

FERNANDO HENRIQUE LOURENCETTI

**Estudo da reprodução do comportamento hidráulico de sistemas de  
abastecimento de água via redes neurais artificiais (RNAs).**

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Mestre em Hidráulica e Saneamento.

Área de concentração: Hidráulica e Saneamento

Orientadora: Prof<sup>ª</sup>. Titular Dr<sup>ª</sup>. Luisa Fernanda Ribeiro Reis

VERSÃO CORRIGIDA

São Carlos

Outubro de 2011



AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTES TRABALHOS, 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

L892e Lourencetti, Fernando Henrique.  
Estudo de reprodução do comportamento hidráulico de sistemas de abastecimento de água via redes neurais artificiais (RNAs). / Fernando Henrique Lourencetti; orientador Luisa Fernanda Ribeiro Reis. São Carlos, 2011.

Dissertação (Mestrado - Programa de Pós-Graduação em Hidráulica e Saneamento e Área de Concentração em Hidráulica e Saneamento)-- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2011.

1. Abastecimento de água. 2. Redes neurais. 3. Engenharia hidráulica. I. Título.

## FOLHA DE JULGAMENTO

Candidato: Engenheiro **FERNANDO HENRIQUE LOURENCETTI**

Título da dissertação: **Estudo da reprodução do comportamento hidráulico de sistemas de abastecimento de água via redes neurais artificiais (RNAs).**

Data da defesa: 14/10/2011:

### Comissão Julgadora:

### Resultado:

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

Aprovado

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

Aprovado

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

APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento:  
Prof. Titular **Edson Cezar Wendland**

Presidente da Comissão de Pós-Graduação:  
Prof. Associado **Paulo Cesar Lima Segantine**

## **Agradecimentos**

A Deus pela graça da vida.

Ao Espírito Santo que através de seus sete dons concede auxílio, discernimento, perseverança, fé e esperança, mesmo em meio a desafios e dificuldades.

A Nossa Senhora pela saúde, amparo e proteção na caminhada da vida.

A minha esposa pelo amor, apoio, sacrifício e incentivo em todos os momentos.

A Professora Fernanda pela sábia e segura orientação. Pela paciência. Pela capacidade de auxiliar, ajudar e apoiar. Pela atenção. Sem seus ensinamentos, jamais seria possível o desenvolvimento e conclusão deste trabalho.

Ao Professor Rodrigo de Melo Porto e Professor Erich Kellner pela valiosa atenção, sugestões e composição da banca julgadora.

A meus pais pela educação, exemplo de vida, humildade e superação.

A minha família pelo incentivo.

Ao amigo, parceiro e irmão Fred, cujo agradecimento levarei até o fim de minha vida, pois sem ele, este trabalho não seria possível.

Aos amigos do Laboratório de Simulação Numérica, Tais, Rafael e Narume.

Ao Departamento de Hidráulica e Saneamento da EESC/USP, pela oportunidade de cursar o mestrado.

A todos os Professores do SHS, em especial ao Prof. Eduardo Mário Mediondo.

Aos colaboradores do SHS, em especial a Sá, a Rose e o André.

Ao Professor e Mestre Eng. José Jorge Guimarães pelos ensinamentos e pela amizade. Onde tudo começou.

Aos amigos e colegas do DAAE Araraquara, que sempre me incentivaram nesta caminhada.

Ao Eng. Guilherme Ferreira Soares, Superintendente do DAAE Araraquara, pelo apoio, confiança e autorização para cursar o mestrado.



## Resumo

Lourencetti, F. H. **Estudo da reprodução do comportamento hidráulico de sistemas de abastecimento de água via redes neurais artificiais** (2011). 175 p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

O objetivo deste trabalho foi analisar o comportamento hidráulico de sistemas de abastecimento de água (SDAA), via redes neurais artificiais (RNA). Tendo em vista que o uso de um modelo de simulação hidráulica é inviável para operações em tempo real em SDAA devido à carga computacional que impõe, a abordagem adotada visa capturar o seu conhecimento de uma forma mais eficiente por meio de uma RNA de camada oculta única.

Desta forma os conjuntos de dados provenientes de simulações hidráulicas realizadas utilizando o conhecido e consagrado software EPANET combinando diferentes situações e avaliando as variáveis que compõem os dois sistemas distintos, foram tabuladas e inseridas em forma de rotinas de programação desenvolvidas na plataforma do software Scilab.

Os conjuntos de dados (entradas e saídas) utilizados para treinar a RNA, foram divididos em conjuntos de treino, validação cruzada e testes, aplicada a dois SDAAs distintos. O primeiro denominado Anytown modificado tratou de um sistema hipotético, cuja finalidade foi avaliar a metodologia e fundamentar o conhecimento. Posteriormente aplicou-se a metodologia em outro SDAA, real e mais complexo, utilizado na conferência de calibração WDSA – *Water Distribution System Analysis*, realizada na cidade de Tucson, Arizona (EUA) entre os dias 12 e 15 de setembro de 2010.

Desta maneira foram obtidos valores simulados de potência energética consumida no bombeamento, níveis de reservação e pressões, muito próximos dos valores reais para os dois SDAAs estudados, comprovando que as RNAs identificadas podem ser consideradas ferramentas eficientes na substituição dos modelos de simulação hidráulica convencionais.

**Palavras chave:** Abastecimento de água, Redes Neurais, Engenharia hidráulica

## **Abstract**

Lourencetti, F. H. **Study of reproduction of the hydraulic behavior of water supply systems through artificial neural networks.** (2011). 175 p. Thesis (Master) – School of Engineering of São Carlos, University of São Paulo, São Carlos.

The objective of this study was to analyze the hydraulic systems of water supply (WSS), using artificial neural networks (ANN). Since the use of a hydraulic simulation model is impractical for real-time operations due to the computational load WSS imposing, the approach aims to capture their knowledge more efficiently through a single hidden layer of RNA.

Thus the data sets from hydraulic simulations conducted using the known and established software EPANET combining different situations and evaluating the variables that make up the two different systems were tabulated and entered in the form of programming routines developed in Scilab software platform.

The data sets (inputs and outputs) used to train the ANN, were divided into training sets, cross validation and testing, applied to two distinct WSS. The first called Anytown modified dealt with a hypothetical system, whose purpose was to evaluate the methodology and knowledge base. Later the methodology was applied in another WSS, real and complex, used in the calibration WDSA conference – Water Distribution System Analysis, held in Tucson, Arizona (USA) between 12 and 15 September 2010.

Thus were obtained simulated values of the power energy consumed in pumping, pressures and reservation levels very close to actual values for the two WSS studied, proving that the identified ANN can be considered effective tools to replace in the conventional hydraulic simulation models.

**Keywords:** Water Supply, Neural Network, Hydraulic Engineering.



## Lista de ilustrações

Figura 3.1: Estrutura de um neurônio biológico.....	28
Figura 3.2: Modelo do Neurônio Artificial.....	30
Figura 3.3: Funções de ativação.....	32
Figura 3.4: Modelo baseado em um perceptron multicamadas. ....	33
Figura 3.5: RNA de três camadas.....	34
Figura 3.6: Fluxo de processamento do algoritmo de backpropagation.....	36
Figura 4.1: Fluxograma do código computacional utilizado para geração aleatória de padrões para a RNA.....	42
Figura 4.2: Modelo de rede – Anytown modificada.....	44
Figura 4.3: Modelo de rede – Conferência de calibração de redes WDSA (2010).....	45
Figura 4.4: Processo de captura da base de conhecimento de um modelo de simulação hidráulica através de uma RNA.....	46
Figura 4.5: Modelo de entrada e saída de rede de distribuição de água.....	55
Figura 5.1: Evolução do RMSE ao longo dos 2.000 ciclos de treinamento – Arquitetura [5,20,7]-taxa de aprendizagem 0,4.....	63
Figura 5.2: Evolução do RMSE ao longo dos 5.000 ciclos de treinamento – Arquitetura [5,20,7]-taxa de aprendizagem 0,4.....	63
Figura 5.3: Pesquisa do número de neurônios da camada intermediária que produziu menor RMSE médio ao longo de 2.000 ciclos de treinamento – Arquitetura [5,20,7]-taxa de aprendizagem 0,4.....	64
Figura 5.4: Evolução do RMSE ao longo dos 10.000 ciclos de treinamento – Arquitetura [5,20,7] – taxa de aprendizagem 0,4.....	65
Figura 5.5: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento (kW).....	66
Figura 5.6: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-65 (m).....	67
Figura 5.7: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-165 (m)....	67
Figura 5.8: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-265 (m)....	68
Figura 5.9: Comparativo das amostras observadas x simuladas – Pressões nó J-55 (mH2O).....	68
Figura 5.10: Comparativo das amostras observadas x simuladas – Pressões nó J-90 (mH2O).....	69
Figura 5.11: Comparativo das amostras observadas x simuladas – Pressões nó J-170 (mH2O).....	69
Figura 5.12: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento (kW).....	72
Figura 5.13: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-65 (m)....	73
Figura 5.14: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-165 (m)..	73
Figura 5.15: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-265 (m)..	74
Figura 5.16: Comparativo das amostras observadas x simuladas – Pressões nó J-55 (mH2O).....	74
Figura 5.17: Comparativo das amostras simuladas x observadas – Pressões nó J-90 (mH2O).....	75
Figura 5.18: Comparativo das amostras observadas x simuladas – Pressões nó J-170 (mH2O).....	75
Figura 5.19: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento (kW).....	78
Figura 5.20: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-65 (m)....	79
Figura 5.21: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-165 (m)...	79
Figura 5.22: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-265 (m)...	80
Figura 5.23: Comparativo das amostras observadas x simuladas – Pressões nó J-55 (mH2O).....	80
Figura 5.24: Comparativo das amostras observadas x simuladas – Pressões nó J-90 (mH2O).....	81
Figura 5.25: Comparativo das amostras observadas x simuladas – Pressões nó J-170 (mH2O).....	81
Figura 5.26: Evolução do RMSE ao longo de 2.000 ciclos de treinamento e taxa de aprendizagem 0,4: (A) Arquitetura [23,50,20]; (B) Arquitetura [23,66,20]; (C) Arquitetura [23,80,20]; (D) Arquitetura [23,100,20] e (E) Arquitetura [23,150,20].....	85
Figura 5.27: Evolução do RMSE para a Arquitetura [23,66,20] e taxa de aprendizagem 0,4 usando: (A) 50.000 padrões e (B) 40.000 padrões.....	86
Figura 5.28: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B1 (kW).....	87
Figura 5.29: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B2 (kW).....	88
Figura 5.30: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B3 (kW).....	88
Figura 5.31: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B4 (kW).....	89

Figura 5.32: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B5 (kW).....	89
Figura 5.33: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-1 (m).....	90
Figura 5.34: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-2 (m).....	90
Figura 5.35: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-3 (m).....	91
Figura 5.36: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-4 (m).....	91
Figura 5.37: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-5 (m).....	92
Figura 5.38: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-6 (m).....	92
Figura 5.39: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-7 (m).....	93
Figura 5.40: Comparativo das amostras observadas x simuladas – Pressões nó J-53 (mH2O).....	93
Figura 5.41: Comparativo das amostras observadas x simuladas – Pressões nó J-297 (mH2O).....	94
Figura 5.42: Comparativo das amostras observadas x simuladas – Pressões nó J-302 (mH2O).....	94
Figura 5.43: Comparativo das amostras observadas x simuladas – Pressões nó J-497 (mH2O).....	95
Figura 5.44: Comparativo das amostras observadas x simuladas – Vazões trecho P-374 (L/s).....	95
Figura 5.45: Comparativo das amostras observadas x simuladas – Vazões trecho P-397 (L/s).....	96
Figura 5.46: Comparativo das amostras observadas x simuladas – Vazões trecho P-399 (L/s).....	96
Figura 5.47: Comparativo das amostras observadas x simuladas – Vazões trecho P-467 (L/s).....	97
Figura 5.48: Evolução do RMSE para a Arquitetura [17,60,20] e taxa de aprendizagem 0,4 – utilizando 50.000 padrões de treinamento.....	99
Figura 5.49: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B1 (kW).....	100
Figura 5.50: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B2 (kW).....	100
Figura 5.51: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B3 (kW).....	101
Figura 5.52: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B4 (kW).....	101
Figura 5.53: Comparativo das amostras observadas x simuladas – Potência consumida pelo conjunto de bombeamento B5 (kW).....	102
Figura 5.54: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-1 (m).....	102
Figura 5.55: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-2 (m).....	103
Figura 5.56: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-3 (m).....	103
Figura 5.57: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-4 (m).....	104
Figura 5.58: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-5 (m).....	104
Figura 5.59: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-6 (m).....	105
Figura 5.60: Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-7 (m).....	105
Figura 5.61: Comparativo das amostras observadas x simuladas – Pressões nó J-53 (mH2O).....	106
Figura 5.62: Comparativo das amostras observadas x simuladas – Pressões nó J-297 (mH2O).....	106
Figura 5.63: Comparativo das amostras observadas x simuladas – Pressões nó J-302 (mH2O).....	107
Figura 5.64: Comparativo das amostras observadas x simuladas – Pressões nó J-497 (mH2O).....	107
Figura 5.65: Comparativo das amostras observadas x simuladas – Vazões trecho P-374 (L/s).....	108
Figura 5.66: Comparativo das amostras observadas x simuladas – Vazões trecho P-397 (L/s).....	108
Figura 5.67: Comparativo das amostras observadas x simuladas – Vazões trecho P-399 (L/s).....	109
Figura 5.68: Comparativo das amostras observadas x simuladas – Vazões trecho P-467 (L/s).....	109

