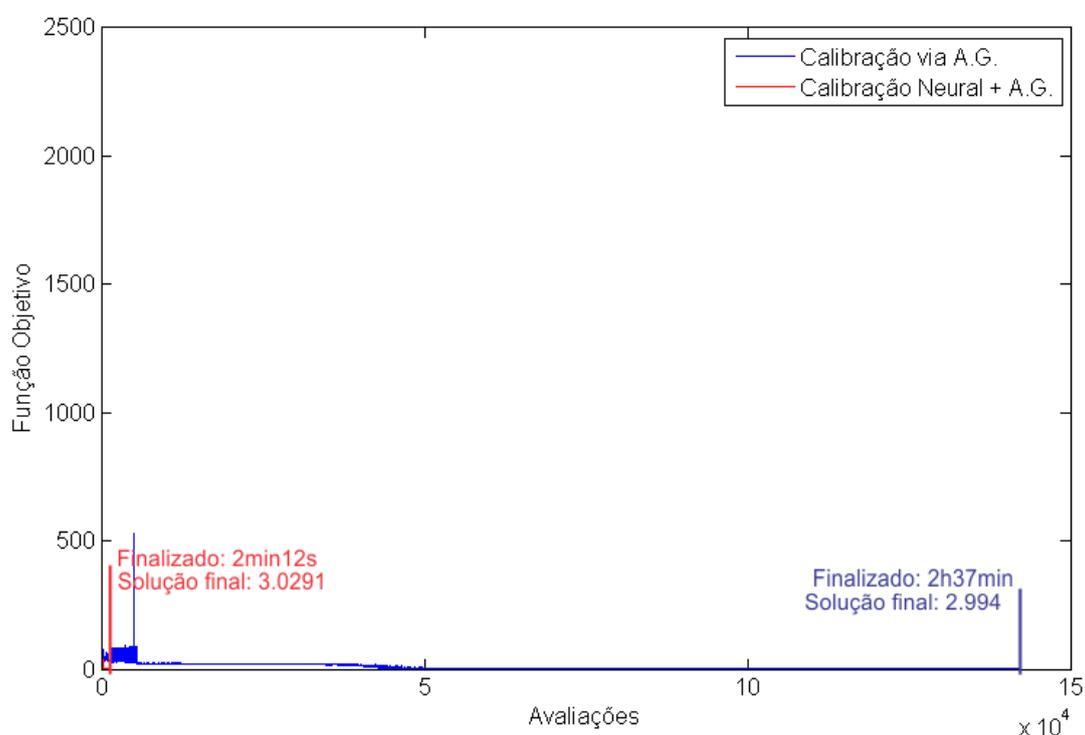


Figura 80 - Convergência da calibração - Eliana

As Figuras 81-89 possibilitam a comparação dos valores das cargas de pressão simulados e observados para o setor Eliana, utilizando os três métodos de calibração. Assim como nos outros setores, a calibração via RNA produziu resultados inferiores quando comparados com a calibração através de AG e através do método híbrido, produzindo valores praticamente constantes ao longo do tempo. Os resultados obtidos pelos dois melhores métodos foram bastante semelhantes e as linhas se sobrepõem na maioria dos casos. Em alguns instantes, a calibração através do AG apresentou uma leve aproximação dos dados observados, ocasionando a diferença no erro que superou a calibração através do método

híbrido. Observa-se que o padrão das cargas de pressão do setor são bastante peculiares comparados com as dos demais setores. Em determinados momentos, entre as 12h e 14h, os valores simulados apresentam uma queda brusca nas cargas de pressões que somente ocorrem pontualmente as 13h nos dados reais. Conforme explicado, as variações bruscas nas cargas de pressões explicam-se devido ao uso compartilhado do reservatório também pelo setor Martinez durante determinadas horas do dia.