## Lista de tabelas

Tabela 5.1: Resultados da melhor taxa de aprendizado para 2.000 ciclos de treinamento – Rede Anytown modificada.....	62
Tabela 5.2: Resultados da melhor taxa de aprendizagem para 5.000 ciclos de treinamento.....	64
Tabela 5.3: Resultados da melhor taxa de aprendizado para 10.000 ciclos de treinamento.....	64
Tabela 5.4: Desvios absolutos (observado x simulado) para 2.000 ciclos de treinamento.....	70
Tabela 5.5: Valores de bias e pesos ajustados das ligações sinápticas: (A) neurônios da camada de entrada para camada intermediária e (B) da camada intermediária para camada de saída.....	71
Tabela 5.6: Desvios absolutos (observado x simulado) para 5.000 ciclos de treinamento.....	76
Tabela 5.7: Valores de bias e pesos ajustados das ligações sinápticas: (A) neurônios da camada de entrada para camada intermediária e (B) da camada intermediária para camada de saída.....	77
Tabela 5.8: Desvios absolutos (observado x simulado) para 10.000 ciclos de treinamento.....	82
Tabela 5.9: Valores de bias e pesos ajustados das ligações sinápticas: (A) neurônios da camada de entrada para camada intermediária e (B) da camada intermediária para camada de saída.....	83
Tabela 5.10: Desvios absolutos (observado x simulado) – Potência consumida pelos conjuntos de bombeamento B1 a B5.....	110
Tabela 5.11: Desvios absolutos (observado x simulado) – Níveis dos tanques T-1 a T-7 (metros).....	110
Tabela 5.12: Desvios absolutos (observado x simulado) – Pressões nós J-53, J-297, J-302 e J-497.....	110
Tabela 5.13: Desvios absolutos (observado x simulado) – Vazões trechos P-374, P-397, P-399 e P-467..	111
Tabela 5.14: Valores de bias e pesos ajustados das ligações sinápticas: neurônios da camada de entrada para camada intermediária – (A1), (A2), (B1), (B2), (B3), (B4) – arquitetura [17,60,20].....	112
Tabela 5.15: Valores de bias e pesos ajustados das ligações sinápticas: neurônios da camada de entrada para camada intermediária – (C1), (C2), (D1), (D2), (D3), (D4), arquitetura [17,60,20].....	116

## Sumário

<b>1. Introdução</b>	11
<b>2. Objetivos</b>	13
<b>3. Revisão bibliográfica</b>	
3.1. Modelos de simulação hidráulica	14
3.1.1 EPANET	17
3.1.2 Modelos empíricos	18
3.1.3 Modelos simplificados	19
3.2. Modelagem via Redes Neurais Artificiais – RNAs	26
3.2.1 Neurônio biológico	28
3.2.2 Neurônio artificial	30
3.3. Funções de ativação	31
3.4. Rede <i>perceptron</i> multicamadas	32
3.5. Aprendizado das RNAs – algoritmo de <i>backpropagation</i>	35
3.6. Verificação das RNAs	39
3.7. Aplicações das RNAs	39
<b>4. Material e métodos</b>	
4.1. Modelagem matemática	41
4.2. Geração de padrões	42
4.3. Os SDAAs utilizados para construção das RNAs	44
4.4. Construção do modelo de simulação hidráulica	47
4.5. Seleção dos pontos críticos para os níveis de armazenamento, pressões e vazões	49
4.6. Execução do modelo com diferentes combinações de condições de partida, demandas e configurações de controle	51
4.7. Modelagem via RNAs	52
4.8. Arquitetura	56
4.9. Critérios de avaliação	58
<b>5. Resultados</b>	
5.1. Geração do conjunto de padrões para treinamento da RNA	59
5.2. Rede Anytown modificada	61
5.2.1. Resultados obtidos	65
5.2.1.1 2.000 ciclos de treinamento	66
5.2.1.2 5.000 ciclos de treinamento	72
5.2.1.3 10.000 ciclos de treinamento	78
5.2.2. Rede WDSA	84
5.2.2.1 Resultados obtidos – arquitetura [23,66,20]	87
5.2.2.2 Resultados obtidos – arquitetura [17,60,20]	99
<b>6. Conclusões</b>	119
<b>7. Referências</b>	122
<b>8. Anexos</b>	
Anexo 1 – Rede Anytown modificada (arquivo .inp)	126
Anexo 2 – Rede WDSA (arquivo .inp)	131
Anexo 3 – Rotina C++ para geração aleatória dos padrões de treinamento da RNA	154
Anexo 4 – Rotina Scilab para treinamento da RNA	163
Anexo 5 – Rede WDSA – Divisão dos DMAs e pontos de monitoramento de pressão e vazão	172
Anexo 6 – Tela do arquivo Excel utilizado para ajuste dos parâmetros básicos de treinamento da RNA	173
Anexo 7 – Tela do arquivo Excel utilizado para armazenar os padrões de treinamento (entradas) da RNA	174
Anexo 8 – Tela do arquivo Excel utilizado para armazenar os padrões de Treinamento (saídas) da RNA	175

## 1. Introdução

Os Sistemas de Distribuição de Água para Abastecimento (SDAAs) são utilizados para suprir as necessidades de núcleos populacionais urbanos. Assim, devem prover água em quantidade e qualidade adequadas ao consumo, desempenhando importante papel sobre a saúde das populações por eles servidas, dentre outros objetivos.

Segundo Gomes (2009) os SDAAs são conjuntos de equipamentos, obras e serviços voltados para o suprimento de água às comunidades, para finalidades domésticas, comerciais, industriais e públicas, normalmente compostos por unidades de captação superficial ou subterrânea, tratamento, estações elevatórias, adução, reservatórios, redes de distribuição e ligações.

A concepção e o dimensionamento de cada elemento constituinte desses sistemas ocorrem de maneira integrada, apesar da peculiaridade inerente a cada etapa dos projetos de engenharia.

No dimensionamento de cada elemento constituinte do sistema, o fator econômico-financeiro, que considera os custos de investimento e de operação, não pode ser negligenciado, uma vez que boa parte dos recursos econômico-financeiros das companhias de abastecimento de água pode ser comprometida na sua operação e manutenção, com destaque aos custos relativos ao consumo de energia elétrica.

Por essa razão grande esforço vem sendo empenhado por pesquisadores do Brasil e exterior no sentido de promover a operação de SDAA de maneira otimizada, tanto no longo prazo como em tempo real.

A otimização da operação em tempo real pode ser realizada de maneira que consumos previstos para um horizonte de planejamento, geralmente curto, de amplitude diária e convenientemente discretizado em intervalos horários, sejam utilizados na determinação da estratégia operacional do período, sendo que somente a estratégia da primeira hora é efetivamente implementada. Transcorrido mais um intervalo de tempo, os dados de consumo são atualizados e utilizados para reinicializar o processo de previsão de consumos e otimização, de maneira sequencial e progressiva ao longo do tempo.

Tal procedimento impõe avaliações das respostas do sistema às estratégias operacionais diversas. Mas, se por um lado o modelo utilizado para prever as consequências de diferentes configurações de controle precisa ser computacionalmente eficiente, altamente preciso e numericamente robusto, por outro, embora as leis físicas que regem o escoamento no interior de tais sistemas possam ser consideradas estabelecidas, através das equações clássicas de conservação de massa e energia, a resolução dos sistemas de equações resultantes pode se mostrar intensiva em termos do tempo de processamento computacional, especialmente para os sistemas de grandes dimensões e mais complexos.

Assim, os modelos de simulação hidráulica podem ter a precisão e robustez necessária, mas não apresentam a necessária eficiência computacional para redes de grande porte (Cunha, 2009).

Já os modelos empíricos e simplificados de redes hidráulicas mostram-se computacionalmente mais eficientes que os modelos de simulação hidráulica, mas a sua precisão e robustez são questionáveis.

Pesquisadores como Jamieson *et. al.* (2007) propõem a combinação dessas técnicas, usando os resultados de um modelo de simulação hidráulica convencional de rede para treinar uma Rede Neural Artificial (RNA). Desta forma, a base de conhecimento complexo do modelo de simulação hidráulica é capturada pela RNA que, posteriormente, será utilizada em substituição ao modelo de simulação hidráulica convencional para predizer o comportamento da rede utilizada para a realização das simulações hidráulicas e posterior treinamento da RNA.

O presente trabalho de pesquisa tem como objetivo investigar a metodologia proposta por Jamieson *et al.* (2007), cujo propósito é capturar o conhecimento relativo ao comportamento de sistemas de abastecimento de água via RNAs.

O presente trabalho tem por objetivo investigar o desempenho das RNAs, para capturar os resultados de um sistema de hidráulico de grande porte devidamente calibrado.

---

## 2. Objetivos

Constitui objetivo do presente trabalho a investigação do emprego de RNAs para a reprodução do comportamento hidráulico primeiramente de um SDAA hipotético, de pequeno porte, denominado Anytown Modificado (Rao & Alvarruiz, 2010), cuja finalidade é testar e avaliar a metodologia proposta. Sequencialmente, após a fundamentação teórica, aplicou-se a metodologia a um SDAA de grande porte utilizado na conferência de calibração WDSA – *Water Distribution System Analysis*, realizada na cidade de Tucson, Arizona (EUA) entre os dias 12 e 15 de setembro de 2010.

Para tanto, o trabalho compreendeu as etapas de elaboração de uma rotina de construção e treinamento de RNAs, escolha e caracterização do sistema objeto de estudo, o emprego da rotina computacional para treinamento, validação cruzada e teste das RNAs correspondentes, bem como a escolha da arquitetura que melhor represente as características dos SDAAs estudados.

### 3. Revisão bibliográfica

Os modelos de rede de distribuição de água destinam-se à previsão das respostas de tais sistemas face às diversas condições operacionais e ambientais a que podem ser submetidos, sem a necessidade de interferir no seu funcionamento ou submetê-los a modos operacionais desconhecidos.

A importância dos modelos reside no fato de que através deles, os problemas podem ser antecipados e as soluções avaliadas antes dos investimentos serem realizados. Daí a importância que lhes é atribuída.

Diversos tipos de modelo já foram propostos para prever o comportamento das redes de distribuição de água para abastecimento, dentre os quais se destacam os modelos de simulação hidráulica, modelos empíricos e modelos simplificados, conforme detalhados a seguir.

#### 3.1 Modelos de simulação hidráulica

Os modelos de simulação hidráulica de redes oferecem a possibilidade da reprodução de dinâmicas não-lineares dos SDAA através da resolução do sistema de equações que representam as leis físicas do escoamento sob pressão, incluindo a conservação de massa e de energia.

O reconhecimento do papel que tais ferramentas podem desempenhar fez com que nos últimos trinta anos, investimentos significativos tenham sido feitos no desenvolvimento de modelos de simulação hidráulica genéricos. Pacotes computacionais como WESNET, InfoWorks, GINAS, STONER/SynerGEE, EPANET, AQUIS, WATNET, WaterCAD, vêm sendo amplamente utilizados com propósitos diversos, dentre os quais destacam-se o planejamento de projetos, as análises operacionais e o desenvolvimento de estratégias de controle de SDAA.

A simulação hidráulica avalia as respostas do sistema face às decisões operacionais em termos das suas variáveis de estado: pressão, vazão e níveis nos tanques. É portanto uma ferramenta imprescindível à rotina computacional que quantifica os objetivos estabelecidos. Utilizou-se neste trabalho, o EPANET 2.0 (Rossman, 2000) para este fim, pois além de tratar-se de uma ferramenta de domínio público, é bastante flexível com relação às mudanças de funcionamento quando necessárias de dispositivos tais como válvulas, bombas, entre outros.

Segundo Tucci (1998) modelos de simulação são modelos matemáticos cujas técnicas permitem representar alternativas propostas e simular condições reais que poderiam ocorrer dentro de uma faixa de incertezas, inerentes ao conhecimento.



De acordo com Silva (2003) apesar do reconhecimento dos modelos matemáticos como ferramentas úteis à análise hidráulica das redes de distribuição de água para abastecimento, na prática eles são pouco utilizados. Mesmo com os aperfeiçoamentos e até sofisticções dos modelos existentes atualmente, que permitem a implementação de hipóteses simplificadoras sobre os sistemas físicos reais, diversas são as razões para que os profissionais da área releguem-nos a segundo plano.

Dentre elas, figura a inexistência de cadastros atualizados dos SDAA de maneira a refletir a realidade de campo tais como a falta de setorização física ou mesmo em certos casos inadequada, muitas vezes pelo simples desconhecimento das singularidades existentes ou a da condição operacional dos mesmos, além do desconhecimento de grandezas características tais como níveis de reservatórios e demandas.

As redes reais podem ser consideradas elementos constituintes de sistemas resultantes de diversas intervenções das mais variadas naturezas. Desde a implantação das mesmas, alterações substanciais nas demandas ocorrem principalmente devido ao crescimento e à redistribuição da população ao longo de seu traçado. Muitas vezes expansões e ações de reabilitação nas redes de distribuição (substituições, adições e limpeza), fatores como envelhecimento, desgaste e ocorrência de incrustações fazem com que características como rugosidade e diâmetro interno dos condutos sofram alterações significativas.

Pressões internas excessivas e tráfego intenso de veículos promovem o surgimento de fissuras nos condutos, acessórios e junções, que passam a apresentar vazamentos. Além das redes sofrerem as citadas intervenções, geralmente não se pode contar com o cadastro fidedigno de tais sistemas, dado que a atualização das informações pelas equipes de campo nem sempre é realizada.

Assim é muito comum não se dispor de informações completas sobre a localização de registros, válvulas, conexões dentre outras singularidades existentes e suas condições reais de funcionamento. Inspeções de campo podem complementar tais informações, mas é usual que os acessos aos registros desapareçam como consequência da execução de obras como o asfaltamento de vias públicas, alterações nas diretrizes dos arruamentos, execução de obras de arte, dentre outras.

Segundo Azevedo *et al.* (2000), a crescente complexidade do gerenciamento de recursos hídricos, tanto no planejamento como na solução de conflitos por água em qualidade e quantidade suficientes para suprir as demandas dos diversos usos deste precioso bem, tem necessitado do emprego de técnicas e instrumentos capazes de auxiliar na tomada de decisão.

De acordo com Albano (2004), uma das ferramentas utilizadas na gestão de recursos hídricos é a modelagem matemática, seja de quantidade ou de qualidade de água. Um modelo matemático

consiste da resolução de uma única equação ou um conjunto de equações matemáticas formuladas para representar um processo natural ou artificial. O processo de modelagem, de forma geral, envolve o conhecimento:

- do fenômeno a ser estudado;
- do problema a ser resolvido;
- da abstração (uma simplificação do problema);
- dos objetivos, restrições e critérios de solução que devem ser declarados;
- da definição e a formulação do modelo com a escolha das equações que descrevem o processo e algoritmos de solução;
- da verificação do modelo quanto à lógica de cálculo e formulação das equações;
- da calibração do modelo (comparação entre o processo modelado e o real);
- da avaliação do modelo para um possível refinamento;
- da análise de sensibilidade que identifica e aprimora o nível de precisão do modelo;
- da validação cuja finalidade é comparar o processo modelado e um novo conjunto de dados reais;
- da simulação propriamente dita.

A simulação matemática tem como principal vantagem a flexibilidade em representar sistemas simples e sistemas complexos na forma de modelos computacionais. A modelagem em rede de fluxo permite a tomada de decisão através de um conjunto de soluções viáveis que podem ser otimizadas por técnicas específicas (Araújo, 2002).

As equações da continuidade e da conservação da energia e a relação entre a perda de carga e a vazão, que caracterizam as condições de equilíbrio hidráulico da rede num dado instante, podem ser resolvidas através de um método híbrido nó-malha.

Todini e Pilati (1987) optaram por designá-lo como sendo o “Método Gradiente”, método utilizado no simulador hidráulico EPANET para obtenção dos valores de pressão e vazão na rede.

De acordo com Souza (1994), um SDAA é definido como um arranjo de tubos cujo propósito é transportar água ao consumidor. Esse sistema é considerado como uma coleção de vários tipos de componentes que são interligados entre si.

A rede hidráulica consiste de um número qualquer de nós e trechos de acordo com qualquer configuração desejada. Reservatórios podem ser introduzidos em qualquer nó e cada trecho pode

incluir bombas, turbinas, válvulas e outros elementos hidráulicos onde a relação energia-vazão é conhecida.

A análise em regime permanente de SDAA é um problema de grande importância na engenharia. As equações hidráulicas básicas que descrevem o fenômeno são formulações algébricas não lineares. Normalmente a solução para o problema de redes é obtida quando algumas condições hidráulicas são satisfeitas:

- A soma algébrica das vazões em qualquer nó deve ser igual a zero (conservação da massa em cada nó);
- O valor da energia piezométrica em um nó deve ser a mesma para todos os tubos conectados a este nó;
- A relação de carga e vazão deve ser satisfeita para cada elemento da rede.

A solução dos problemas de projetos de redes consiste nos diâmetros, vazões, perdas de carga para todos os elementos do sistema, e os correspondentes valores das respectivas condições de contorno.

### 3.1.1 EPANET

De acordo com Rossman (2002) o EPANET é um programa de computador que permite executar simulações estáticas e dinâmicas do comportamento hidráulico e de qualidade da água de SDAA operando em regime de pressão.

Os SDAAs são constituídos por tubos, bombas, válvulas, reservatórios de nível fixo e/ou reservatórios de nível variável. O EPANET permite obter valores de vazão em cada trecho de rede bem como pressão em cada nó, níveis de água nos reservatório e concentração de elementos químicos presentes na rede durante o período de simulação, subdividido em múltiplos passos de cálculo.

Adicionalmente o cálculo da idade e o rastreamento da origem da água em qualquer ponto da rede também podem ser levados em conta na simulação. O EPANET foi concebido para ser uma ferramenta de apoio à análise dos SDAA, podendo ser utilizado em diversas situações onde seja necessário efetuar simulações dos sistemas de distribuição, melhorando o conhecimento sobre as condições de transporte e o destino dos elementos constituintes da água para consumo humano.

O estabelecimento de cenários de projeto, tais como a expansão de uma rede existente, a calibração de modelos hidráulicos, a análise do decaimento do cloro residual e a avaliação dos consumos constituem alguns exemplos.

O EPANET pode auxiliar também em análises estratégicas e alternativas de gestão nos seguintes casos:

- Alteração de esquemas de funcionamento de grupos elevatórios e enchimento/esvaziamento de reservatórios de nível variável;
- Utilização de tratamento adicional (recloração);
- Seleção de tubos para limpeza, reabilitação e/ou substituição.

O EPANET fornece ainda um ambiente integrado para editar dados de entrada da rede, executar simulações hidráulicas e de qualidade da água e visualizar os resultados em vários formatos. Estes últimos incluem a possibilidade de visualizar mapas da rede com codificações diferenciadas por cores, tabelas de dados, gráficos de séries temporais e gráficos de isolinhas.

### 3.1.2 Modelos empíricos

O comportamento de redes de distribuição de água em geral e sua dinâmica hidráulica em particular, são variáveis ao longo do tempo. Esse comportamento altamente não-linear pode ser representado quer por meio de modelos empíricos, como por exemplo, somente de equilíbrio de massa, quer por um processo baseado em modelos, como a simulação hidráulica.

Neste contexto, os modelos de balanço de massa consistem de relações funcionais ponderadas entre o armazenamento e as vazões da estação de bombeamento. Os pesos associados às relações funcionais podem ser determinados através de regressão linear (Sterling & Coulbeck, 1975) ou a partir de linearização da rede não-linear (Fallside & Perry, 1975).

A principal vantagem dos modelos de balanço de massa é que a resposta do sistema pode ser determinada muito mais rapidamente do que através de um modelo de simulação hidráulica. São, contudo, mais apropriados para a água de sistemas regionais de abastecimento, que redes de distribuição.

Um modelo de balanço de massa simples, de natureza não-linear da rede hidráulica poderia ser representado com mais precisão, utilizando um conjunto de equações de regressão linear. Informações necessárias à construção de um modelo desse tipo podem ser obtidas de diversas formas. Por exemplo, as curvas de regressão podem ser geradas por execuções repetidas de um modelo de simulação de

reservatórios calibrados para diferentes níveis e condições de armazenamento, de carga, ou usando informações de operações reais para formar uma base de dados sobre a altura manométrica de bombeamento, vazões, níveis de reservatório e demandas de rede.

Os modelos de regressão têm a capacidade de incorporar algum grau de não-linearidade, proporcionando um mecanismo eficiente para estimar a resposta da rede. No entanto, as curvas de regressão e de bases de dados contêm informações apenas para uma determinada rede e determinado intervalo de demandas. Se para alterações na rede ou exigências previstas fora do alcance do banco de dados, tal abordagem pode produzir resultados insatisfatórios.

Em geral, estes modelos são bastante simples e úteis no dia a dia. No entanto, são pouco robustos, uma vez que são específicos para a região e condições para as quais as relações foram estimadas. Além disso, os modelos empíricos não possibilitam fazer simulações de mudanças em condições para os quais o modelo não previu.

Os modelos podem ser também baseados em processos e em geral, são mais complexos que os empíricos, uma vez que procuram descrever toda a metodologia que envolve determinado fenômeno estudado. Os modelos baseados em processos podem ser subdivididos em modelos conceituais e modelos físicos. Os conceituais fazem uso de equações empíricas e por isso também são chamados de modelos semi-empíricos, mas que descrevem o sistema segundo as leis da física. Já os modelos físicos, utilizam as principais equações diferenciais do sistema físico na representação dos processos. Podem ser estimados através de medidas e observações reais, uma vez que seus parâmetros possuem um significado físico.

Apesar dos fenômenos naturais variarem continuamente no tempo, na maioria das vezes, estes fenômenos são representados por modelos discretos. A escolha do intervalo de tempo (passo) no qual o modelo será executado depende basicamente do fenômeno estudado, da disponibilidade de dados e da precisão desejada nos resultados.

Em geral, quanto menor o intervalo de tempo maior será a precisão dos resultados, aumentando também o custo computacional para geração destes resultados.

### **3.1.3 Modelos simplificados**

Como um passo intermediário entre modelos empíricos e de simulação hidráulica de uma rede completa, um modelo simplificado pode ser considerado. Nestes casos, o sistema hidráulico da rede é aproximado usando um modelo de rede simplificado, que utiliza como referencial, funções analíticas cuja implementação computacional é substancialmente mais simplificada, que a estrutura de

simulação. Modelos simplificados avaliam a rede discretamente, por trechos ou seções, representando o layout das tubulações através do uso de um modelo esquematizado. As abordagens simplificadas tradicionais são estáticas, e avaliam um único estado da rede, que representa condições médias ou acumuladas no espaço de tempo.

Demoyer & Horowitz (1975) utilizaram modelos simplificados compostos de diversos termos relacionados ao efeito de vários componentes da rede, constituída dentro de uma única equação. Em certos casos, quando as condições de contorno são essencialmente independentes da estação de bombeamento, pode ser possível por meio de um modelo linear simples representar a rede hidráulica.

Jowitt & Germanopoulos (1992) usaram um modelo linear aproximado de uma rede dominada por diferentes alturas manométricas de bombeamento, em que pequenas variações nos níveis de armazenamento não afetavam significativamente a operação da bomba. Em uma aplicação similar, Little & McCrodden (1989) desenvolveram um modelo linear simples para uma rede de abastecimento em que o nível hidrostático no reservatório de controle foi mantido constante.

Os coeficientes para ambos os modelos, são determinados através de uma ampla análise dos dados para formulação, cujos resultados são específicos de cada local e devem ser julgados com base nesta peculiaridade para determinar sua aceitabilidade.

De acordo com Shamir e Howard (1977), a inclusão de cada tubo, peça ou equipamento da rede real, no modelo computacional, não se faz necessária. Na prática sistemas reais de distribuição são freqüentemente esquematizados antes de se proceder à análise, sendo representados no modelo somente os elementos mais importantes, como as tubulações de diâmetros maiores.

Esse passo da análise é particularmente importante quando se está analisando SDAA em cidades que apresentam maiores extensões de redes com grandes variações de diâmetros dos tubos. Muitas das tubulações menores podem não ser importantes para a capacidade da rede na distribuição de grandes quantidades de água às várias regiões do sistema.

Desta forma, a capacidade de uma rede para conduzir água dos reservatórios para os nós principais de consumo pode ser avaliada através de uma rede simplificada com tubos fictícios. A capacidade de transporte de vazão prevista para essa rede deve ser a mesma da rede real.

Uma técnica para desenvolver uma rede simplificada é obter soluções para uma série de condições de carga. Essas soluções devem incluir um número de tubos com fatores de resistência desconhecidos em uma rede esquematizada, contendo somente as mais importantes tubulações da rede real. Tal fato define o modelo simplificado. Os resultados da análise de um modelo maior e mais

realista ou dados de campo reais podem ser utilizados para determinar valores de consumo conhecidos e cargas totais para o modelo hipotético de análise.

O método discutido permite visualizar soluções diretas para as resistências dos tubos fictícios, que corresponderiam ao comportamento de uma rede cuja complexidade seja maior. Vazões e cargas hipotéticas podem ser determinadas por processo similar. Desenvolver uma rede simplificada é equivalente a calibrar um modelo de rede para representar adequadamente a distribuição real do sistema.

Modelos simplificados são necessários quando a eficiência computacional da solução é decisiva, como no caso de controle operacional em tempo real. Na época em que o tempo de processamento computacional ainda era um grande problema, Shamir e Howard (1977), mostram que a prática comum era reduzir o número de tubos a outro valor, tendo para tanto a capacidade de carga equivalente.

Se uma rede de cem nós pudesse ser reduzida para cinquenta nós, o custo de tempo computacional seria reduzido, aproximadamente, por um fator quatro, pois o tempo de computação varia com o quadrado do número de nós. Essa pôde ser uma importante consideração na análise da relação custo x benefício do tempo computacional, especialmente se forem consideradas simulações da operação de armazenamento, análises de otimização de redes ou controle da operação em tempo real.

Luvizotto Jr. (2000) salienta que na modelação de um escoamento, além de se ter em conta o conjunto de equações adequado para representar o estado do fluxo, é necessária uma adequada descrição da configuração da rede. O grau de detalhes que se deve utilizar para descrever a topologia, ou seja, como as tubulações e acessórios devem ser considerados para que a modelação seja a representação fiel da realidade é uma questão relevante, cuja solução não poderá abstrair de investigações para cada caso.