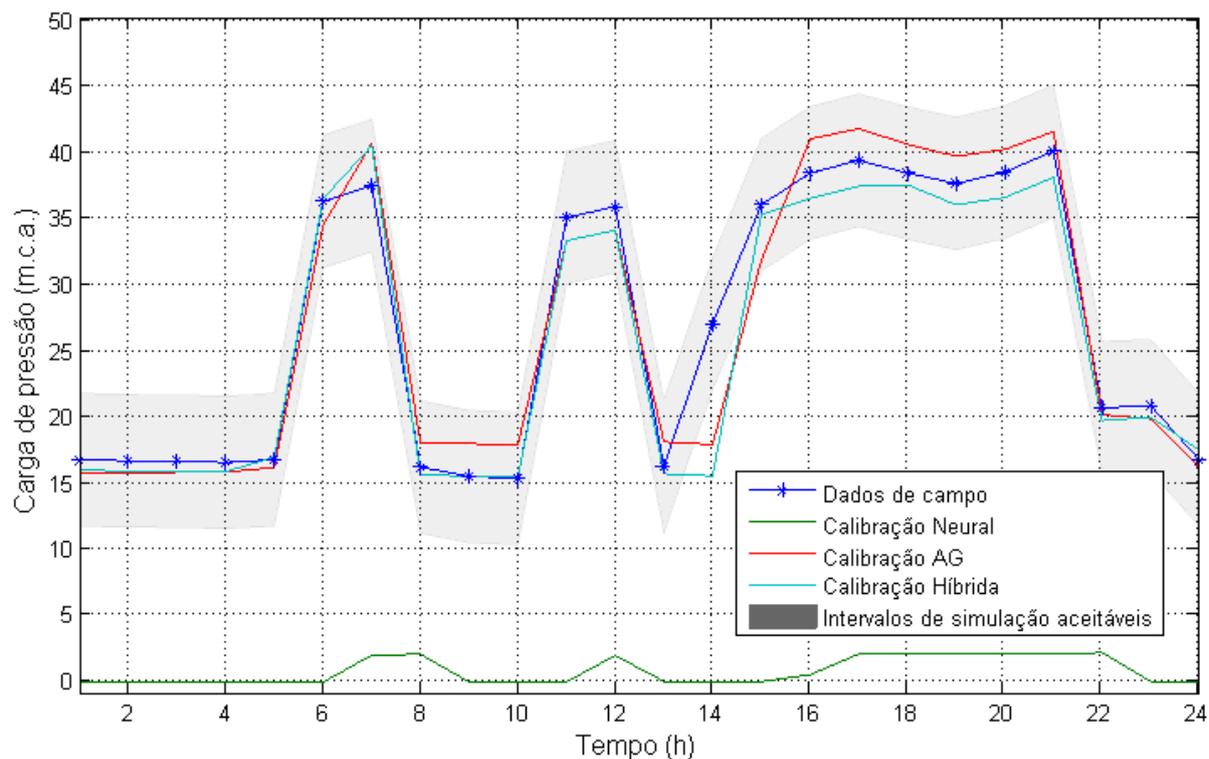


Figura 81 - Eliana – Calibração do Nó n2n

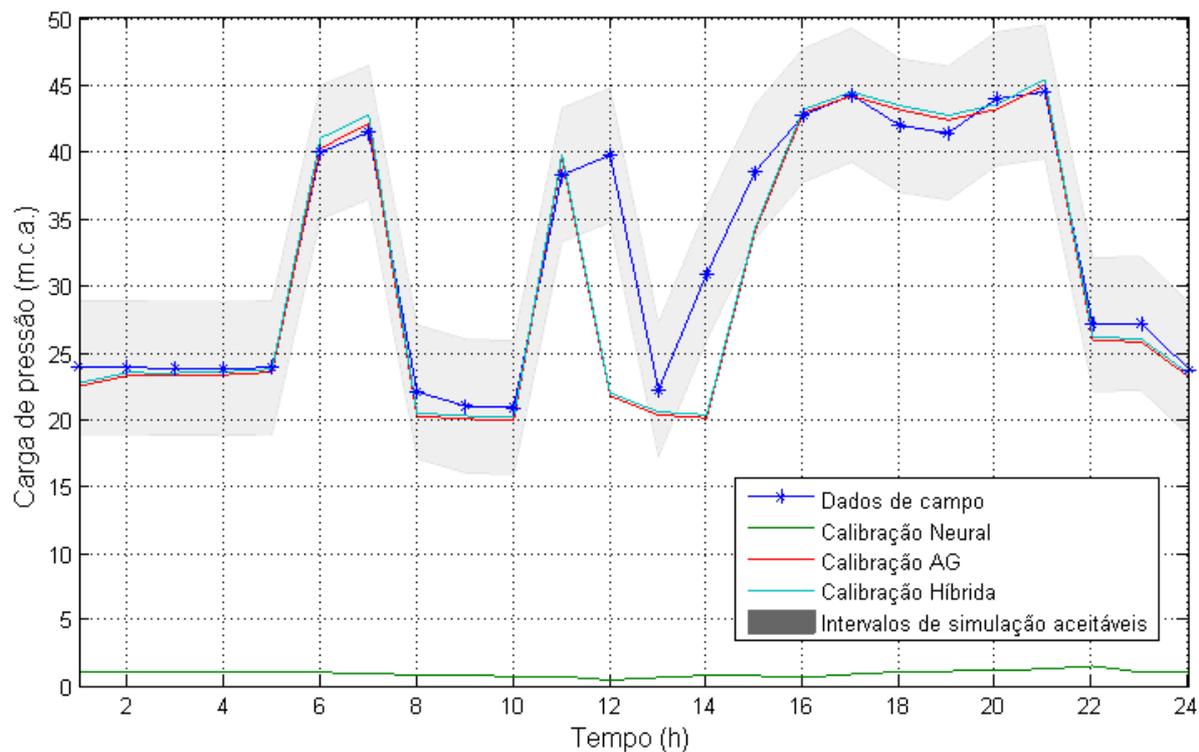


Figura 82 - Eliana – Calibração do Nó n8

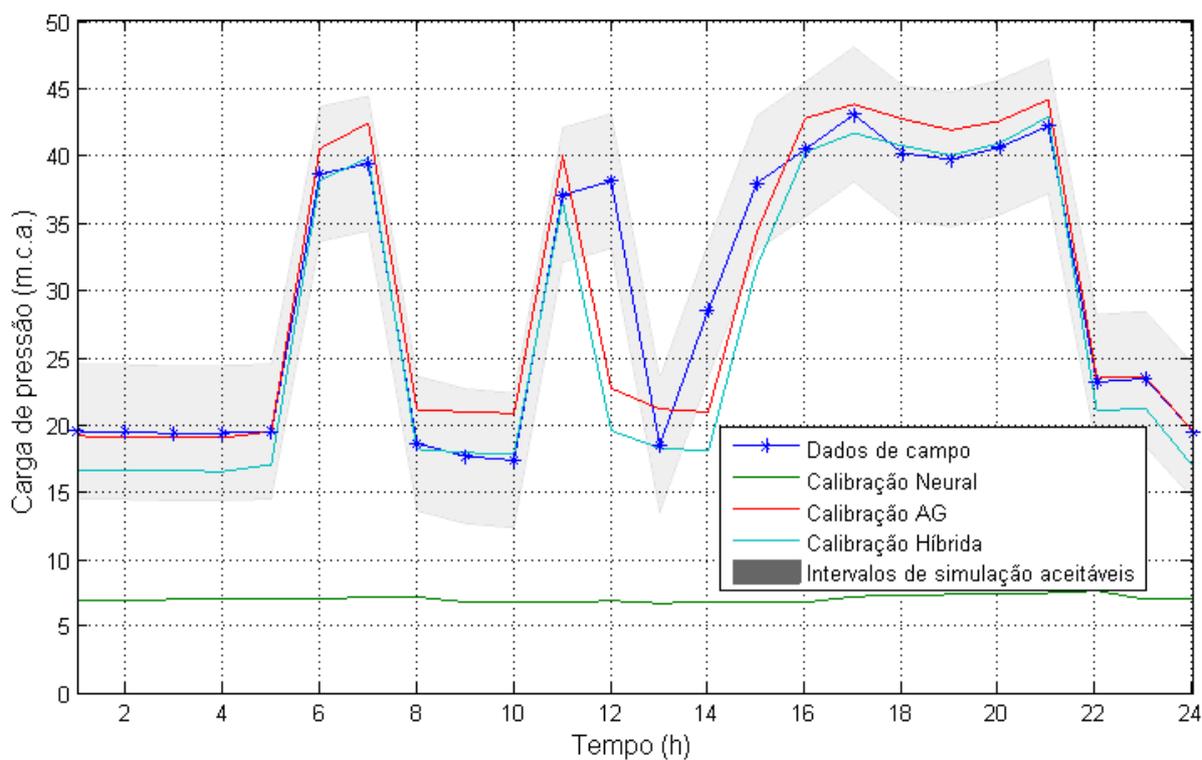


Figura 83 - Eliana – Calibração do Nó n11e

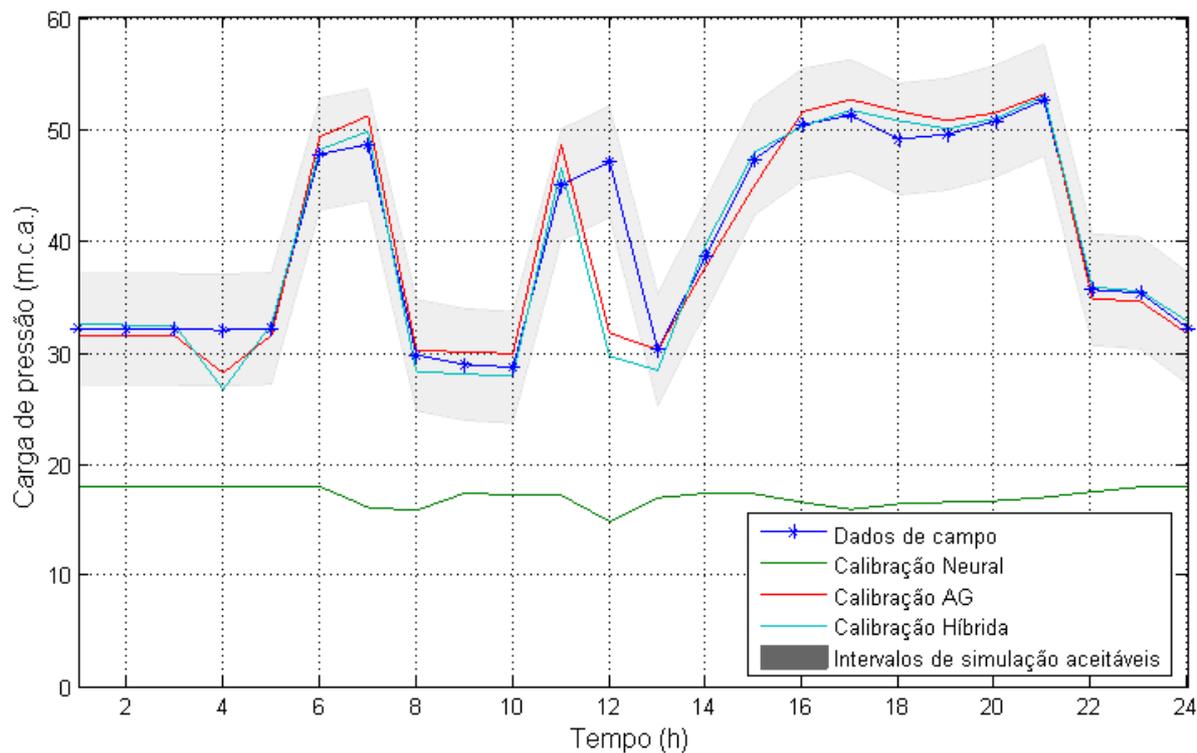


Figura 84 - Eliana – Calibração do Nó n32

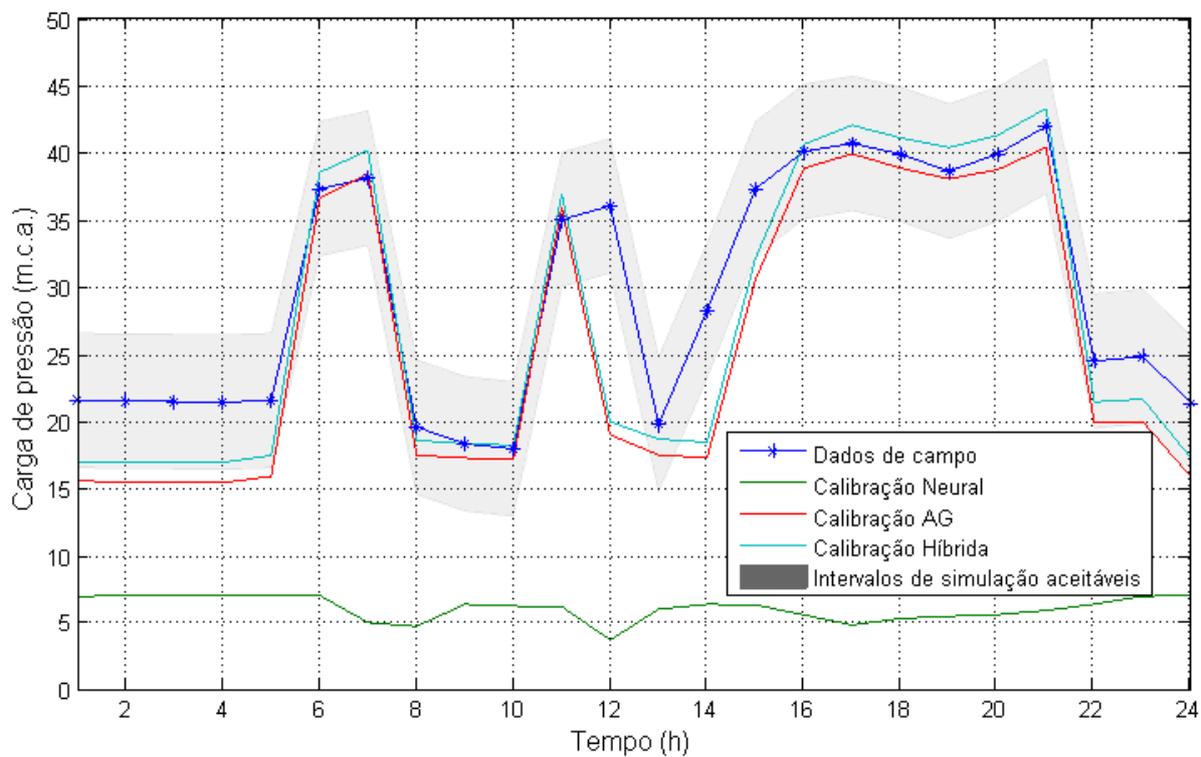


Figura 85 - Eliana – Calibração do Nó n60

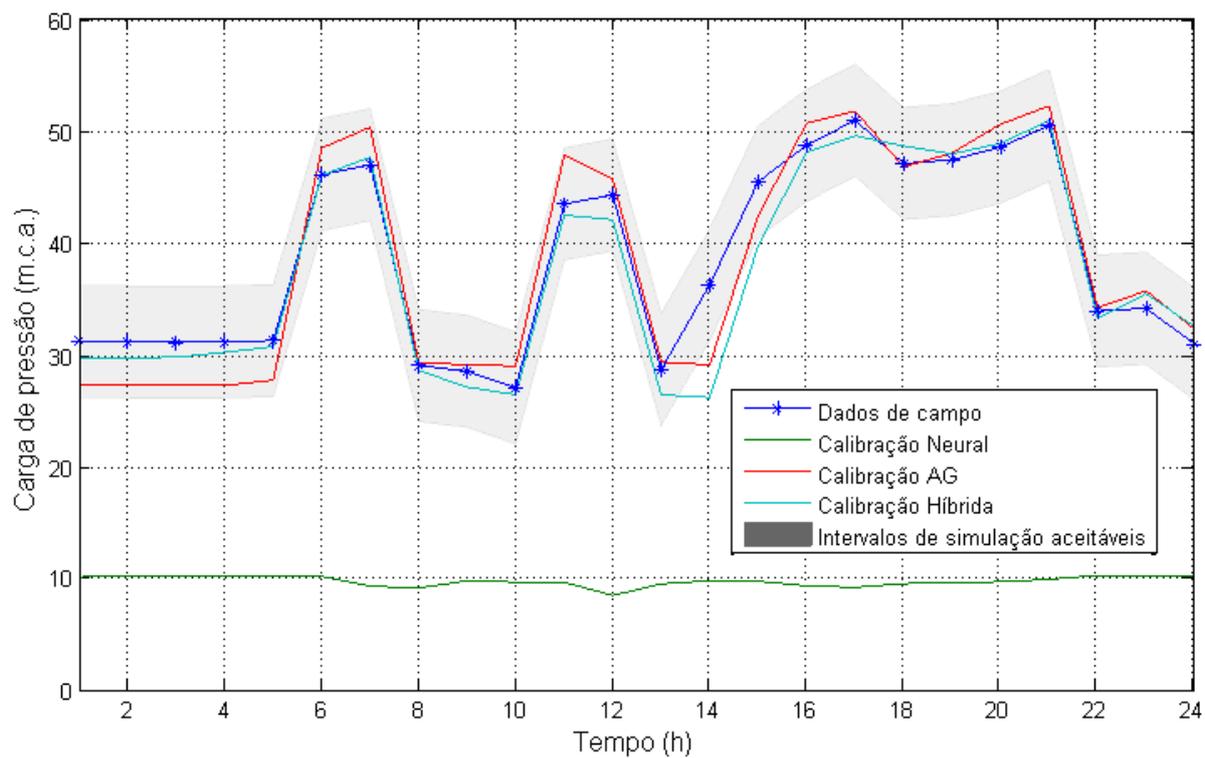


Figura 86 - Eliana – Calibração do Nó n85

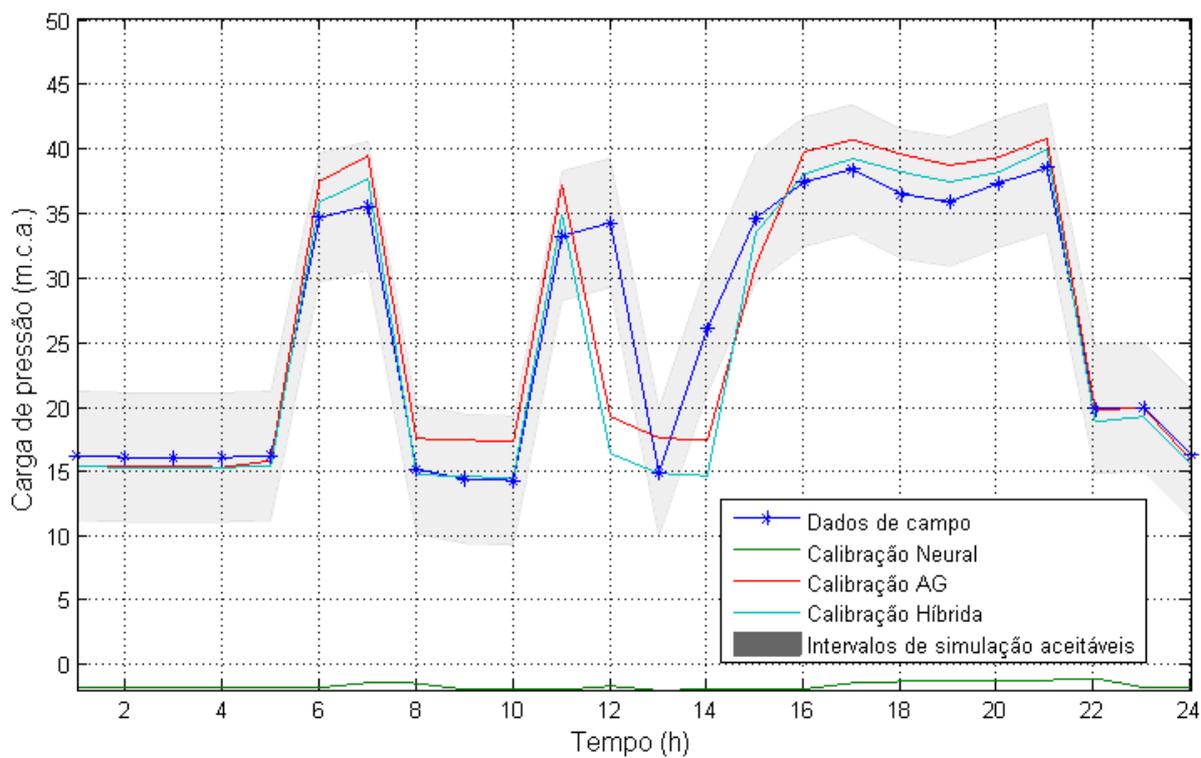


Figura 87 - Eliana – Calibração do Nó n93

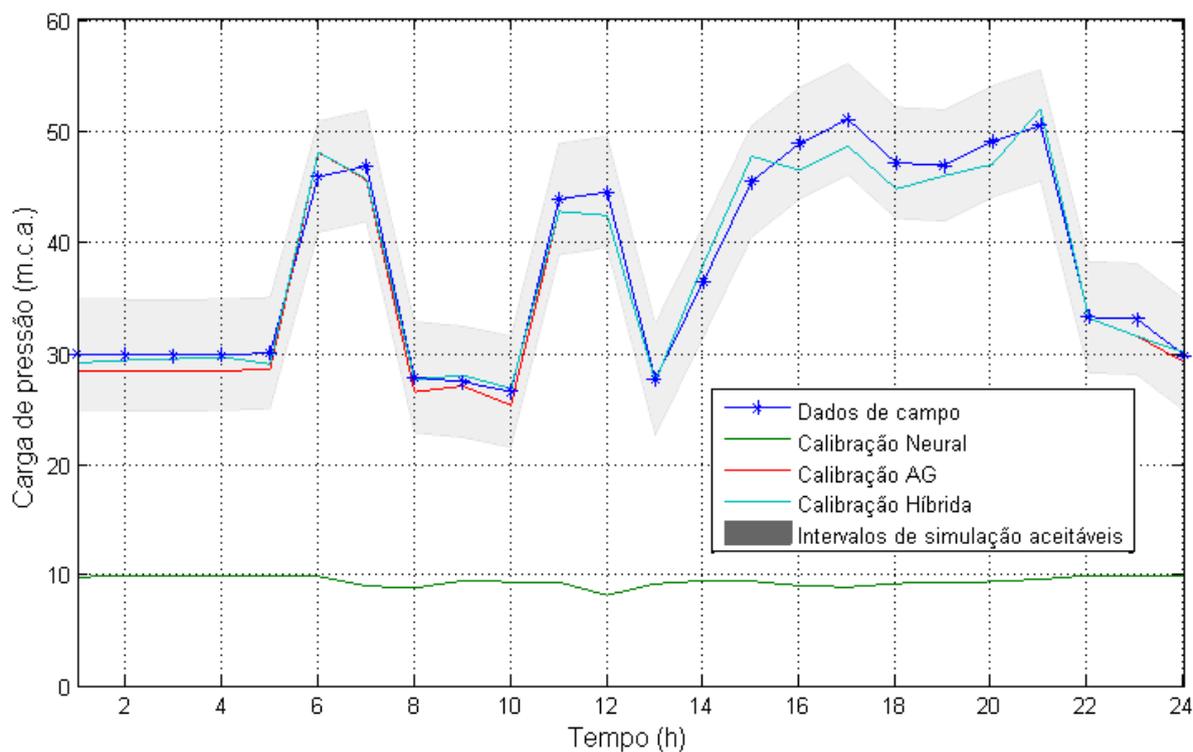


Figura 88 - Eliana – Calibração do Nó n141

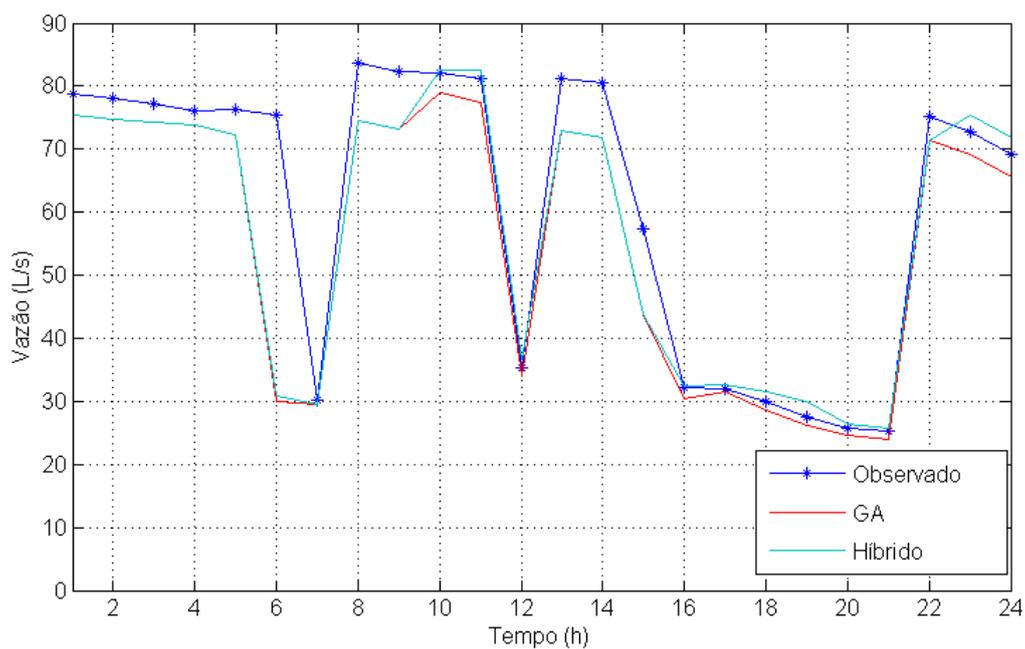


Figura 89 - Eliana – Calibração do Trecho 4

A Figura 90 mostra as correlações obtidas para o setor Eliana para as diferentes calibrações propostas. As correlações também são listadas na Tabela 28. A primeira linha da Figura mostra o resultado das correlações entre os valores observados e calibrados. O modelo

calibrado através dos algoritmos genéticos foi modestamente superior à calibração através do método híbrido.

Nesse caso, o resultado da calibração em termos das vazões simuladas se mostrou novamente superior para o caso do método híbrido.