Para a esquematização deve ser feito um trabalho de síntese uma vez que geralmente, não é possível representar no modelo teórico todos os condutos integrantes da rede, mas somente os principais. Ainda assim, os nós devem concentrar as demandas de vários usuários em um só ponto, hipótese de trabalho que simplifica a realidade.

Apresentam-se na sequência algumas observações práticas utilizada na elaboração do modelo, tornando-o mais confiável e simples de se utilizar:

- Tubulações:

Para reduzir o número de tubos e nós recomenda-se utilizar diâmetros iguais ou maiores que 100 ou 150 mm. Em caso de ser necessário incluir diâmetros menores, convêm substituí-los por condutos equivalentes. Isso é particularmente importante nas vizinhanças das fontes de alimentação do sistema.

- Carga nos reservatórios:

A carga nesses pontos de alimentação deve ser um parâmetro altamente confiável dos modelos, devido à relativa simplicidade das medições. Os níveis dos reservatórios, pressão das bombas, etc., têm seus valores quantificáveis com equipamentos de controle adequados, por exemplo, células de pressão, manômetros digitais de boa precisão, etc.

- Consumos associados aos reservatórios:

De forma similar à carga, o consumo na rede deve ser um parâmetro confiável ao se estruturar o modelo. Atualmente existe no mercado uma gama de equipamentos destinados a medição de vazão, com precisões razoáveis.

- Consumo nos nós:

É uma das variáveis mais complexas de se estimar e, visto que é parâmetro fundamental no desempenho do modelo de simulação, deve ser avaliada da maneira mais criteriosa possível. Uma estimativa correta dos consumos nos nós é bastante difícil de ser realizada. Depende da população atendida pelo nó, do tipo de uso da água (residencial, público, comercial, etc.), e também depende do dia e da hora de maior consumo.

- Coeficientes de perda de carga:

Uma das mais difíceis tarefas é a calibração de uma rede, bem como a seleção apropriada dos coeficientes de perda de carga nos condutos, tais como os coeficientes de Hazen-Williams ou de Darcy-Weisbach. A mais indicada forma para a estimativa desses coeficientes são as observações em campo, ou seja, medir o coeficiente de perdas de certo número de trechos de rede, considerando sempre os mais representativos possíveis e então traçar uma curva de coeficientes de perda x idade da tubulação, obtendo assim a partir de tal curva os coeficientes de perda de carga para cada segmento da rede.



Garcia Serra (1988) observa que em primeiro lugar, deve-se definir a topologia do modelo, ou seja, de quais tubulações irá se compor. A fim de atingir o objetivo, deve-se dispor de um conjunto o mais detalhado possível de dados da rede relativos a:

a) Relação completa de tubulações do sistema

- diâmetros
- extensões
- material
- idade
- estado de conservação

b) Relação completa das válvulas

- diâmetros
- graus de abertura
- tipo de função
- estado de conservação

c) Mapas com curvas de nível de metro em metro

Uma vez agrupadas essas informações, deve-se definir até que nível de detalhes será considerado na elaboração do modelo. Podem acontecer basicamente dois casos:

- Redes pequenas (até cerca de 200 tubos): possível se chegar a um grande nível de detalhes, de maneira que sejam representados todos os tubos e nós do sistema;
- Redes maiores: necessária uma simplificação do modelo real, constituindo essencialmente em

a) eliminação de alguns tubos de pequeno diâmetro;

b) associação de tubos em série ou em paralelo;

c) unificação de nós próximos;

d) eliminação de ramais, substituindo-os por seu consumo no ponto de encontro com a rede, a menos que se queira determinar pressões no próprio ramal.

Em qualquer simplificação deve-se levar em conta a situação das tubulações com relação ao fluxo principal, pontos de consumo e manutenção da capacidade de condução do sistema original.

Em geral trata-se de eliminar todas as tubulações que afetem muito pouco a capacidade de condução do sistema. Normalmente trata-se de condutos de pequeno diâmetro que formam malhas equilibradas, ou seja, a vazão por ambos extremos do circuito é afluyente. Todavia, uma variação importante no estado de consumos da rede pode fazer com que os condutos apresentem acréscimos de vazão, sendo que a aproximação efetuada afetaria, mais ou menos segundo o diâmetro e a vazão circulante, a capacidade de condução do sistema. Nesse caso, o entorno seria modificado pela eliminação dos condutos.

Garcia Serra (1988) explana que vários autores haviam proposto, quase três décadas antes, a possibilidade de eliminar as tubulações de 80 mm de diâmetro ou menores quando a rede for pequena, e de até 200 mm para redes maiores.

Desta forma, as rugosidades finais nas tubulações do modelo devem ser ajustadas com a finalidade de minimizar o erro entre valores calculados e valores medidos. Se a tendência é a diminuição exagerada das rugosidades, é de se imaginar que o sistema foi excessivamente esqueletizado. Conclui que sempre podem ser eliminadas tubulações, desde que a capacidade de condução não seja reduzida no modelo.

#### - Coincidência de nós próximos

Esta simplificação consiste basicamente em unir dois ou mais nós da rede em um só, no modelo, sempre que estejam suficientemente próximos, de forma que seja possível considerar a cota piezométrica em ambos como sendo praticamente a mesma. Trata-se de um caso muito freqüente, pois é habitual que os condutos circulem por ambas as calçadas de uma rua. Também é possível realizar essa união em pequenas praças, de onde confluem várias tubulações, quando a distância que separa seus nós de cabeceira é pequena, podendo ser desprezada a perda de carga ente eles.

Evidentemente o consumo de cada nó passará a fazer parte do consumo do nó resultante. Em qualquer caso, a inclusão no sistema de condutos de resistência ao escoamento muito pequena pode dar lugar a problemas de convergência quando da resolução do sistema de equações que se forma. Não se ter em conta esses condutos é irrelevante, pois suas resistências serão acumuladas a outros segmentos do sistema no momento de ajustar o modelo.

#### - Importância do consumo na topologia adotada

O grau de esqueletização de uma rede depende da distribuição dos consumos na mesma. Costuma-se atribuir os consumos aos nós do modelo. Pode-se concluir então, que o número de nós do modelo e portanto, o de condutos, será claramente influenciado pela distribuição de consumos. A

simplificação de coincidência de nós pode dar-se quando apresentarem consumos semelhantes, porém quando um nó possuir consumo muito superior aos demais, esse deve ser mantido em sua forma original, no modelo topológico.

- Associação de tubulações em série e em paralelo

Dado um conjunto de tubulações, denomina-se conduto equivalente à tubulação resultante da associação entre elas, de tal forma que seja produzida uma mesma perda de carga que a anteriormente verificada, para uma mesma vazão, ou seja, é uma tubulação fictícia que substitui várias outras e mantém o mesmo comportamento hidráulico do conjunto anterior.

A metodologia a ser utilizada na obtenção dos condutos equivalentes, tanto na associação em série quanto na associação em paralelo é bastante simples, podendo ser encontrada em qualquer manual de hidráulica. O que é importante e deve ser ressaltado é que expedientes como o apresentado são muito utilizados na simplificação de uma malha mais complexa.

Segundo Eggener e Polkowski (1976), questões relacionadas ao grau de detalhamento e esqueletização necessário ao bom funcionamento dos modelos de distribuição têm atraído a atenção dos analistas desde que as técnicas de balanço de redes foram introduzidas. Sugere-se que os investigadores mais antigos esqueletizavam os sistemas a fim de que os cálculos pudessem ser feitos com régua de cálculo.

Na possibilidade de se desconsiderar uma tubulação mais próxima de reservatórios de abastecimento, com uma vazão provavelmente mais concentrada, é de se esperar um erro maior que se tal tubulação estiver mais a jusante. Dessa forma, ressalta-se a importância de se considerar também os tubos de diâmetros menores nas vizinhanças das maiores fontes de suprimento e de grandes cargas concentradas (vazões pontuais).

Segundo Ormsbee e Lingireddy (1997), antes que um sistema de distribuição real possa ser modelado ou simulado por um programa, o sistema físico deve ser representado em uma forma que o computador possa analisar. Isso requer que o sistema de distribuição seja inicialmente representado por uma base de dados de nós articulados entre si.

Nesse caso, as articulações representariam tubos individuais, e os nós representariam pontos no sistema onde dois ou mais tubos se conectam ou onde a água estiver sendo injetada. Os dados associados com cada seção do tubo incluem a identificação do número do tubo, o comprimento, diâmetro e rugosidade. Dados associados com cada nó de junção incluem o número de identificação da junção, a cota e a demanda no ponto.

Walski (1990) aponta uma série de problemas possíveis de ocorrer na fase de definição da topologia da rede:

- Modelos de sistemas reais, onde a maior parte da vazão escoar por tubos de pequenos diâmetros, tendo esses tubos sido deixados de lado na representação topológica;
- Esquecimento de se representar válvulas ou outros dispositivos no modelo topológico pode levar a conclusões errôneas;
- Representar uma determinada tubulação como interconectada ao sistema, sendo que, na verdade, encontra-se desconectada das outras;
- Válvulas consideradas abertas no modelo podem estar parcialmente fechadas na realidade, ocasionando uma grande perda de carga localizada e discrepância nos resultados. Aí se incluem também os casos de válvulas totalmente fechadas ou com defeito.

Embora seja reconhecido que o escoamento das vazões é dado de forma variável no tempo, através das conexões existentes ao longo do comprimento, é geralmente aceitável em modelação relacionar metade da vazão ao longo do segmento de tubo ao nó de montante, e a outra metade ao nó de jusante. Além das tubulações da rede e dados dos nós, devem ser obtidos dados de todos os reservatórios e tanques, bombas e válvulas. Os dados acerca de reservatórios incluem informações sobre a geometria dos mesmos e níveis iniciais de água. Dados de bombas incluem o valor da potência média útil que descrevem a curva característica (altura manométrica x vazão).

Técnicas baseadas em soluções analíticas geralmente requerem simplificações significativas da rede, através da esqueletização e uso de tubulações equivalentes. Dessa maneira, as técnicas empregadas podem obter somente resultados próximos aos corretos e menos precisos. De forma contrária, tanto propostas de simulação quanto de otimização têm a vantagem de usar um modelo completo, e assim produzem resultados mais precisos.

### **3.2 Modelagem via Redes Neurais Artificiais – RNAs**

Nos últimos anos, progressos significativos em matéria de reconhecimento de padrões não-lineares ocorreram através da teoria de controle de sistemas. Tornaram-se possíveis assim avanços no ramo da modelagem não-linear das chamadas redes neurais artificiais (RNAs).

As RNA compreendem técnicas computacionais cujo funcionamento baseia-se na estrutura neural dos seres vivos e que realizam tarefas de computação adquirindo conhecimento através da experiência, construída por um processo de aprendizagem. Algumas de suas vantagens importantes são as características de adaptabilidade, generalização e tolerância a falhas.

Assim uma RNA é capaz de aprender a partir de exemplos e de generalizar a informação aprendida. A generalização que está associada à capacidade de aprendizagem com base em um conjunto de informações ou exemplos, e posteriormente produzir respostas coerentes para dados desconhecidos, é uma demonstração de que a capacidade das RNAs vai muito além do que simplesmente mapear relações entre variáveis de entrada e saída.

Devido a estas características as RNAs podem ser definidas como um processador paralelamente distribuído, formado por unidades de processamento simples, que tem a capacidade natural de armazenar conhecimento experimental e posteriormente torná-lo disponível para o uso. Uma RNA é similar ao cérebro dos seres vivos em dois aspectos: o conhecimento é adquirido pela rede através de processos de aprendizagem; as forças de conexão entre os neurônios, conhecidos como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.

As RNAs são capazes de extrair informações não apresentadas de forma explícita por meio dos dados ou exemplos a elas apresentados. Não obstante as RNAs são capazes de atuar como aproximadoras universais de funções multivariáveis com custo computacional que cresce apenas em formato linear com o número de variáveis.

Haykin (2001) define uma RNA como uma tecnologia que tem raízes nas mais diversas disciplinas: neurociência, matemática, estatística, física, ciência da computação e engenharia.

Descreve ainda que as RNAs encontram aplicações em campos tão diversos, como modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controles, em virtude de uma grande e importante propriedade: a habilidade de aprender a partir de dados de entrada e saída (Rao & Alvarruiz, 2007).

A RNA é uma representação matemática de elementos de computação interligados (ou neurônios) organizados em camadas, que processam a informação por sua resposta a estímulos externos, de forma análoga ao sistema nervoso central.

### 3.2.1 Neurônio biológico


Para compreender como funciona um neurônio artificial é preciso primeiramente conhecer o princípio de funcionamento do neurônio biológico, já que o neurônio artificial tem por finalidade simular o funcionamento desta estrutura neural.

O cérebro é responsável pelo processamento de uma grande quantidade de informações que o corpo envia a todo o momento. Porém, o cérebro não teria essa capacidade se não fosse formado por uma grande quantidade de células nervosas as quais são conjuntos de pequenos elementos interligados.