Tabela 28 – Matriz de correlação esparsa para o setor Eliana

	Observado	Neural	A.G.	Híbrido
Observado	1,0000	0,6041	0,8323	0,8224
Neural	0,6041	1,0000	0,3200	0,3163
A.G.	0,8237	0,3200	1,0000	0,9999
Híbrido	0,8224	0,3163	0,9999	1,0000

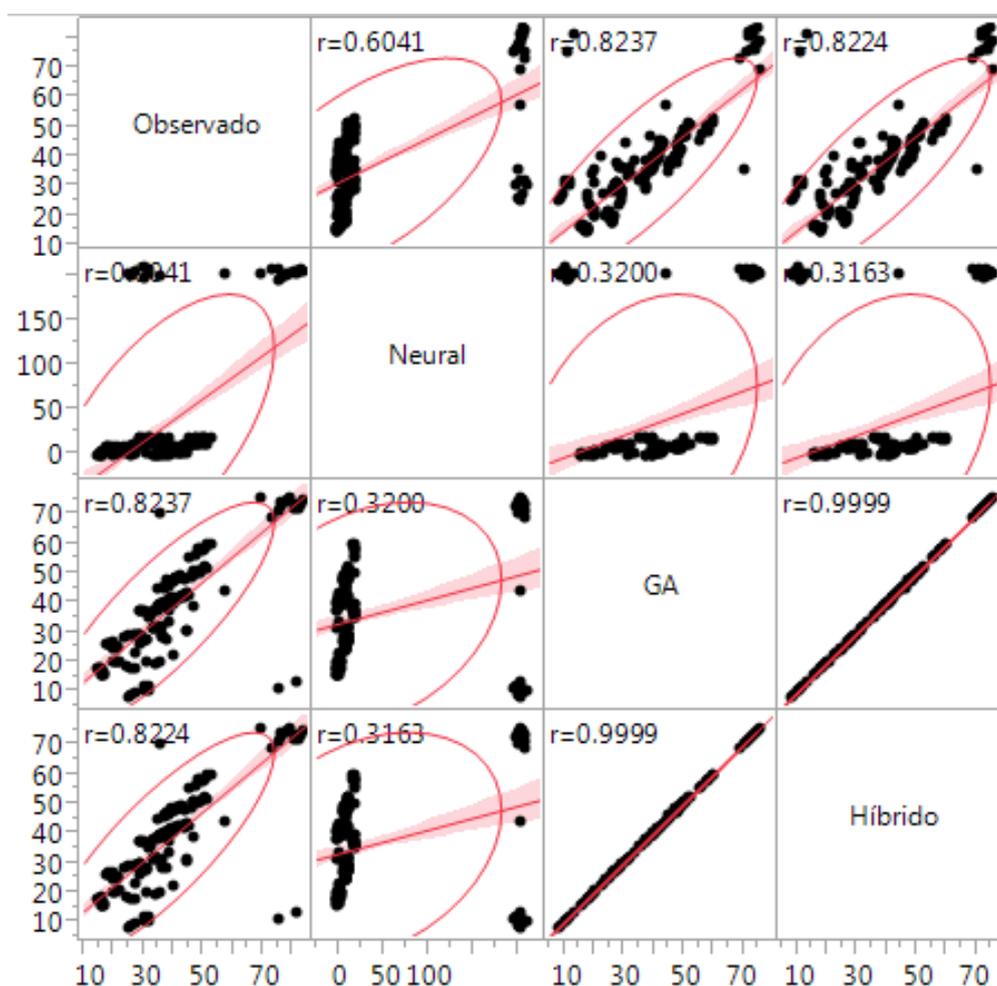


Figura 90 – Gráfico de regressão multivariada do setor Eliana

A Figura 91 ilustra o processo de calibração do setor Martinez. A calibração deste setor foi a que consumiu os maiores tempos – 9h23min para a calibração utilizando algoritmos genéticos (linha azul) e 2h40min para calibração através do método híbrido (linha vermelha). Apesar do grande tempo utilizado para a calibração via AG, pode-se verificar que o processo poderia ser interrompido anteriormente, pois não houve redução significativa na função objetivo. O erro médio atingido pelo método híbrido mostrou-se menor do que o método tradicional. Ao contrário do que foi notado nas redes anteriores, a diferença do erro entre os dois métodos de calibração (via algoritmos genéticos e via método híbrido) foi perceptível para esse setor. Contudo, nenhum dos métodos apresentou ajustes satisfatórios comparados com os resultados obtidos nos outros setores.

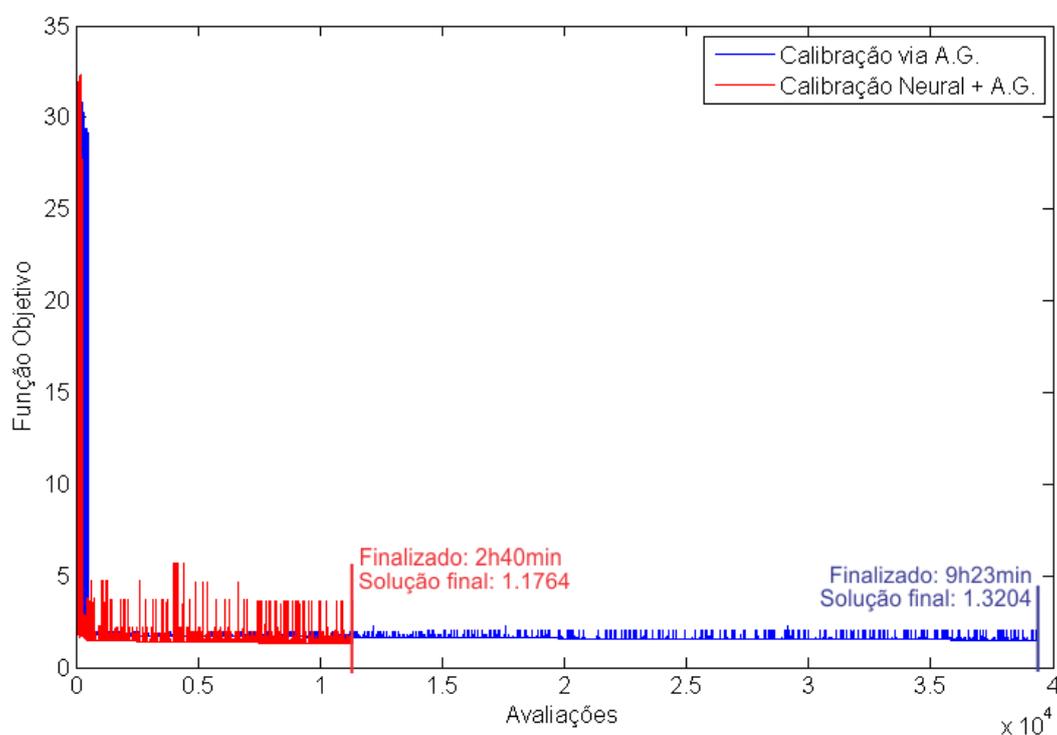


Figura 91 - Convergência da calibração - Eliana

Neste setor, as cargas de pressões observadas mantiveram-se relativamente constantes ao longo do tempo. Nestes casos, a calibração utilizando os métodos tradicional e híbrido mostraram-se satisfatórias, conforme indicações das Figuras 92-99. Entretanto, nos pontos 83 (Figura 93) e 296 (Figura 94) as maiores variações transientes observadas não puderam ser reproduzidas de modo eficiente. O setor foi dividido em grupos e os métodos de calibração

utilizados buscaram a redução do erro para cada grupo formado. Como grande parte dos nós observados apresentou comportamento constante, o algoritmo privilegiou poucas mudanças nas perdas de carga, comprometendo os poucos pontos em que a variação da carga de pressão foi maior. O desvio destes pontos poderia ser minimizado com informações complementares sobre o sistema, tais como idade das tubulações, pois isso possibilitaria a divisão dos setores em grupos menores, permitindo a busca de coeficientes de forma localizada. Outro fator que pode ter influenciado o resultado da calibração deste setor foi o uso de informações de vazões com períodos diferentes dos dados adquiridos em campo devido ao problema nos equipamentos de telemetria da companhia de saneamento. A vazão calibrada no setor (Figura 99) comportou-se como uma constante ao longo do tempo, tanto pelo método tradicional, quanto pelo método híbrido, distanciando-se muito dos valores reais. Além disso, o setor Martinez não possui características predominantemente residenciais. Para melhor representação do modelo e, conseqüentemente, melhor calibração existe a necessidade do monitoramento dos grandes consumidores do setor.