Braga *et al.* (2007) define o neurônio biológico de maneira simplificada em três seções: o corpo celular, os dendritos e o axônio, cada qual com estrutura e funções específicas, porém complementares conforme se segue:

- Dendritos: são responsáveis por capturar os sinais emitidos pelo corpo humano e encaminhá-los para o destino correto;
- Axônio: é responsável pela saída desses impulsos, onde o mesmo estará ligado a outro neurônio pelos terminais do axônio;
- Núcleo: é responsável pelo somatório de todas as entradas dos dendritos.

A Figura 3.1 ilustra a estrutura de um neurônio biológico.



**Figura 3.1:** Estrutura de um neurônio biológico. Fonte: Braga *et al.* (2007), adaptado.

O cérebro humano trabalha de uma forma muito complexa e não-linear. Seu funcionamento pode ser visto como um sistema que possui três importantes estágios: Receptores, Redes Neurais

Cerebrais e Atuadores. O cérebro é representado pelas Redes Neurais Cerebrais, e está no centro do sistema, pois é ele o responsável por processar os impulsos que os receptores enviaram e, depois de feito isso é o cérebro que decide o que fazer com os impulsos, gerando assim uma resposta. Os receptores recebem os impulsos do corpo, transmitem esses impulsos para o cérebro (redes neurais), onde são processados e enviados aos atuadores gerando assim uma resposta final.

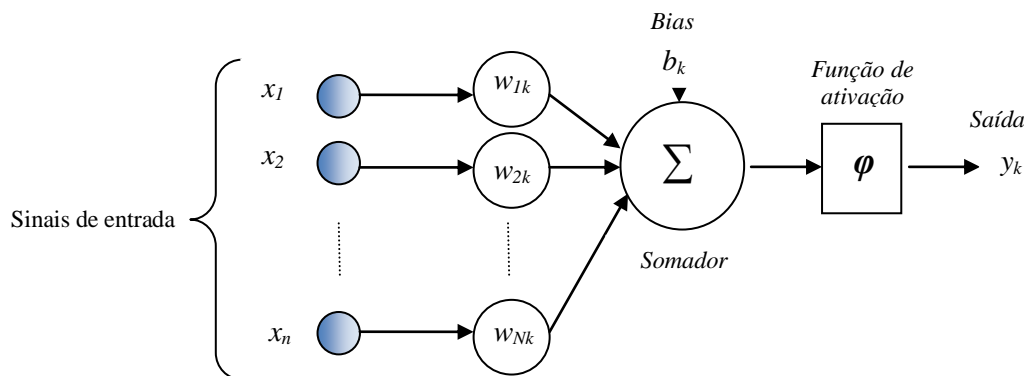
Os neurônios são células nervosas que transmitem impulsos nervosos através de sinapses, que conduzem os impulsos do corpo para as células nervosas. As sinapses são regiões eletroquimicamente ativas, localizadas entre duas membranas celulares: a membrana pré-sináptica, onde chegam os estímulos de outras células e a membrana pós-sináptica, que é a membrana dos dendritos.

Os impulsos nervosos são reações físico-químicas que se verificam nas superfícies dos neurônios e seus processos. Os neurônios são conectados uns aos outros através de sinapses, formando um aglomerado de neurônios, sendo que a saída de um neurônio é sempre a entrada de outro. Os sinais entram nos neurônios através de sinapses nos dendritos. Uma grande característica das sinapses é o fato dos sinais se propagarem sempre na mesma direção, permitindo assim que os sinais sejam conduzidos de maneira adequada.

O sistema nervoso central possui cerca de 100 bilhões de neurônios conectados em uma rede capaz de realizar aproximadamente 60 trilhões de ligações sinápticas e processar milhões de informações por segundo. Esta rede é responsável por permitir o armazenamento e o processamento de grandes quantidades de informações.

### 3.2.2 Neurônio artificial

O modelo matemático de um neurônio artificial foi idealizado pelos pesquisadores McCulloch & Pitts (1943), utilizando como base o neurônio biológico. O neurônio artificial é composto por uma unidade de processamento matemático relativamente simples, que recebe uma ou mais entradas e as transforma em saída. A operação de uma unidade de processamento pode ser resumida conforme Figura 3.2:



**Figura 3.2:** Modelo do Neurônio Artificial – Fonte Haykin (1994), adaptado.

Com base na Figura 3.2, é possível distinguir alguns elementos considerados importantes na estrutura de um neurônio:

1. Um combinador linear soma os sinais das entradas ponderados pelos seus respectivos pesos;
2. As sinapses que são caracterizadas por um peso  $w$ . O papel do peso  $w_{jk}$  é multiplicar o sinal  $x_j$  na entrada da sinapse  $j$ , conectada ao neurônio  $k$ . O peso  $w_{jk}$  é positivo se a sinapse associada é excitatória e negativo se a sinapse associada é inibitória;
3. Uma função de ativação que restringe o sinal de saída do neurônio a um intervalo fechado geralmente  $[0,1]$  ou  $[-1,1]$ ;

Em notação matemática podemos expressar um neurônio  $k$  com as seguintes equações:

$$u_k = \sum_{j=1}^N w_{jk} x_j \quad (3.1)$$

$$v_k = b_k + u_k \quad (3.2)$$



$$y_k = \varphi(v_k) \quad (3.3)$$

Sendo  $x_1, x_2, \dots, x_N$  os sinais de entrada,  $w_{1k}, w_{2k}, \dots, w_{Nk}$  os pesos sinápticos,  $u_k$  a saída do combinador linear devido aos sinais de entrada,  $b_k$  o bias que tem a finalidade de aumentar ou diminuir a entrada da função de ativação,  $v_k$  o potencial de ativação do neurônio  $k$ ,  $\varphi$  a função de ativação e  $y_k$  o sinal de saída do neurônio.

### 3.3 Funções de ativação

A função de ativação  $\varphi(\cdot)$ , define a saída do neurônio em termos de nível de atividade do mesmo. Dentre as principais funções de ativação as mais comuns são:

1. Função linear – não é limitada. Neurônios com essa função podem ser utilizados como aproximadores lineares (Equação 3.4);
2. Função logística sigmoidal – assume um intervalo contínuo de valores entre 0 e +1. É a função geralmente adotada em redes neurais, em virtude de ser contínua, estritamente crescente, não linear e facilmente diferenciável em qualquer ponto (Equação 3.5);
3. Função tangente hiperbólica – possui as mesmas características da função logística sigmoidal, entretanto, seu intervalo varia de -1 a +1, permitindo assim que as saídas sejam simétricas (Equação 3.6);

A Figura 3.3 apresenta as expressões matemáticas das funções de ativação anteriormente listadas e seus respectivos gráficos, demonstrando seu comportamento

- Função linear (Hard Limiter):  $\varphi(v) = v$ ; (3.4)

- Função logística sigmoidal (Threshold Logic):  $\varphi(v) = \frac{1}{1 + \exp(-av)}$ ; (3.5)

- Função tangente hiperbólica (Sigmoid):  $\varphi(v) = \tanh\left(\frac{v}{2}\right) = \frac{1 - \exp(-v)}{1 + \exp(-v)}$  (3.6)




Figura 3.3: Funções de ativação.

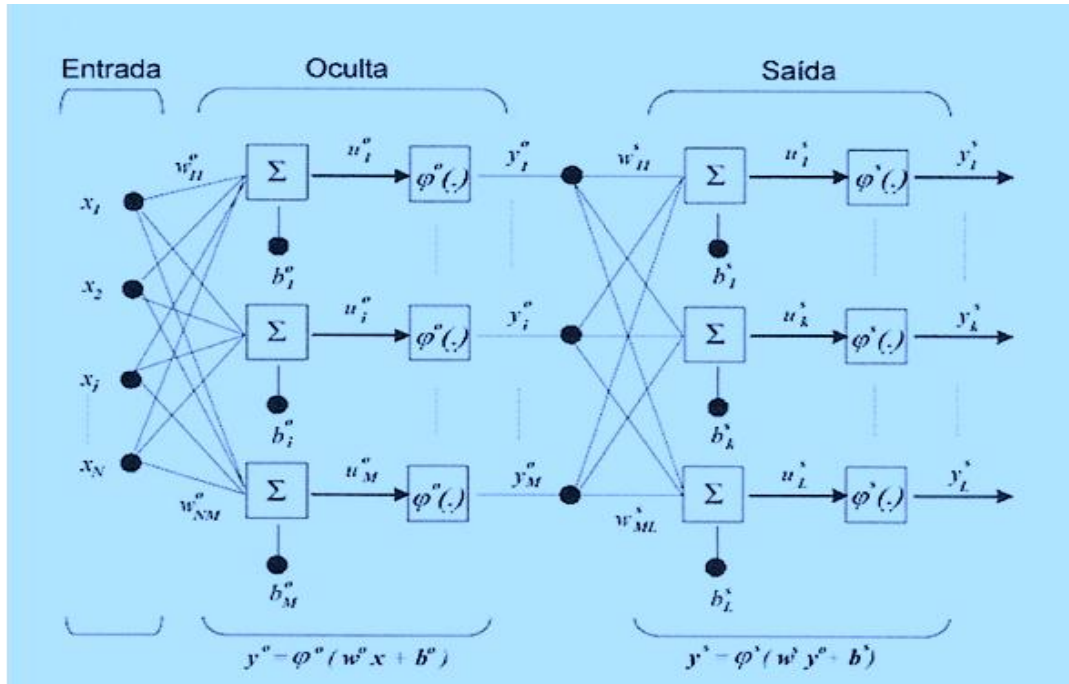
A maioria dos modelos de redes neurais possui alguma regra de treinamento, segundo a qual os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos.

### 3.4 Rede *perceptron* multicamadas

A rede *perceptron* multicamadas, ou MLP (*multilayer perceptron*), consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Figura 3.4). Excluindo-se a camada de entrada, todas as demais camadas são constituídas por neurônios. O sinal de entrada propaga-se a frente através da rede camada por camada, ou seja, é uma rede do tipo *feedforward*. A saída de um *perceptron* multicamadas pode ser expressa conforme a Equação 3.7:

$$y_k^s = \varphi_k^s \left[ b_k^s + \sum_{i=1}^M w_{ik}^s \varphi_i^o \left( b_i^o + \sum_{j=1}^N w_{ji}^o x_j \right) \right] \quad (3.7)$$

no qual  $o$  denota o elemento da camada oculta e  $s$  indica o elemento da camada de saída;  $w_{ji}^o$  é o peso que conecta o neurônio  $j$  da camada de entrada com o neurônio  $i$  da camada oculta;  $w_{ik}^s$  é o peso que conecta o neurônio  $i$  da camada oculta com o neurônio  $k$  da camada de saída;  $\varphi_i^o$  é a função de transferência do neurônio  $i$  da camada oculta;  $b_k^s$  é o bias do neurônio  $k$  da camada de saída;  $y_k^s$  é a saída do neurônio  $k$  da camada de saída e  $x_j$  é a entrada do neurônio  $j$  a camada de entrada.



**Figura 3.4:** Modelo baseado em um *perceptron* multicamadas. Fonte: Aguirre-Basurko *et al.* (2006), adaptado.

Os neurônios artificiais usualmente devem estar organizados em camadas classificadas em três tipos distintos:

- Camada de Entrada (*inputs*): responsável pela simples apresentação e passagem dos valores de entrada para os neurônios das camadas seguintes;
- Camadas Intermediárias ou Ocultas (*hidden layer*): contém neurônios responsáveis pelo processamento não-linear da informação de entrada, através das conexões ponderadas, de modo a facilitar a resolução do problema para os neurônios da camada de saída. Conferem à rede capacidade de extrair conhecimento complexo;
- Camada de Saída (*output*): contém neurônios responsáveis pela geração da saída da rede neural, após as entradas terem sido devidamente processadas pelos neurônios oculto. Fornece os resultados do processamento das informações.




Figura 3.5: RNA de três camadas.

Segundo Cybenko (1989) uma rede com uma camada intermediária pode implementar qualquer função contínua e a utilização de duas camadas intermediárias permite a aproximação de qualquer função matemática. Deve ser observado porém, que em alguns casos, a utilização de duas ou mais camadas intermediárias pode facilitar o treino da rede. A utilização de um grande número de camadas intermediárias não é recomendada, pois cada vez que o erro medido durante o treinamento é retro propagado, ou seja, é propagado para a camada anterior, ele se torna menos útil e impreciso. A única camada que tem uma noção precisa do erro cometido pela rede é a de saída.

Dentre as camadas intermediárias, a última recebe apenas uma estimativa do erro. A penúltima uma estimativa da estimativa, e assim sucessivamente.

Com relação ao número de neurônios das camadas intermediárias, esse é em geral definido forma empírica dependente da distribuição dos padrões de treinamento, validação cruzada e teste da rede.

Devem-se levar em conta dois fatores: primeiro não utilizar unidades demais que possam levar a rede a memorizar os padrões de treinamento em vez de extrair as características gerais que permitirão a generalização e o reconhecimento dos padrões não observados durante o processo de treinamento, problema chamado de *overfitting*; segundo, não utilizar um número muito pequeno, que pode conduzir a rede a gastar tempo computacional em excesso tentando encontrar uma representação ótima, ou seja, a rede não converge durante seu treinamento, problema que é chamado de *underfitting*.

### 3.5 Aprendizado das RNAs – algoritmo de *backpropagation*

A propriedade mais importante das redes neurais é a habilidade de aprender e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos. Através desses ajustes a RNA aprende o correto comportamento da entrada e a resposta de saída.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado:

- Aprendizado supervisionado, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;
- Aprendizado não supervisionado (auto-organização), quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;
- Reforço, quando um crítico externo avalia a resposta fornecida pela rede.