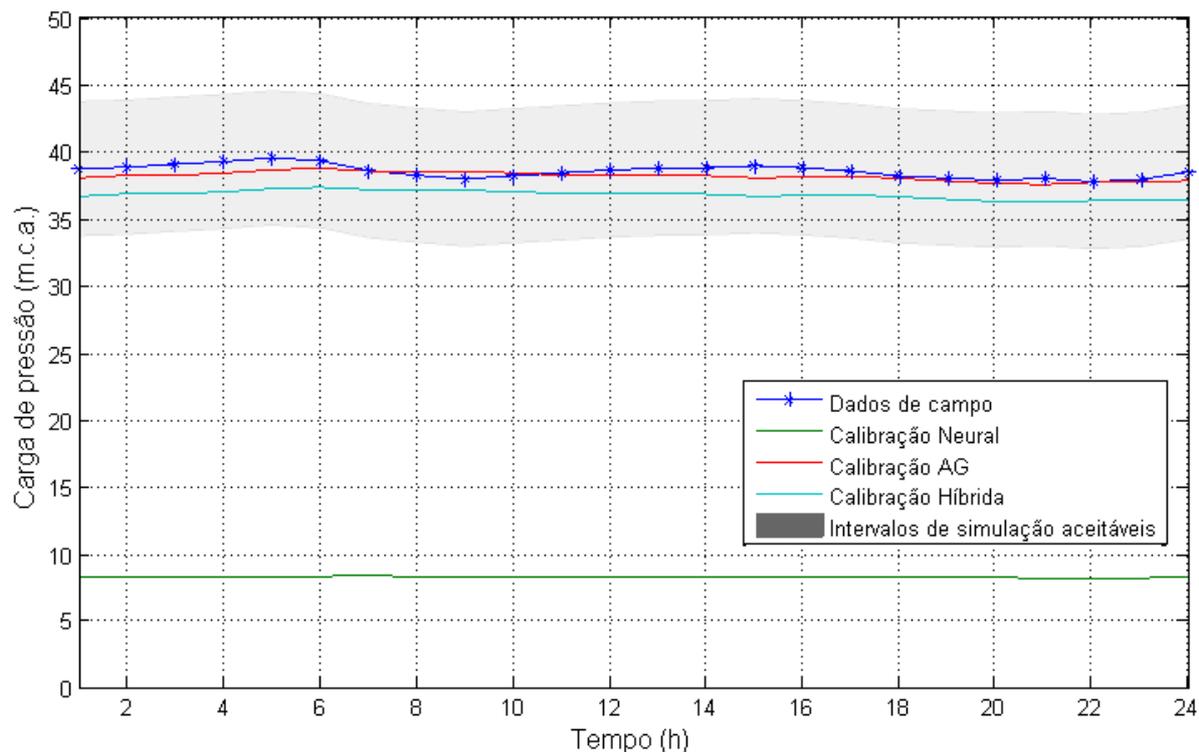


Figura 92 - Calibração do Martinez – Nó n45

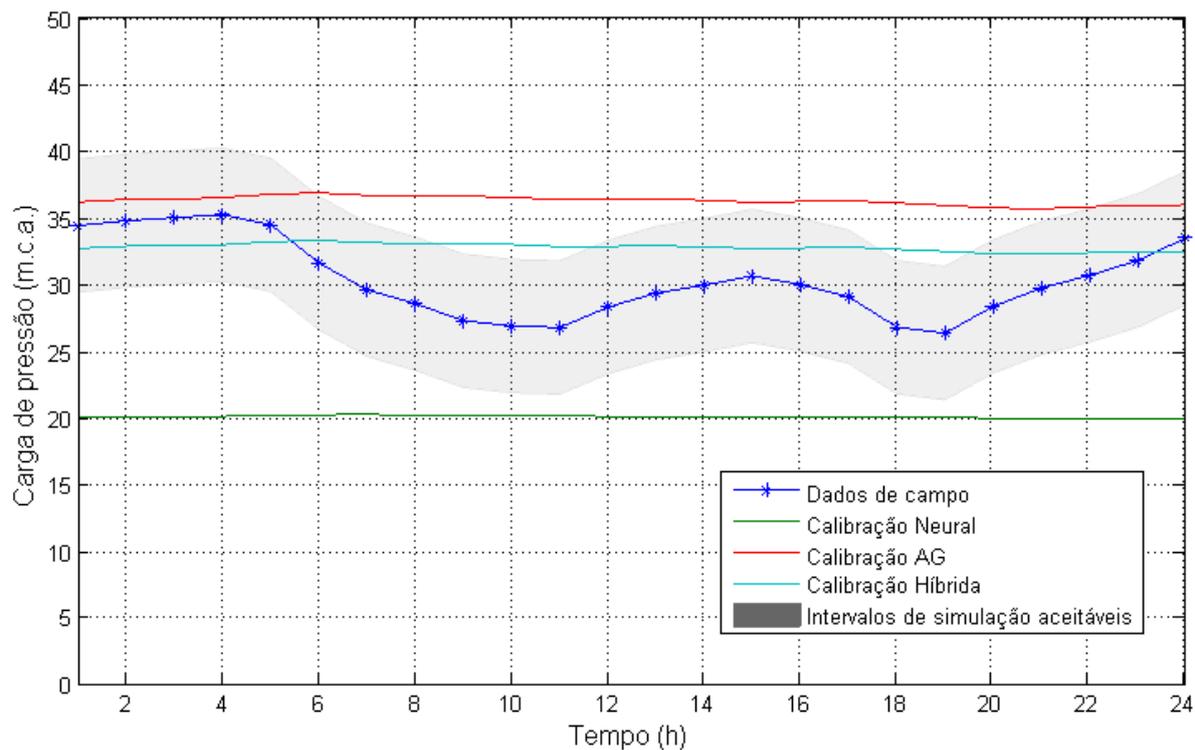


Figura 93 - Martinez – Calibração do Nó n83h

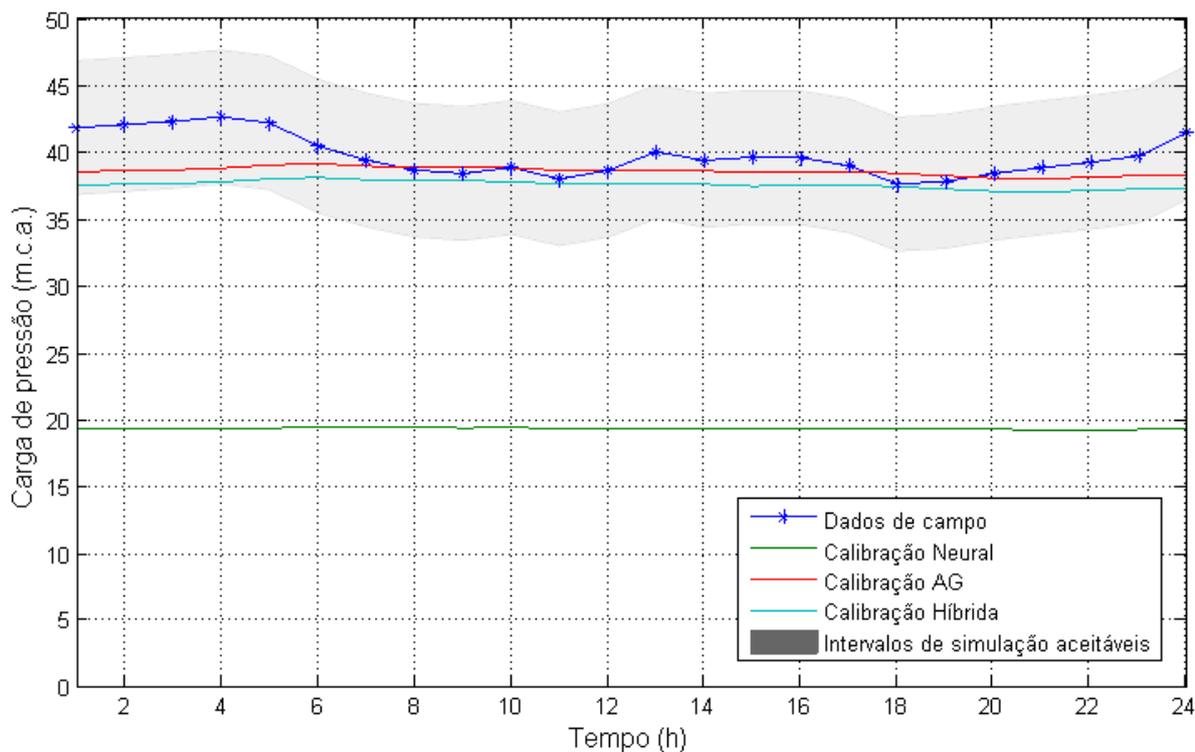


Figura 94 - Martinez – Calibração do Nó n296

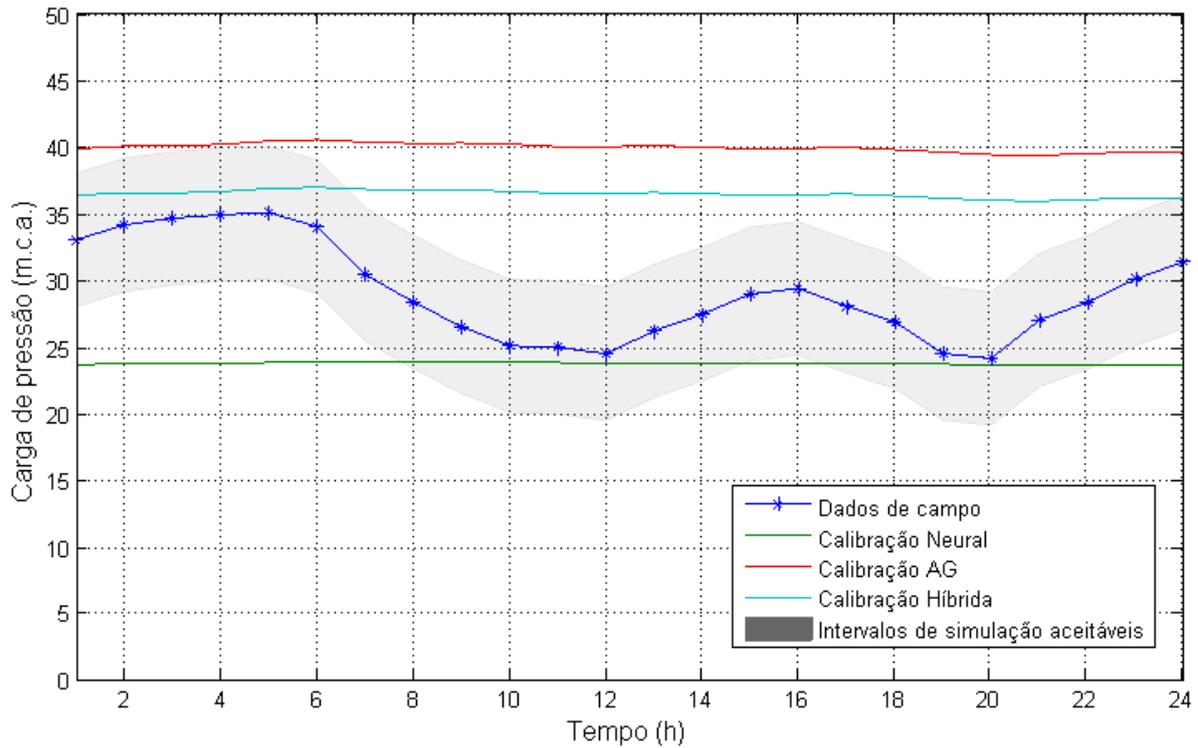


Figura 95 - Martinez – Calibração do Nó n102

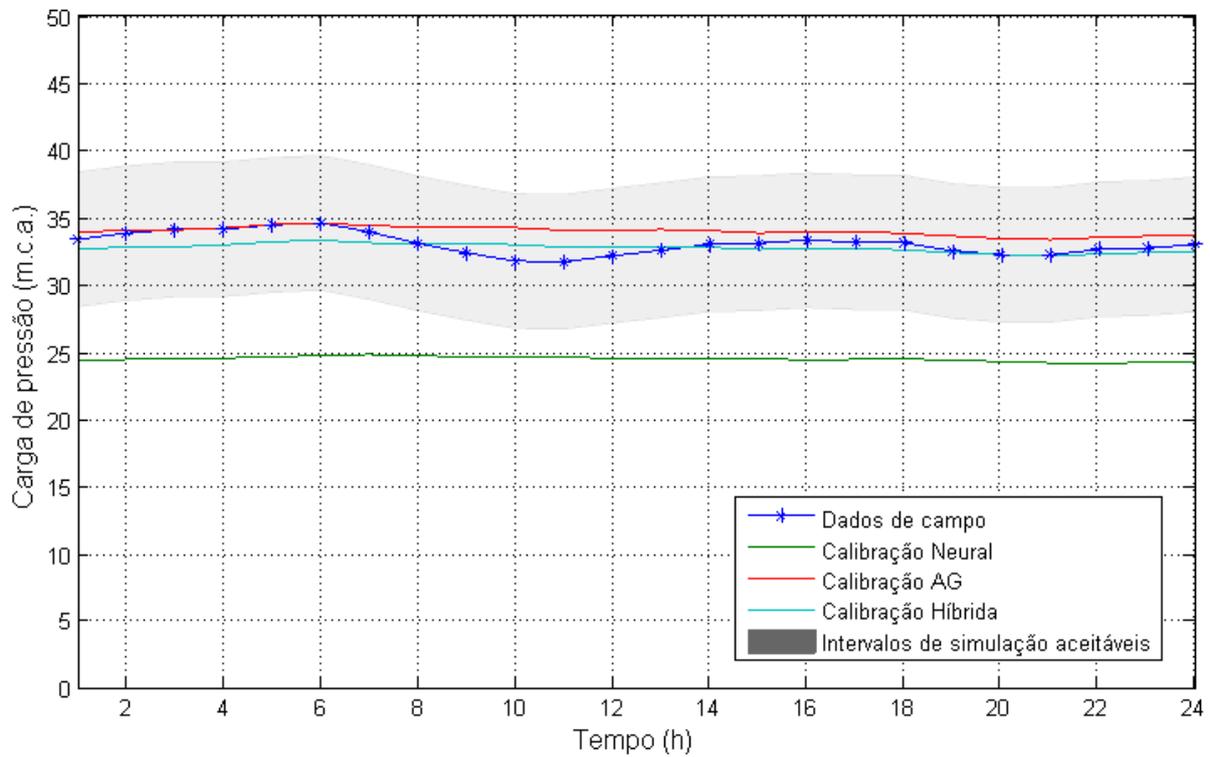


Figura 96 - Martinez – Calibração do Nó n203

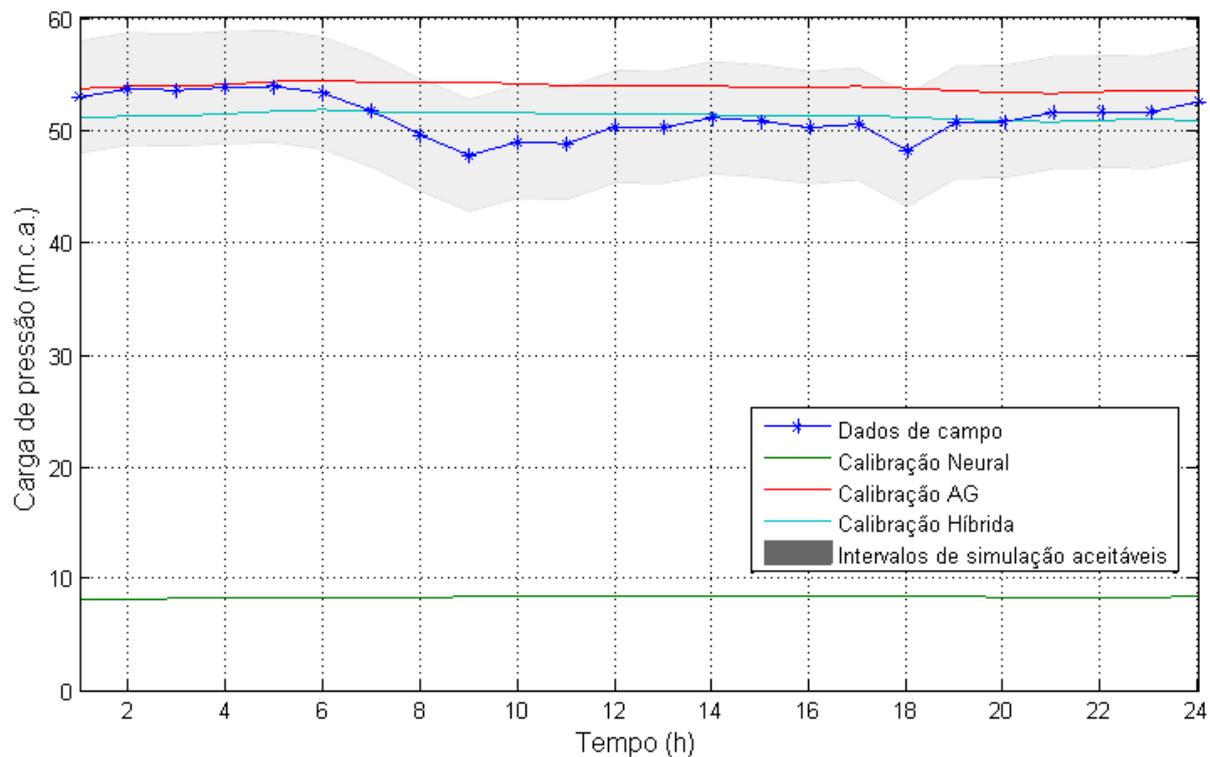


Figura 97 - Martinez – Calibração do Nó n523

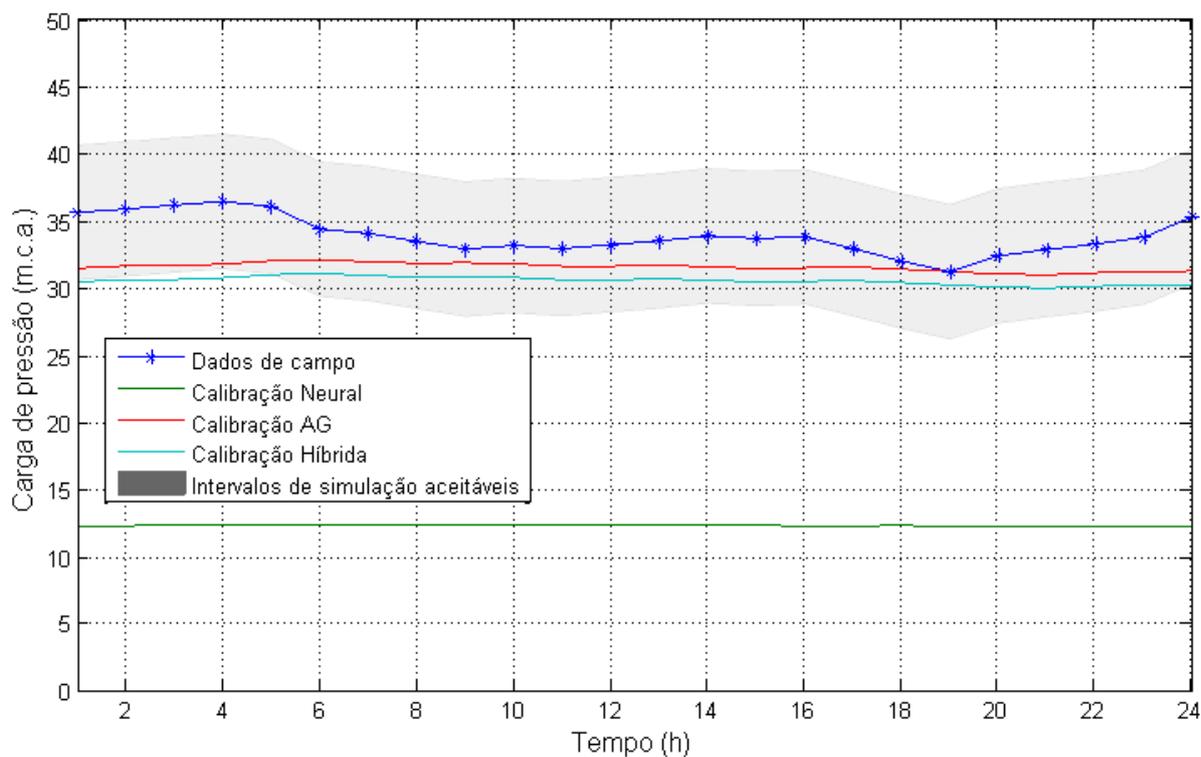


Figura 98 - Martinez – Calibração do Nó n405

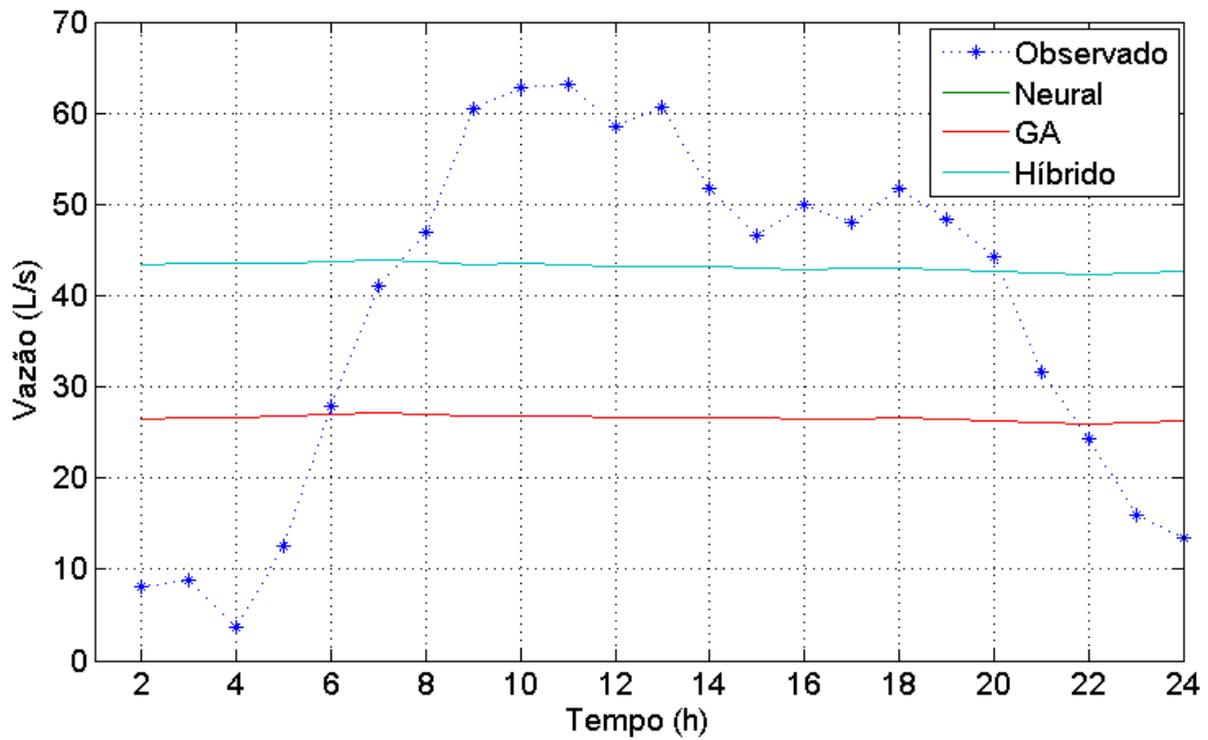


Figura 99 - Martinez – Calibração do Trecho 3

Devido à grande variação da vazão observada, as vazões simuladas apresentaram-se aparentemente constantes no tempo. A Figura 100 ilustra o detalhe do padrão de variação da vazão obtida através da simulação pelo método híbrido através da adição de eixo secundário, de escala diferenciada, mostrando que existe o acompanhamento do padrão e a necessidade de investigação aprofundada da modelagem hidráulica do setor.

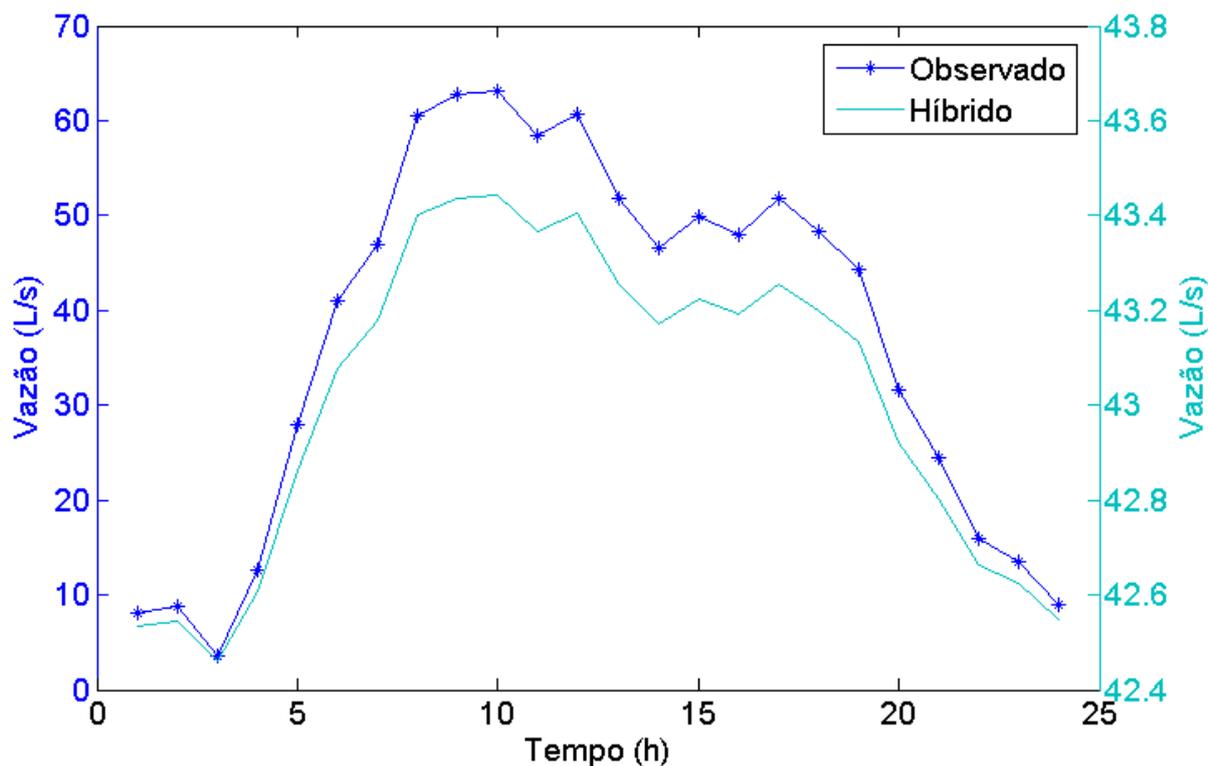


Figura 100 – Martinez – detalhe da variação de consumo do Trecho 3

A Figura 101 mostra a matriz de correlações obtida pela calibração do setor Martinez. Diferentemente dos outros setores, verifica-se que os valores obtidos após a calibração tradicional (AG) e via método híbrido não apresentam forte correlação. As correlações entre os valores observados e aqueles simulados com parâmetros calibrados através dos algoritmos genéticos apresentaram dois padrões distintos, promovendo a dispersão dos dados e contribuindo para um baixo valor de R. O mesmo ocorreu para a correlação entre os valores observados e aqueles simulados com parâmetros calibrados através do método híbrido. Esse segundo padrão encontrado nas duas comparações se deve ao fraco desempenho da calibração dos valores de vazão. Apesar de existir variação dos valores da vazão nos dados medidos em campo, esses valores mantiveram-se constante nos dados simulados, criando um padrão de linhas verticais perceptíveis no gráfico e também verificável na Figura 99.

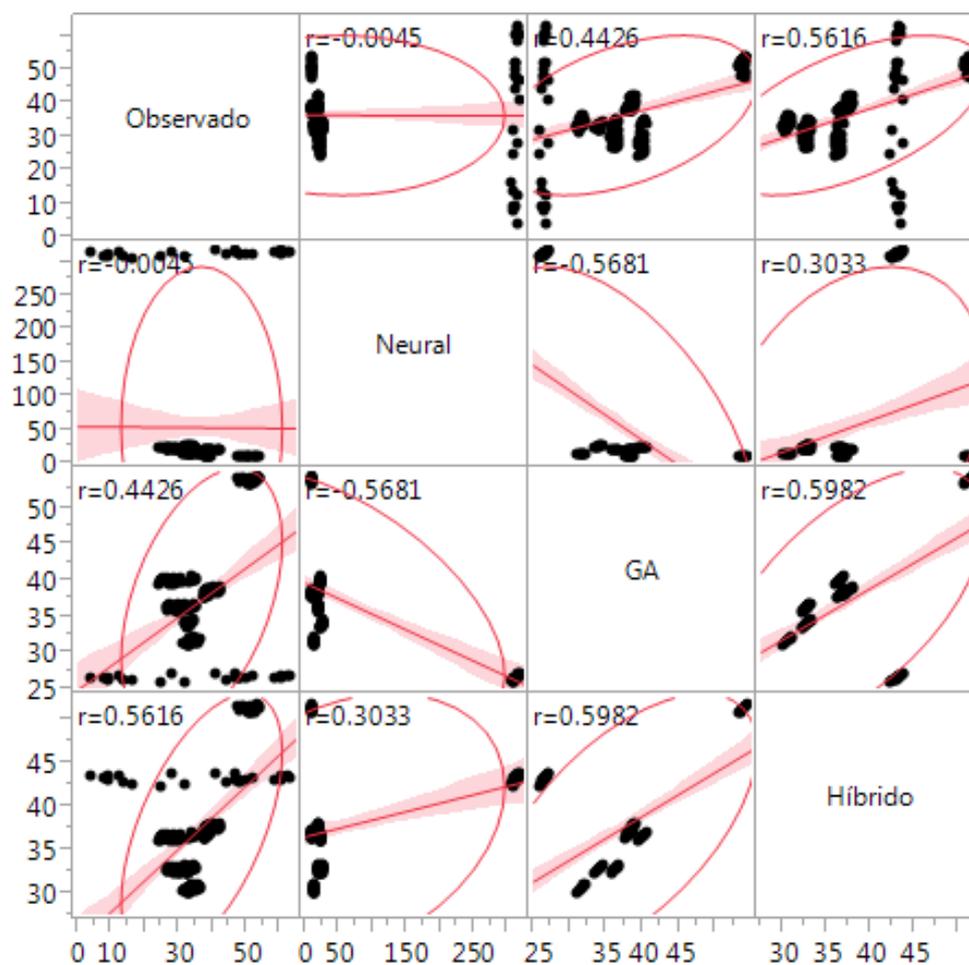


Figura 101 – Gráfico de regressão multivariada do setor Martinez

Tabela 29 - Matriz de correlação esparsa para o setor Martinez

	Observado	Neural	A.G.	Híbrido
Observado	1.0000	0.0045	0.4426	0.5616
Neural	0.0045	1.0000	0.5681	0.3033
A.G.	0.4426	0.5681	1.0000	0.5982
Híbrido	0.5616	0.3033	0.5982	1.0000

5 CONCLUSÕES

Este trabalho teve como objetivo propor e testar novos métodos de calibração através do uso das RNA (redes neurais artificiais) construtivas. Conforme verificado na revisão da literatura, as redes neurais têm sido usadas com êxito para diversas finalidades dentro de modelos de sistemas de abastecimento. Porém, o emprego de redes neurais diretamente para a calibração das redes não é usual.