Denomina-se ciclo uma apresentação de todos os  $N$  pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executada de duas maneiras:

- Modo padrão: A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem  $N$  correções.
- Modo batch: Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro fazem-se as correções dos pesos.

Este processo de treinamento é geralmente realizado utilizando-se um algoritmo especial, em que uma função custo, determinada como sendo o somatório dos quadrados dos erros obtidos entre a saída real e a saída produzida pela rede sejam mínimos. Quando a função custo se aproxima de um mínimo, considera-se a rede como convergente. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

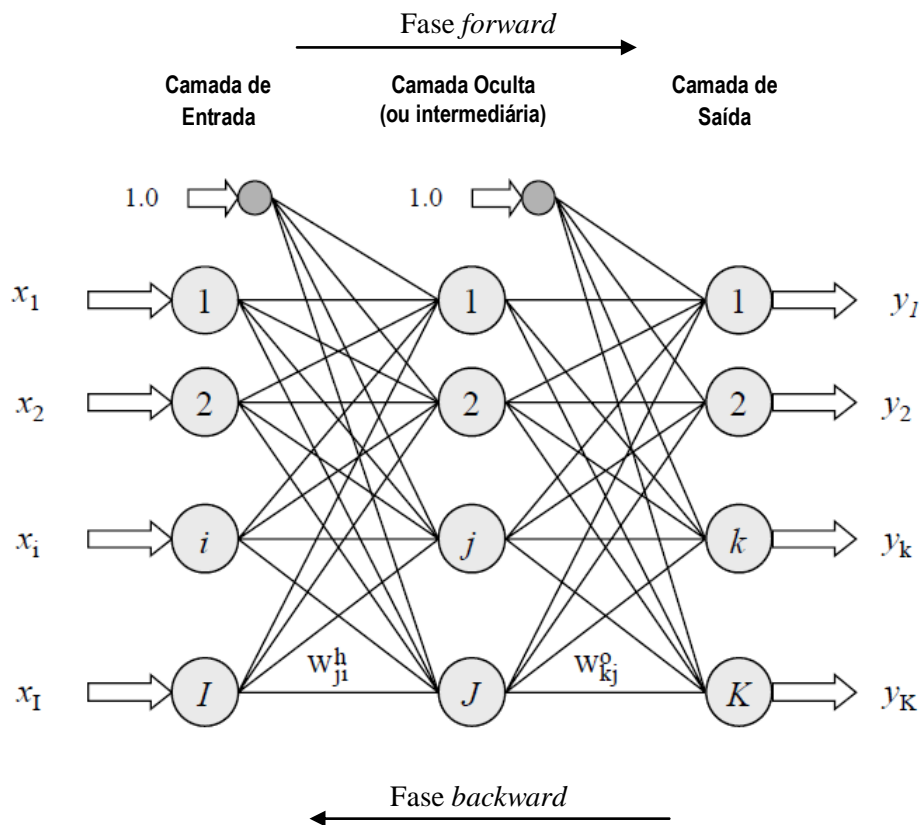
Denomina-se algoritmo de aprendizado o conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para

determinados modelos de redes neurais, sendo que estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

O algoritmo de *backpropagation* ou retro propagação do erro apresentado por Rumelhart & McClelland (1986), é considerado o mais popular no que tange ao aprendizado de redes MLPs (*Multi Layers Perceptrons*). Tal popularidade resulta, sobretudo, de sua relativa simplicidade de implementação e eficiência.

O algoritmo de *backpropagation* utiliza pares de entrada/saída desejada para ajustar os pesos da rede através da regra da correção do erro. O treinamento ocorre em duas fases nas quais cada fase percorre a rede em um sentido. A essas duas fases são chamadas *forward* e *backward*.

A fase *forward* é utilizada para definir a saída da rede para um determinado padrão de entrada. Já a fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. A Figura 3.5 ilustra estas duas fases:



**Figura 3.6:** Fluxo de processamento do algoritmo de *backpropagation*. Fonte: Rao & Alvarruiz (2007), adaptado.

A fase *forward* envolve os seguintes passos:

1. A entrada é apresentada à primeira camada da rede, a camada  $C^0$ ;
2. Calcula-se a saída de cada neurônio da próxima camada  $C^i (i > 0)$  a partir da saída da camada anterior  $C^{i-1}$ . Estas saídas servirão como entrada para a camada  $C^{i+1}$ ;
3. O passo 2 repete-se até a última camada;
4. As saídas produzidas pelos neurônios da última camada são comparadas com as saídas desejadas;

A fase *backward* envolve as seguintes etapas:

1. Os erros de cada neurônio da camada de saída são calculados;
2. Os pesos de cada neurônio da camada de saída são ajustados de forma a reduzir seus erros;
3. Seqüencialmente o erro de cada neurônio das camadas intermediárias  $C^i$  é calculado, utilizando os erros dos neurônios da camada seguinte  $C^{i+1}$  conectados a ele, e ponderados pelas conexões entre eles;
4. O passo 4 repete-se até a primeira camada.

O algoritmo de *backpropagation*, que faz o uso dessas duas fases é apresentado a seguir:

1. Inicializar os parâmetros;
2. Para cada padrão de treinamento:
  - a) Calculam-se as saídas da rede através da fase *forward*;
  - b) Comparam-se as saídas produzidas com as saídas desejadas;
  - c) Atualizam-se os pesos dos neurônios através da fase *backward*;
3. Após a rede ser apresentada a todos os padrões, uma nova iteração é iniciada voltando-se ao item 2;
4. As iterações continuam até que o erro seja mínimo ou que um número máximo de iterações seja alcançado.

O sinal de erro na saída do neurônio  $k$ , na iteração  $n$ , é definido por:

$$e_k(n) = d_k(n) - y_k(n) \quad (3.8)$$

na qual  $d_k$  é a saída desejada para o neurônio  $k$  e  $y_k$  é dado pela Equação (3.3).

Embora o erro total  $E$  seja definido como a soma dos erros dos neurônios da camada de saída para todos os padrões contidos no conjunto de treinamento, será considerada, sem perda de generalidade, que a minimização do erro para cada padrão individualmente levará a minimização do erro total. Assim o erro passa a ser definido por:

$$E(n) = \frac{1}{2} \sum_{k=1}^L e_k^2(n) \quad (3.9)$$

O algoritmo de *backpropagation* aplica uma correção  $\Delta w_{jk}(n)$ , que é definida pela regra delta (Widrow e Hoff Jr., 1960) por:

$$\Delta w_{jk}(n) = -\eta \frac{\partial E(n)}{\partial w_{jk}(n)} \quad (3.10)$$

ou

$$w_{jk}(n+1) = w_{jk}(n) - \eta \frac{\partial E(n)}{\partial w_{jk}(n)} \quad (3.11)$$

sendo  $\eta$  denominado taxa de aprendizagem. O uso do sinal negativo na Equação (3.10) indica a descida do gradiente no espaço de pesos, ou seja, busca de uma direção para a mudança de pesos que reduza o valor de  $E(n)$ . Quanto menor for  $\eta$ , mais suaves serão as variações dos pesos sinápticos da rede, de uma iteração a outra. Por outro lado, se  $\eta$  for grande, para acelerar a taxa de aprendizagem, as grandes modificações nos pesos sinápticos podem tornar a rede instável.

Para uma melhor compreensão do processo de aprendizagem, pode-se supor, por exemplo, que cada combinação de pesos e *bias* corresponda a um ponto na superfície de solução. Considerando-se que a altura de um ponto é diretamente proporcional ao erro associado a esse ponto, a solução está obviamente, nos pontos mais baixos da superfície. Em resumo o algoritmo de *backpropagation* procura minimizar o erro obtido pela rede ajustando pesos e *bias* para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro.



### 3.6 Verificação das RNAs

Desenvolver uma RNA compreende duas etapas principais: o treinamento ou aprendizagem e teste ou verificação. Durante o processo de formação, associações de dados conhecidos de entrada e saída são ajustados até a entrada especificada que prevê a saída desejada.

Após o treinamento, a RNA é submetida à verificação, fase em que outras combinações conhecidas de dados de entrada e saída são introduzidas, a fim de estimar-se o erro residual. Com base no desempenho da RNA treinada, ajustes podem ou não ser apropriados para tornar o modelo mais preciso.

Existem vários tipos de RNAs que diferem em arquitetura ou forma de treinamento. Para o presente trabalho, utiliza-se um Perceptron de Múltiplas Camadas (MLP), com treinamento supervisionado realizado pelo algoritmo de retropropagação do erro.

O algoritmo de retropropagação do erro consiste na propagação da entrada pelas camadas sucessivas da MLP, até gerar uma saída que é comparada com o valor real disponível gerando um erro que é retropropagado camada por camada, sendo seguida pela modificação dos respectivos pesos.

### 3.7 Aplicações das RNAs

As RNAs vem sendo aplicadas na resolução de problemas das mais diversas áreas do conhecimento.

Alguns exemplos de aplicação das RNAs na área de recursos hídricos incluem a concepção de sistemas de abastecimento através de águas subterrâneas (Rogers & Dowla, 1994; Rao & Jamieson, 1997) e de planejamento regional do tratamento de águas residuárias (Wang & Jamieson, 2002), em que a replicação de complexos modelos de simulação por uma RNA reduziu significativamente a carga computacional do processo de otimização.

Modelos empíricos e simplificados são muito sensíveis às mudanças físicas e variações espaciais da demanda, e geralmente requerem uma quantidade considerável de dados para sua formulação. Já os modelos de simulação hidráulica, cuja principal característica é a robustez, precisam de muito mais esforço computacional para ser adequadamente calibrados.

Uma vez que esses modelos precisam de um esforço computacional extra, geralmente são restritos a aplicações que exigem um número mínimo de avaliações individuais. Assim, a sua

utilização em tempo real é pouco prática para grandes SDAA, devido a carga computacional imposta pela otimização.

Reconhecendo que a eficiência computacional é especialmente importante para o controle operacional em tempo real, devido ao curto tempo de incremento entre as sucessivas atualizações necessárias ao processo, Rao & Alvarruiz (2007) propuseram o uso de RNAs treinadas para capturar o comportamento de SDAA a partir dos resultados obtidos em um modelo de simulação hidráulica.

A prerrogativa real dessa abordagem é o alto grau de realismo do modelo de simulação hidráulica convencional antes do treinamento da RNA.

Portanto, poderá naturalmente ser apreciado um pressuposto implícito em primeira instância, onde a rede real pode ser precisamente modelada utilizando um modelo de simulação hidráulica convencional.

Rogers & Dowla (1994) e Wang & Jamieson (2002) observaram que a resposta de modelos de simulação assistidos por uma RNA reduziu significativamente a carga computacional do processo de otimização, em simulações realizadas em sistemas de captação de água subterrânea e sistemas de tratamento de águas residuárias.

## 4. Material e Métodos

### 4.1 Modelagem matemática

A modelagem matemática busca estudar, desenvolver e programar modelos que representem ou interpretem de maneira simplificada a realidade, em conformidade com conceitos concebidos em levantamentos, interpretações de dados e observações do sistema real. Tem por objetivo uma melhor compreensão do comportamento presente, possibilitando a previsão de situações futuras, geralmente com vistas à tomada de decisão.

Assim, de uma maneira geral, a modelagem dos SDAAs tem por objetivo reproduzir os fenômenos hidráulicos que ocorrem no interior desses sistemas de tubulações e demais componentes (reservatórios, bombas, válvulas, etc.) de maneira a reproduzir suas respostas às solicitações de consumo dos usuários, em termos de pressões e vazões.

Dentre as técnicas de modelagem destacam-se duas possibilidades: a mecanística e a empírica.

Os modelos mecanísticos tentam representar as relações de causa-efeito entre as variáveis envolvidas, com base no conhecimento dos processos em nível dos diversos componentes do sistema. No caso dos SDAAs, as leis físicas da continuidade e da conservação de energia são utilizadas, juntamente com equações hidráulicas que expressam a perda de carga (fórmula universal, Hazen-Williams, etc.) são utilizadas para descrever o comportamento do sistema.

Já os modelos empíricos, tentam descrever as relações entre as variáveis envolvidas com base em observações em nível do sistema como um todo.

Dentre as vantagens dos modelos mecanísticos podem-se citar aquelas relacionadas à representação detalhada do sistema. No entanto isso implica diretamente no aumento da necessidade de recursos computacionais para manipulação de grandes volumes de dados, quando estes são usados em modelos de previsão que simulam a evolução de fenômenos físicos.

Para a reprodução de respostas ao controle operacional dos SDAAs em tempo real, o modelo selecionado para prever os efeitos de diferentes configurações e estratégias de controle, precisa ser computacionalmente eficiente, altamente preciso e numericamente robusto (Rao & Alvarruiz, 2007).

Com base nestes critérios, os modelos de simulação hidráulica mecanísticos poderão ter a necessária precisão e robustez, mas lhes faltará eficiência computacional para SDAAs de grande porte. Da mesma forma, os modelos empíricos são computacionalmente eficientes, mas podem não apresentar a precisão e a robustez necessárias à reprodução do comportamento do sistema objeto de simulação, inviabilizando sua aplicação a redes reais

As RNAs são ferramentas computacionalmente eficientes, mas necessitam de um grande número de dados de entrada e saída durante o procedimento de treino e teste.

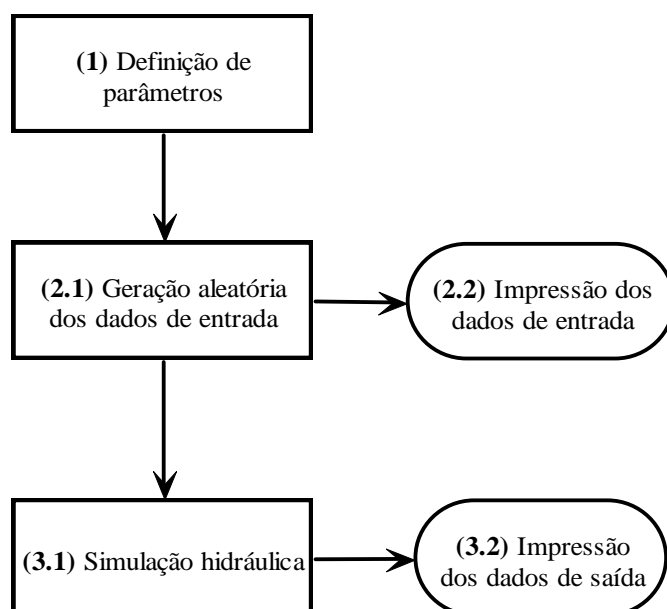
Assim, a metodologia adotada no presente trabalho consiste em combinar os dois métodos (mecanístico e empírico), usando uma RNA para capturar o conhecimento do modelo de simulação hidráulica, para posterior construção de um modelo (empírico) que reproduza o comportamento hidráulico de um SDAA a partir de um conjunto de dados pré-processados.

Desta forma, a base de conhecimento gerada através do modelo de simulação hidráulica é organizada e armazenada para posterior uso na reprodução do comportamento do sistema em substituição ao modelo de simulação hidráulica convencional, como parte do processo de controle operacional ótimo.

## 4.2 Geração de padrões

A geração de padrões aleatórios foi realizada utilizando-se um compilador C++ acoplado ao Toolkit do EPANET 2.0, que permite personalizar o uso das funções de simulação hidráulica, cujas funcionalidades foram incorporadas a um código computacional em linguagem C++.

O funcionamento do código pode ser representado pelo fluxograma da Figura 4.1, o qual será detalhado na sequência:



**Figura 4.1** – Fluxograma do código computacional utilizado para geração aleatória de padrões para a RNA

Inicialmente, são definidos os parâmetros (1), tais como o número de padrões a serem gerados, o número de bombas, de tanques e de setores de demanda presentes no sistema de distribuição.

Com base nos parâmetros definidos anteriormente são gerados aleatoriamente os dados de entrada (2.1), de maneira a atribuir valores dentro de intervalos pré-estabelecidos, com limites mínimos e máximos definidos com base no comportamento do SDAA em estudo que são: número de bombas em funcionamento e/ou desligadas em cada conjunto elevatório, os níveis iniciais dos tanques de armazenamento e as demandas de cada setor consumidor.

Após a geração dos dados, efetua-se a impressão destes valores em um arquivo de texto (2.2) que constituirá o banco de informações denominado entradas da RNA.

Os dados de entrada são então utilizados para simular o sistema de distribuição, por meio das funções do Toolkit (3.1), os quais irão fornecer os dados de saída (variáveis de estado), tais como o consumo energético das bombas, nível dos reservatórios ao final da simulação, pressões e vazões (1 hora à frente), os quais serão impressos em outro arquivo de texto (3.2), denominado saídas da RNA.


Assim estes dois arquivos contendo as informações de entradas e saídas da RNA e que servirão de elementos para efetuar o treinamento da RNA são posteriormente transferidos para uma planilha do programa MS Excel, discretizados em duas abas distintas dentro do mesmo arquivo cujos nomes são entradas e saídas.

Após esta etapa, no mesmo arquivo MS Excel é criada uma terceira pasta, que contém os elementos que podem ser manipulados para proceder às modificações e ajustes na arquitetura da RNA.

O software utilizado na presente pesquisa para realizar as simulações pertinentes a RNAs é o Scilab operando em conjunto com a ferramenta ANN Toolbox, que serão detalhados mais adiante. Cabe salientar que este software dispõe de ambiente computacional para visualização e computação numérica de alto desempenho e que possibilita a leitura dos dados diretamente de uma planilha de dados em formato MS Excel.

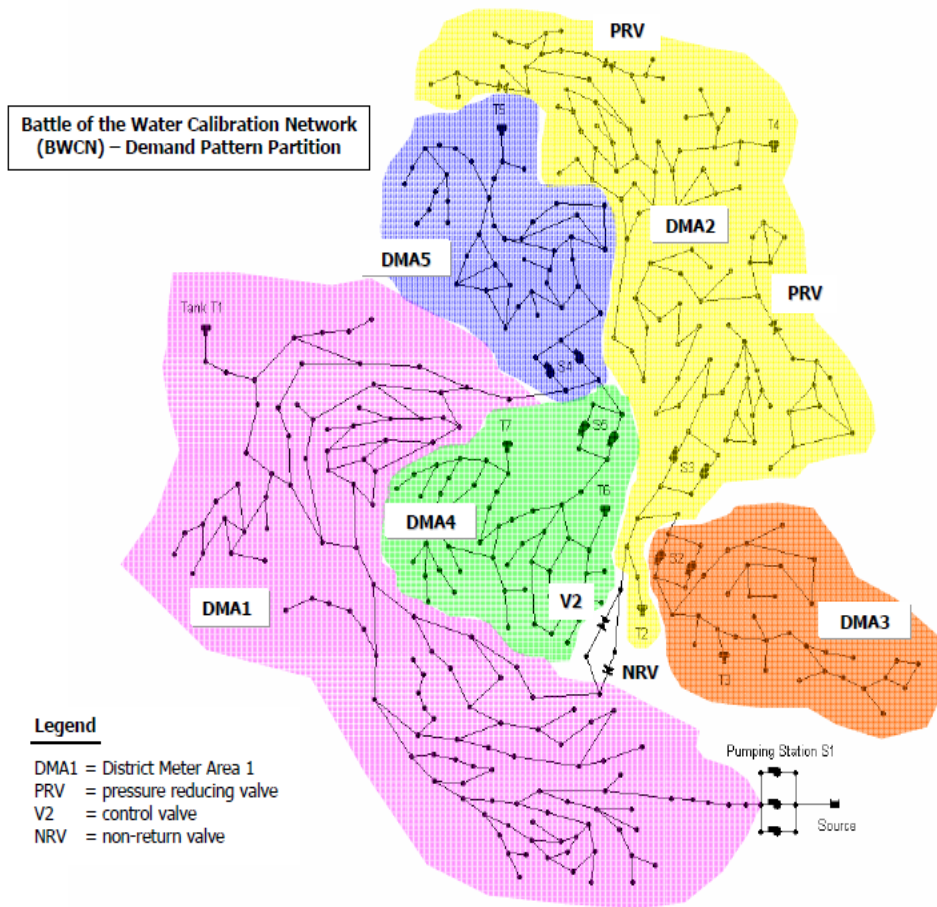
### 4.3 Os SDAA utilizados para a construção das RNAs

No presente trabalho optou-se pelo uso de dois SDAA distintos. O primeiro, denominado Rede Anytown modificada (Figura 4.2), trata de um SDAA hipotético de pequenas proporções, composto de três conjuntos de bombeamento, um reservatório de nível fixo, três reservatórios de nível variável, dezenove nós e quarenta e um trechos de rede, cuja finalidade foi testar a metodologia e verificar a técnica descrita por Rao & Alvarruiz (2007). Serviu ao propósito específico de comparação com resultados produzidos anteriormente pelos referidos autores, como teste da metodologia implementada.



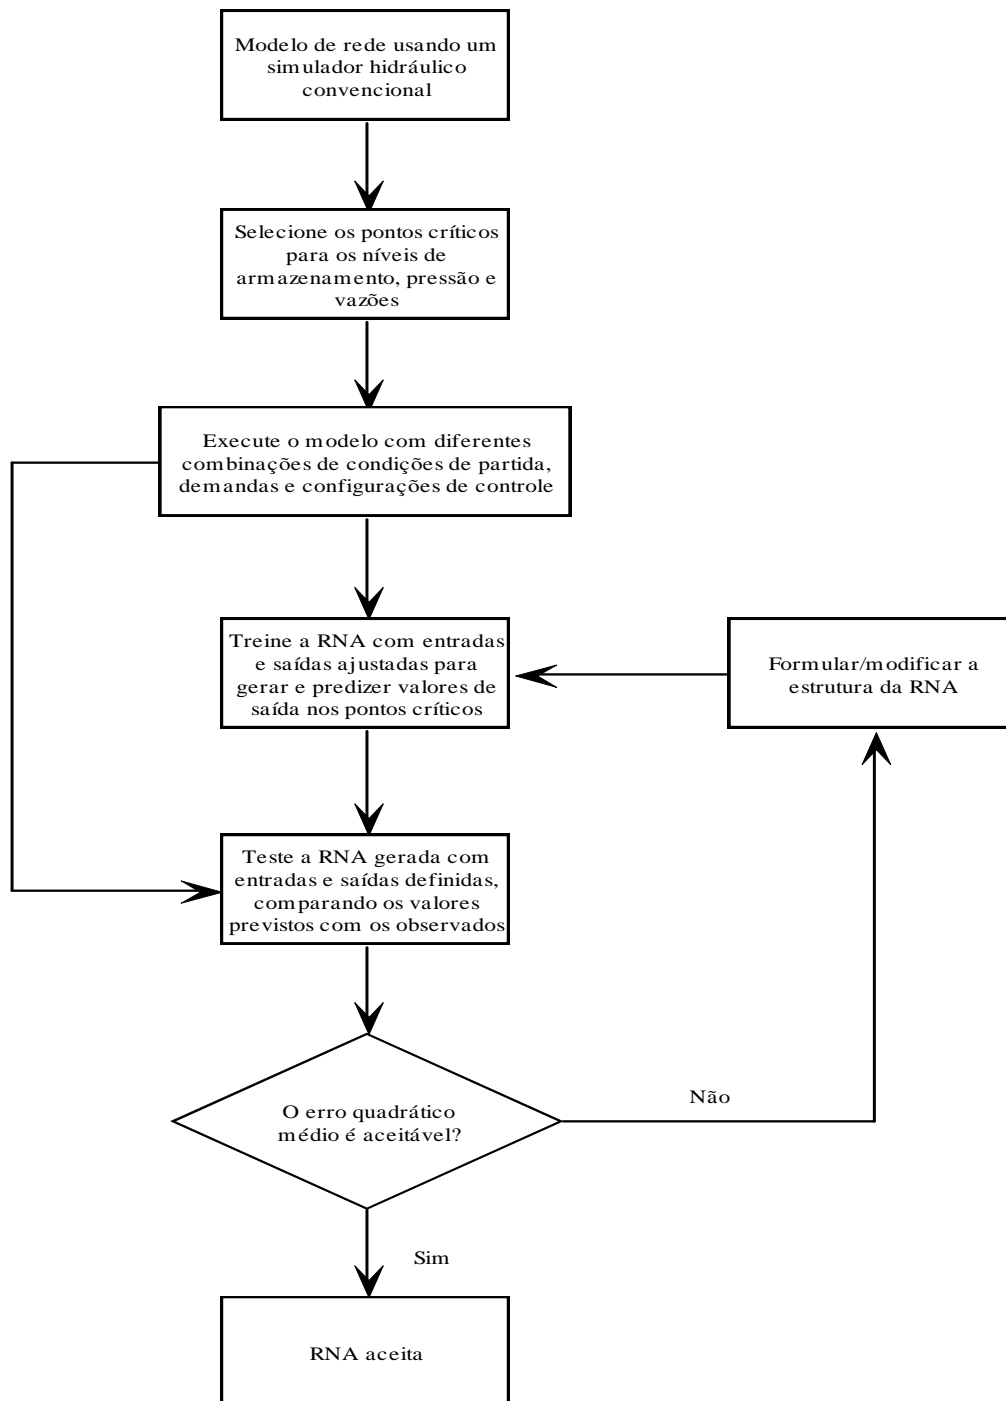
**Figura 4.2:** Modelo de rede – Anytown modificado. Fonte: Rao & Alvarruiz (2007).

Já o segundo SDAA trata de um sistema real utilizado na conferência de calibração WDSA – *Water Distribution System Analysis*, realizada na cidade de Tucson, Arizona (EUA) entre os dias 12 e 15 de setembro de 2010 (Figura 4.3). É composto por onze conjuntos de bombeamento, um reservatório de nível fixo, três reservatórios de nível variável, trezentos e oitenta e oito nós, quatrocentos e vinte e nove trechos de rede (tubos) e quatro válvulas. A escolha de tal sistema se deveu principalmente ao fato de tratar-se de uma rede real, previamente calibrada, com dimensões e características compatíveis com sistemas existentes.



**Figura 4.3:** Modelo de rede – Conferência de calibração de redes WDSA (2010).

De acordo com Rao & Alvarruiz (2007) a representação esquemática do processo completo para capturar a base de conhecimento de um modelo de simulação hidráulica, através de uma RNA pode ser descrito em conformidade com o esquema da Figura 4.4.