Apesar das redes neurais serem bem sucedidas em outras áreas, o uso das RNAs isoladamente na calibração não apresentou bons resultados. Porém, o uso combinado das redes neurais com os tradicionais algoritmos genéticos mostrou resultados bastante promissores.

Partiu-se da hipótese que a inserção de valores obtidos através do treinamento das redes neurais dentro da população inicial de algoritmos genéticos seria útil no desempenho da otimização. Os algoritmos genéticos tradicionais realizam buscas a partir de estados iniciais aleatórios. A inserção de soluções obtidas via redes neurais artificiais, mesmo não sendo ótimas, auxiliam o algoritmo genético, fazendo com que a busca seja realizada partindo de pontos mais próximos da solução ótima. A hipótese mostrou-se verdadeira nos testes realizados. Acompanhando os gráficos de convergência dos algoritmos de otimização, verificou-se que o algoritmo genético tradicional despense recursos realizando centenas de avaliações até atingir o mesmo estado já informado pelo método híbrido. A economia de tempo no processo de calibração é um processo importante, pois com o advento das tecnologias de monitoramento em tempo real, novos estudos tem sido realizados, mostrando que a calibração constante dos modelos produz resultados mais confiáveis e redução do nível de incerteza nas simulações.

Quanto a minimização do erro, o método híbrido atingiu resultados superiores ao método tradicional em 3 das 4 redes calibradas. Conforme discutido, esse resultado é pouco relevante, pois a diferença numérica entre os dois métodos de calibração não é significativa, bem como a inspeção visual dos gráficos. Entretanto, pode se supor que a rede neural auxiliou o algoritmo genético a prevenir regiões de mínimos locais. Por outro lado, o critério de avaliação usado no Reino Unido mostrou resultados diferentes. Conforme foi discutido, pesquisadores concordam que a avaliação de desempenho das calibrações é subjetivo e depende da finalidade de uso do modelo. Analisando os gráficos que contabilizam os valores

calibrados dentro de intervalos dos dados de campo, notou-se que pequenas diferenças (muitas vezes de alguns centímetros de coluna de água de carga de pressão) são responsáveis por diminuir significativamente a avaliação sobre a qualidade da calibração. Isso fez com que, ao contrário do que foi concluído anteriormente, classificasse prematuramente os resultados da calibração através do método AG como bastante inferior. Além disso, analisando os intervalos limites que permeiam os resultados da calibração demonstraram que este método de avaliação é bastante restritivo.

A calibração do setor Martinez não apresentou bons resultados para a vazão. Ao que tudo indica, incertezas inerentes ao modelo não proporcionaram o correto ajuste das variáveis de decisão. Entretanto, os métodos de calibração propostos foram úteis para demonstrar que existem erros que necessitam de revisão no setor.

Durante todas as etapas do desenvolvimento do trabalho, buscou-se a redução ou análise das incertezas. As demandas foram quantificadas e foi demonstrado que necessitam de realocação de acordo com o volume consumido durante o dia da semana. A análise dos dados de carga de pressão mostraram a necessidade da escolha dos máximos das cargas de pressão por hora ao invés da média horária, pois isto diminuía o viés dos dados quando comparados aos valores médios. A análise estatística dos dados gerados pelo modelo e a amostragem através do hipercubo latino proporcionaram melhor espalhamento dos dados e redução de dados falhos para o treinamento. As matrizes de correlações finais ilustraram comparativamente os valores observados com cada método de calibração proposto, mostrando que o método híbrido apresenta calibração superior, mas não de forma extraordinária.

É de conhecimento comum que os algoritmos genéticos são boas ferramentas para percorrer o espaço de busca para localização de máximos e mínimos, mas que são pouco eficientes para o ajuste fino das variáveis. Após a determinação das regiões próximas do ponto ótimo, pesquisadores utilizam técnicas de otimização não lineares, como o método de Nelder-Mead, que é um método numérico utilizado para problemas com derivadas não conhecidas. Esta técnica é útil para acelerar o final do processo de otimização, enquanto o método híbrido proposto buscou acelerar o estado inicial do algoritmo genético. Sugere-se, como trabalho futuro, um método híbrido que busque a aceleração do processo de calibração em todas as instâncias do processo.

A incorporação da amostragem através do hipercubo latino no software gerador de padrões proposto foi essencial para o desenvolvimento do trabalho. O uso de amostras aleatórias geravam milhares de quantidades de dados com pouca utilidade que sobrecarregavam a RNA. O treinamento da RNA só foi possível com a nova amostragem proposta, pela diminuição da quantidade de dados e pela qualidade dos dados amostrados.

Não se descarta o uso dos dados sinalizados com erro pelo Epanet para o treinamento das RNA. Estes dados fornecem informações sobre os limites para os quais o modelo hidráulico funciona sem problemas. Entretanto, é necessário uma grande quantidade de dados para delimitar esses pontos exigindo computadores com maior capacidade de armazenamento e processamento.

Dois tipos de redes neurais construtivas foram testadas neste trabalho. A rede neural DAN2 foi bastante eficiente nos testes para a previsão de demandas e destacou-se pela velocidade de treinamento, entretanto não foi capaz de reproduzir o comportamento do modelo hidráulico, gerando saídas sem significado físico e foi descartado no trabalho. No entanto, mais estudos podem ser feitos para determinar variáveis de entradas e saídas mais apropriadas para o processo de calibração utilizando a DAN2. A rede neural AMGA também apresentou bom desempenho nos testes para previsão de demanda e foi útil no processo de gerar populações iniciais para o algoritmo genético. Entretanto, a calibração somente utilizando redes neurais não se mostrou eficiente.

Os softwares auxiliares foram importantes para a modelagem do setor. O software responsável pela correção dos erros gerados pelo EPACAD proporcionou economia de tempo na modelagem dos setores e a eliminação da falha humana comum em processos manuais. A eliminação de nós e trechos desnecessários foram necessários para que a calibração dos modelos ocorresse mais rapidamente, pois proporcionaram a redução no número de elementos nas matrizes responsáveis pelos cálculos numéricos.

REFERÊNCIAS

- ALLEN, M., PREIS, A., IQBAL, M., SRIRANGARAJAN, S., LIM, H. B., GIROD, L., & WHITTLE, A. J. (2011). Real-time in-network distribution system monitoring to improve operational efficiency. *Journal American Water Works Association (AWWA)*, 103(7), 63-75.
- ALPEROVITS, E., AND U. SHAMIR. "Design of optimal water distribution systems." *Water resources research* 13.6 (1977): 885-900.
- ARAUJO, L.; RAMOS, H.; COELHO, S. Pressure control for leakage minimisation in water distribution systems management. *Water Resources Management*, Springer, v. 20, n. 1, p. 133–149, February 2006. ISSN 0920-4741.
- ARREGUI, F.; CABRERA, E.; COBACHO, R. Integrated water meter management. [S.l.]: *IWA Publishing*, 2006. ISBN 9781843390343.
- ARREGUI, F. et al. Key factors affecting water meter accuracy. In: *IWA Leakage Conference*, September 2005. [S.l.: s.n.], 2005.
- BHAVE, P. Calibrating water distribution network models. *Journal of Environmental Engineering*, v. 114, p. 120, 1988.
- BRANISAVLJEVIĆ, N.; PRODANOVIĆ, D.; IVETIĆ, M. Uncertainty reduction in water distribution network modelling using system inflow data. *Urban Water Journal*, v. 6, n. 1, p. 69–79, 2009. ISSN 1573-062X.
- BURROWS, R.; TANYIMBOH, T.; TABESH, M. Some reflections on the building and calibration of useful network models. *Proc., Water Network Modelling for Optimal Design and Management*, Exeter, UK, p. 33–42, 2000.
- BUSH, C.; UBER, J. Sampling design methods for water distribution model calibration. *Journal of water resources planning and management*, v. 124, p. 334, 1998.
- CABRERA, E., GARCIA-SERRA, J., IGLESIAS, P.L. *Modelización de redes de distribución de água*, Mejora del rendimiento y de la fiabilidad em sistemas de distribución de água, editores: Cabrera, E., Vela, A.F., UPV, Espanha, 1994, 536 p.

- CASSA, A. M.; VAN ZYL, J. E. Leakage exponents of elastically deforming cracks in pipes. 12th International Conference on Computing and Control for the Water Industri, CCWI 2013.
- CUTORE, P. et al. Probabilistic prediction of urban water consumption using the SCEM-UA algorithm. *Urban Water Journal*, v. 5, n. 2, p. 125–132, 2008. ISSN 1573-062X.
- DANDY, G. C.; SIMPSON, A. R.; MURPH, L. J. A review of pipe network optimisation techniques. *Watercomp 93*, 1993.
- DANDY, G. C.; SIMPSON, A. R.; MURPH, L. J. An improved genetic algorithm for pipe network optimization. *Water Resour. Res.*, v. 32, p. 449–458, 1996.
- DE SCHAETZEN, W. D.; WALTERS, G.; SAVIC, D. Optimal sampling design for model calibration using shortest path, genetic and entropy algorithms. *Urban Water*, Elsevier, v. 2, n. 2, p. 141–152, 2000.
- DE SCHAETZEN, W. de. (2000). *Optimal Calibration and Sampling Design for Hydraulic Network Models*. Tese (Doutorado)—University of Exeter.
- FERRERI, G.; NAPOLI, E.; TUMBIOLO, A. Calibration of roughness in water distribution networks. In: *Proceeding of second International Conference on Water Pipeline Systems*. [S.l.: s.n.], 1994. v. 1, p. 379–396.
- GHIASSI, M.; BURNLEY, C. Measuring effectiveness of a dynamic artificial neural network algorithm for classification problems. *Expert Systems with Applications*, Elsevier, v. 37, n. 4, p. 3118–3128, 2010.
- GHIASSI, M.; NANGOY, S. A dynamic artificial neural network model for forecasting nonlinear processes. *Computers & Industrial Engineering*, Elsevier, v. 57, n. 1, p. 287–297, 2009.
- GHIASSI, M.; SAIDANE, H. A dynamic architecture for artificial neural networks. *Neurocomputing*, Elsevier, v. 63, p. 397–413, 2005.
- GHIASSI, M.; SAIDANE, H.; ZIMBRA, D. A dynamic artificial neural network model for forecasting time series events. *International Journal of Forecasting*, Elsevier, v. 21, n. 2, p. 341–362, 2005.

- GHIASSI, M.; ZIMBRA, D.; SAIDANE, H. Medium term system load forecasting with a dynamic artificial neural network model. *Electric power systems research*, Elsevier, v. 76, n. 5, p. 302–316, 2006.
- GHIASSI, M.; ZIMBRA, D.; SAIDANE, H. Urban water demand forecasting with a dynamic artificial neural network model. *Journal of Water Resources Planning and Management*, v. 134, p. 138, 2008.
- GIUSTOLISI, O.; SAVIC, D.; KAPELAN, Z. Pressure-driven demand and leakage simulation for water distribution networks. *Journal of Hydraulic Engineering*, ASCE, v. 134, n. 5, p. 626–635, 2008.
- GIUSTOLISI, O.; TODINI, E. Pipe hydraulic resistance correction in WDN analysis. *Urban Water Journal*, v. 6, n. 1, p. 39–52, 2009. ISSN 1573-062X.
- GOLDBERG, D. E. Genetic algorithms in search, optimization and machine learning, Addison-Wesley, Reading Mass, 1989.
- GOMES, G. et al. Hybrid model with dynamic architecture for forecasting time series. In: IEEE. Neural Networks, 2006. IJCNN'06. *International Joint Conference on*. [S.l.], 2006. p. 3742–3747.
- GRECO, M.; GIUSEPPE, D. G. (1999). New approach to water distribution network calibration. *Journal Hydraulic Engineering*, 125(8), 849-854.
- GREYVENSTEIN, B.; ZYL, J. E. v. An experimental investigation into the pressure leakage relationship of some failed water pipes. In: *Journal of Water Supply. Great Britain*, 2007. v. 56, n. 2, p. 117–124.
- HUTTON, C. J., KAPELAN, Z., VAMVAKERIDOU-LYROUDIA, L., & SAVIĆ, D. A. (2012). Dealing with Uncertainty in Water Distribution Systems' Models: a Framework for Real-Time Modeling and Data Assimilation. *Journal of Water Resources Planning and Management*.
- IGLESIAS, P.L. *Modelo general de análisis de redes hidráulicas a presión en régimen transitorio*. Tese de doutorado. UPV, Espanha, 2001. 598 p.
- ISLAM, M.M.; SATTAR, M.A.; AMIN, M.F.; YAO, X.; AND MURASE, K. (2009) "A New Adaptive Merging and Growing Algorithm for Designing Artificial Neural Networks", IEEE Transactions on Systems, Man, and cybernetics- Part B: Cybernetics, vol. 39, no. 3, June 2009.

- JACOBSEN, L. B.; KAMOJJALA, S. Tools and processes for calibrating large all-pipes models. *Urban Water Journal*, v. 6, n. 1, p. 29–38, 2009. ISSN 1573-062X.
- KANG, D. S.; PASHA, M. F. K.; LANSEY, K. Approximate methods for uncertainty analysis of water distribution systems. *Urban Water Journal*, v. 6, n. 3, p. 233–249, 2009. ISSN 1573-062X.
- KANG, K. L. D. Bad data processing for water distribution system demand estimation. *In: Water Distribution System Analysis 2010 - WDSA2010*. Tucson, AZ, USA: [s.n.], 2010.
- KANG, K. L. D. Sequential estimation of demand and roughness in water distribution system. *In: Water Distribution System Analysis 2010 - WDSA2010*. Tucson, AZ, USA: [s.n.], 2010.
- KAPELAN, Z. *Calibration of Water Distribution System Hydraulic Models*. Tese (Doutorado) — University of Exeter, 2002.
- KAPELAN, Z.; SAVIC, D.; WALTERS, G. Multiobjective sampling design for water distribution model calibration. *Journal of water resources planning and management*, v. 129, p. 466, 2003.
- KAPELAN, Z.; SAVIC, D.; WALTERS, G. Optimal sampling design methodologies for water distribution model calibration. *Journal of hydraulic engineering*, v. 131, p. 190, 2005.
- KAPELAN, Z. S.; SAVIC, D. A.; WALTERS, G. A. Multiobjective design of water distribution systems under uncertainty. *Water Resources Research*, v. 41, 2005.
- KAPELAN, Z. S.; SAVIC, D. A.; WALTERS, G. A. Calibration of water distribution hydraulic models using a bayesian-type procedure. *Journal of Hydraulic Engineering*, ASCE, v. 133, n. 8, p. 927–936, 2007.
- KOPPEL, T., & VASSILJEV, A. (2009). Calibration of a model of an operational water distribution system containing pipes of different age. *Advances in Engineering Software*, 40(8), 659-664.
- LAMBERT, A. et al. Review of performance indicators for real losses from water supply systems. *Journal of Water Services Research and Technology (Aqua)*, International Water Services Association, v. 48, n. 6, p. 227–237, 1999.

- LAMBERT, V.; HIRNER, W. Losses from water supply systems: standard terminology and recommended performance measures. *Voda i sanitarna tehnika*, v. 32, n. 1, p. 29–38, 2002.
- LEE, B. Optimal locations of monitoring stations in water distribution system. *Journal of Environmental Engineering*, v. 118, p. 4, 1992.
- LIGGETT, J. A.; CHEN, L.-C. Inverse transient analysis in pipe networks. *Journal of Hydraulic Engineering*, ASCE, v. 120, n. 8, p. 934–955, 1994.
- MALLICK, K. N. et al. Determining pipe groupings for water distribution networks. *Journal of Water Resources Planning and Management*, ASCE, v. 128, n. 2, p. 130–139, 2002.
- NEVES, C. L. Calibração de parâmetros de modelos hidráulicos de redes de distribuição de água para estudos de operação de rede. Brasília/DF, 2007. Dissertação (Mestrado). Universidade de Brasília.
- NICOLINI, M., Patriarca, A. (2011, March). Model calibration and system simulation from real time monitoring of water distribution networks. *In Computer Research and Development (ICCRD), 2011 3rd International Conference on* (Vol. 1, pp. 51-55). IEEE.
- ODAN, F.K.; REIS, L.F.R. (2012). *Hybrid Water Demand Forecasting Model Associating Artificial Neural Network with Fourier Series*. *J. Water Resour. Plann. Manage.* 138 (3), pp. 245-256.
- OLIVARES, J. S. EpaCAD v1.0. Universidad Politénica de Valencia, 2009.
- ORMSBEE, L.; WOOD, D. Explicit pipe network calibration. *Journal of Water Resources Planning and Management*, ASCE, v. 112, n. 2, p. 166–182, 1986.
- PILLER, O.; BREMOND, B.; MOREL, P. A spatial sampling procedure for physical diagnosis in a drinking water supply network. *Proceedings of Water Industry Systems: Modelling and Optimisation Applications*, v. 1, 1999.
- PRECHELT, L. (1994). “PROBEN1—A set of neural network benchmark problems and benchmarking rules,” Faculty Informatics, Univ. Karlsruhe, Karlsruhe, Germany, Tech. Rep. 21/94, 1994.

- PUDAR, R.; LIGGETT, J. Leaks in pipe networks. *Journal of hydraulic engineering*, ASCE, v. 118, n. 7, p. 1031–1046, 1992.
- REED, R. (1993). Pruning algorithms-a survey. *Neural Networks, IEEE Transactions on*, 4(5), 740-747.
- ROSSMAN, L. A. EPANET 2 User's Manual. Cincinnati, 2000.
- RIGHETTO, A. M. *Calibração de Modelo Hidráulico de Rede de Distribuição de Água*. Revista Brasileira de Recursos Hídricos, Vol 6, n. 3 Jul/Set 2001.
- SANZ, G.; PÉREZ, R. Demand Pattern Calibration in Water Distribution Networks. 12th International Conference on Computing and Control for the Water Industri, CCWI 2013.
- SOARES, A. K. (2003). *Calibração de Modelos de Redes de Distribuição de Água para Abastecimento Considerando Vazamentos e Demandas Dirigidas pela Pressão*. São Carlos, 2003. 152 p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.
- SOARES, A. K. (2007). *Calibração e Detecção de Vazamentos em Modelos de Sistemas Hidráulicos no Escoamento Transitório*. São Carlos, 2007. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.
- SOARES, A. K.; CHEUNG, P. B.; REIS, L. F. R. *Avaliação das perdas físicas de um setor da rede de abastecimento de água de Campo Grande - MS via modelo inverso*. Eng. Sanit. Ambient. Vol 9, n. 4, 2004.
- SOARES, A. K., REIS, L. F. R., FORMIGA, K. T., DA SILVA, F. G. B., & CARRIJO, I. B. Aplicação de modelo dirigido pela pressão na estimativa de parâmetros de redes de distribuição de água. XXIV Iberian Latin-American Computational Methods in Engineering, Anais Eletronicos, 2003.
- SPEIGHT, V.; KHANAL, N. Model calibration and current usage in practice. *Urban Water Journal*, v. 6, n. 1, p. 23–28, 2009. ISSN 1573-062X.
- SUMER, D.; LANSEY, K. WDS calibration and assessment for alternative modelling objectives. *Urban Water Journal*, v. 6, n. 4, p. 265–277, 2009. ISSN 1573-062X.
- TODINI, E.; PILATI, S. A gradient algorithm for the analysis of pipe networks. *Research Studies Press Ltd.*, Taunton, UK, UK, p. 1–20, 1988.

- TUCCIARELLI, T.; CRIMINISI, A.; TERMINI, D. Leak analysis in pipeline systems by means of optimal valve regulation. *Journal of Hydraulic Engineering*, ASCE, v. 125, n. 3, p. 277–285, 1999.
- VITKOVSKY, J. P.; SIMPSON, A. R.; LAMBERT, M. F. Leak detection and calibration using transients and genetic algorithms. *Journal of Water Resources Planning and Management*, ASCE, v. 126, n. 4, p. 262–265, 2000.
- WALL, M. *GALib: A C++ Library of Genetic Algorithm Components*. Mechanical Engineering Department, Massachusetts Institute of Technology, 1996.
- WALSKI, T. Technique for calibrating network models. *Journal of water resources planning and management*, v. 109, n. 4, p. 360–72, 1983.
- WALSKI, T. Case study: pipe network model calibration issues. *Journal of Water Resources Planning and Management*, ASCE, v. 112, n. 2, p. 238–249, 1986.
- WALSKI, T.; CHASE, D. V.; SAVIC, D. A. GRAYMAN, W. M.; BECKWITH, S.; KOELLE, E. (2003). *Advanced water distribution modeling and management*. Haestad press.
- WANG, J.; NIU, D.; LI, L. Middle-long term load forecasting based on dynamic architecture for artificial neural network? *Journal of Information & Computational Science*, v. 7, n. 8, p. 1711–1717, 2010.
- WU, W., GAO, J., YUAN, Y., ZHAO, H., & CHANG, K. (2011, April). Water distribution network real-time simulation based on SCADA system using OPC communication. In *Networking, Sensing and Control (ICNSC), 2011 IEEE International Conference on* (pp. 329-334). *IEEE*.
- WU, Z. Y.; SAGE, P. Water loss detection via genetic algorithm optimization-based model calibration. In: *BUCHBERGER, S. G. (Ed.). [S.l.]: ASCE, 2006. v. 247, n. 40941, p. 180–180.*
- WU, Z. Y. et al. Efficient pressure dependent demand model for large water distribution system analysis. In: *BUCHBERGER, S. G. (Ed.). [S.l.]: ASCE, 2006. v. 247, n. 40941, p. 39–39.*
- YEH, W. Review of parameter identification procedures in groundwater hydrology. *Water Resour. Res*, v. 22, n. 2, p. 95–108, 1986.

- YU, G.; POWELL, R. Optimal design of meter placement in water distribution systems. *International journal of systems science*, Taylor & Francis, v. 25, n. 12, p. 2155–2166, 1994.
- ZYL, J. E. v.; CLAYTON, C. R. I. The effect of pressure on leakage in water distribution systems. *Water Management, Proceedings of the Institution of Civil Engineers*, v. 160, n. 2, p. 109–114, 2007. ISSN 1741-7589.