**Figura 4.4:** Processo de captura da base de conhecimento de um modelo de simulação hidráulica através de uma RNA. Adaptado de Rao & Alvarruiz (2007) .



#### 4.4 Construção do modelo de simulação hidráulica

O modelo de simulação hidráulica deve ser construído a partir da coleta, geração e compilação das informações relativas à infra-estrutura hidráulica do sistema a modelar, observado-se os seguintes critérios:

- A topologia, geometria, altimetria e características do comportamento da infra-estrutura física (condutos, válvulas, reservatórios, bombas dentre outros elementos);
- As solicitações do sistema, sob a forma de consumos, tanto na sua distribuição espacial como na escala e variação temporal;
- O funcionamento operacional do sistema para os vários cenários a simular.

Observa-se que a análise dos dados de consumo irá permitir: (verificar etapas executivas no caso do trabalho, etapas não necessárias – redes prontas)

- Identificação de consumidores especiais;
- Determinação do consumo da área; e
- Atribuição dos consumos aos nós do sistema;

Cabe salientar que na presente pesquisa, em função dos dois SDAA em estudo possuírem todos os dados imprescindíveis à simulação previamente formatada (pronta), obviamente não se fez necessária a etapa de análise da distribuição espacial dos dados de consumo e calibração do sistema para determinação das pressões e vazões reais em função das rugosidades das tubulações.

O modelo de simulação hidráulica deve obedecer às equações da continuidade, da conservação de energia e a relação entre perda de carga e vazão que caracterizam as condições de equilíbrio hidráulico da rede em um determinado instante. Seja uma rede composta por  $N$  nós e  $NF$  nós cuja carga hidráulica é fixa (reservatórios), a relação entre a perda de carga e a vazão em uma tubulação situada entre os nós  $i$  e  $j$  pode ser representada através da seguinte expressão:

$$H_i - H_j = h_{ij} = r \cdot Q_{ij}^n + m \cdot Q_{ij}^2 \quad (4.1)$$

em que  $H_i$  é a carga hidráulica no nó  $i$ ,  $h_{ij}$  é a perda de carga total no trecho  $ij$ ,  $r$  é o termo de perda de carga, dependente da formulação utilizada,  $Q_{ij}$  é a vazão aduzida pela tubulação que liga os nós  $i$  e  $j$ ,  $n$  é o expoente da formulação dado pela relação entre perda de carga e vazão e  $m$  é o coeficiente de perda de carga localizada.

A conservação de massa nos nós é dada pela expressão:

$$\sum_{j \in J_i} Q_{ij} - C_i = 0 \quad \text{para } i = 1, \dots, N \quad (4.2)$$

sendo  $C$  o consumo no nó  $i$  e  $J_i$ , todos os nós conectados ao nó  $i$ .

Esse sistema de equações pode ser resolvido através de um método híbrido nó-malha, que Todini & Pilati *apud* Rossman (2000) denominaram “Método Gradiente”, que é utilizado pelo simulador hidráulico EPANET, para a obtenção dos valores de pressão e vazão na rede.

Desta forma, conhecendo-se a carga hidráulica nos nós de carga hidráulica fixa (NF), obtêm-se os valores relativos às pressões e vazões na rede de forma a satisfazer as equações 4.1 e 4.2.

Alguns sistemas de abastecimento, notadamente aqueles que não dispõem de reservatórios domiciliares, necessitam que sejam consideradas as demandas variáveis com a pressão na equação de balanço hídrico (Fujiwara & Li, 1998; Tucciarelli, Criminisi & Termini, 1999; e Tabesh & Karimzadeh, 2000). Outros autores consideram também os vazamentos inerentes na modelagem. A literatura apresenta alguns modelos para vazamentos. Soares (2003) apresenta uma revisão abrangente sobre o tema.

Soares et al. (2003) propuseram um procedimento iterativo para adicionar os vazamentos às demandas nodais internamente a setores de rede, utilizando o EPANET 2 (Rossman, 2000). Desenvolveram um modelo de calibração, onde os dados de entrada reportavam-se a observações de pressões em alguns nós e de vazões em determinados trechos da rede, usualmente na saída dos reservatórios, dos níveis dos reservatórios e da vazão abastecida, para os diversos padrões de demanda observados.

Para determinação dos vazamentos, realizaram um balanço hídrico que admite que a vazão abastecida seja composta de vazamentos e demandas condicionadas pela pressão. Tal hipótese pressupõe que a vazão não medida (submedição, fraude, furto, etc.) seja proporcional à vazão micromedida média, com a mesma distribuição espaço temporal.

Como resposta foram obtidos alguns parâmetros da rede propriamente dita, tais como rugosidades, diâmetros, consumos e os fatores de consumo para os diversos padrões operacionais observados.

Considerando que não existem sistemas estanques, toda rede de abastecimento de água existente apresenta alguma parcela de perdas por vazamento na distribuição. A quantificação dos

vazamentos distribuídos ao longo da rede pode ser feita por meio da inclusão de modelos pressão x vazamento nas análises hidráulicas.

Entretanto, para que esses modelos possam realizar estimativas confiáveis, é necessário, primeiramente, que seus parâmetros sejam conhecidos. Além disso, é necessário que as relações entre pressões e demandas sejam consideradas. Mas neste trabalho, por desconhecer os parâmetros relativos a esses modelos, não foram consideradas as perdas por vazamento e a demanda variável com a pressão.

A calibração de um modelo de rede de distribuição de água é um procedimento preliminar a ser adotado antes de qualquer análise de SDAAs existentes com o objetivo de identificar os seus parâmetros e assim poder avaliar, por meio de simulações hidráulicas, o comportamento mais realístico das suas variáveis de estado (níveis, pressões e vazões).

A calibração visa ao ajuste dos parâmetros do sistema de tal forma que os desvios entre os dados simulados e observados em campo sejam minimizados.

#### **4.5 Seleção dos pontos críticos para os níveis de armazenamento, pressões e vazões**

Para a seleção dos pontos críticos existe a necessidade de investigar as características específicas de cada sistema.

Cada setor de abastecimento é definido pela área suprida por um reservatório de distribuição (elevado, apoiado, semi-enterrado ou enterrado), destinado a regularizar as variações de adução e de distribuição e condicionar as pressões na rede de distribuição. Nesse contexto, os setores são divididos em zonas de pressão, na qual as pressões estáticas e dinâmicas obedecem a limites prefixados. Segundo a ABNT – Associação Brasileira de Normas Técnicas, na NBR 12218/1994 a pressão estática máxima nas tubulações distribuidoras deve ser de 500 kPa (50 mH<sub>2</sub>O), e a pressão dinâmica mínima, de 100 kPa (10 mH<sub>2</sub>O). Valores fora dessa faixa podem ser aceitos desde que justificados técnica e economicamente.

Na implantação de um sistema de abastecimento, a definição das zonas de pressão é feita tomando como base a limitação da pressão estática máxima em 50 mH<sub>2</sub>O no ponto mais baixo da zona de pressão e a limitação da pressão dinâmica mínima em 10 mH<sub>2</sub>O no ponto crítico da zona de pressão.

Assim define-se o ponto crítico como sendo aquele ponto, interno à zona de pressão, em que se verificam os menores valores das pressões dinâmicas (ponto de cota topográfica mais elevada em relação ao referencial de pressão) ou o ponto mais distante do reservatório ou desfavorável da rede em relação ao ponto de abastecimento e distribuição.

Cabe salientar que, com o passar do tempo, o ponto crítico pode se deslocar devido ao aumento de rugosidade em função da idade da tubulação, tendendo a se localizar inicialmente no ponto mais alto da zona de pressão e futuramente nos pontos mais distantes em relação ao referencial de pressão (reservatório, booster ou válvula redutora de pressão).

Ele é utilizado para estimar o potencial de redução de pressão da área, além de ser um ponto de controle do abastecimento. A mínima pressão aceitável neste ponto pode variar entre as companhias de abastecimento de água, sendo consideradas satisfatórias do ponto de vista qualitativo pressões mínimas variando entre 10 e 15 mH<sub>2</sub>O.

Diante desta evidência, a questão primordial da boa utilização de modelos matemáticos é a sua calibração. A verificação para que o modelo espelhe o comportamento do sistema real, necessita da definição de quais e quantos pontos de medição de pressão e vazão são necessários e suficientes para essa análise.

A seleção dos pontos básicos que necessitam de medição são os seguintes:

- Níveis de reservatórios;
- Vazão de saída de reservatórios (ou de entrada, havendo a necessidade de transformar em vazão de saída, sabendo-se a área do reservatório e as variações de nível ocorridas);
- Vazão de boosters e VRP's;
- Pressões a montante e a jusante de boosters e VRPs; e
- Pressão(ões) no(s) ponto(s) crítico(s).

Verifica-se que quanto maiores são as perdas de carga no sistema em estudo, maior será a quantidade de pontos de medição necessários para a calibração do modelo. Somente após a certificação de calibração do modelo é que será possível utilizá-lo para simulações. Caso o modelo seja utilizado sem ter sido calibrado, as simulações decorrentes produzirão resultados irrealistas.

Desta forma no desenvolvimento do modelo Anytown modificado, não foi realizada uma análise dos pontos críticos do SDAA. Optou-se para este modelo, em desenvolver a metodologia proposta utilizando os mesmos pontos de monitoramento de níveis de reservatório, pressões e

demandas propostos por Rao & Alvarruiz (2007), cuja finalidade foi apenas efetuar comparações entre os valores produzidos pelos autores e aqueles obtidos nesta pesquisa.

Por outro lado, para o modelo WDSA, foram realizadas diversas simulações no EPANET, dentro de horizontes diários, cuja finalidade foi justamente reconhecer e destacar os pontos que apresentavam maior variabilidade de valores, em termos de pressões e vazões durante a operação do sistema.

Cabe ressaltar que para ambos os casos estudados, o número e a quantidade de padrões para efeito de treinamento das respectivas RNAs, foi obtido via rotina externa desenvolvida em linguagem C++, que produziu uma listagem de valores das grandezas hidráulicas envolvidas, inseridos nos limites admissíveis de cada sistema

#### **4.6 Execução do modelo com diferentes combinações de condições de partida, demandas e configurações de controle**

Na captura do conhecimento de domínio de um modelo de simulação hidráulica, a RNA é utilizada como uma função de mapeamento universal na medida em que relaciona um espaço multivariado de entradas com outro de saídas. Como tal, pode ser considerada como um modelo de entrada / saída no qual uma série de dados de entrada são conectados aos neurônios da camada de saída por um ou mais neurônios da camada oculta, cujas funções determinam ponderações em relação à camada oculta e a camada de saída.

Pares de vetores são utilizados para verificar o desempenho da RNA cuja finalidade é buscar o melhor ajuste. Embora o número de neurônios nas camadas de entrada e saída são fixados pela natureza do que se pretende gerar em termos de resultados, o número de neurônios na camada oculta é obtido com base em experimentos de tentativa e erro, portanto, nesse sentido, o processo é de certa forma heurístico.

Decisões relativas à quantificação dos conjuntos de treinamento e teste são necessárias e estão novamente sujeitas a opinião e experiência. No entanto, na formulação da RNA, deve-se acima de tudo, especificar a real necessidade para o qual o modelo foi concebido, desde o seu real valor em termos de tolerância, robustez e precisão até a avaliação dos resultados, válidos apenas neste contexto.

Salomons et al. (2007) demonstra em seu trabalho realizado no SDAA denominado Haifa-A no âmbito do projeto POWADIMA, a necessidade testar e avaliar várias combinações diferentes antes de adotar a arquitetura que melhor se ajusta ao modelo real.

Os pares de vetores são gerados aleatoriamente, utilizando um compilador em linguagem C++ acoplado ao EPANET 2.0, o qual permite personalizar o uso do modelo de simulação hidráulica dos SDAAs em estudo, para determinar as consequências de diferentes combinações de condições de partida, configurações de controle e demandas, cujo propósito é produzir o conjunto de padrões necessários ao treinamento da RNA.

#### 4.7. Modelagem via RNA

No desenvolvimento do presente trabalho, os padrões produzidos via simulação hidráulica serão utilizados para o treinamento da RNA, que, uma vez ajustada, será submetida à verificação.

Diferentes estruturas de RNAs foram avaliadas para identificar a arquitetura que melhor reproduzisse o comportamento dos sistemas em estudo, em termos do número de neurônios na camada oculta, principalmente para a rede da batalha de calibração WDSA, devido a sua complexidade.

Uma vez selecionados os conjuntos determinaram-se os parâmetros de interesse (a taxa de aprendizagem, a quantidade de ciclos para o treinamento, validação cruzada e para o teste da rede), bem como a quantidade de neurônios na camada oculta, para ambos os sistemas estudados.

Nesse estágio, combinações de dados de entrada e saída conhecidos, distintas daquelas usadas para efeito de treinamento, serão utilizadas para estimar o erro residual e compará-lo com valores obtidos em procedimentos de simulação realizados no ambiente EPANET.

Todo treinamento e replicação através do algoritmo de *backpropagation* foram realizados com o auxílio da plataforma do programa *Scilab*, programa criado em 1990 e mantido por pesquisadores pertencentes ao *Institut de Recherche en Informatique et en Automatique*, INRIA, através do Projeto MÉTALAU (*Méthods, algorithmes et logiciels pour l'automatique*) e à École Nationale des Ponts et Chaussées, juntamente com módulos específicos desenvolvidos para uso em RNAs. É importante ressaltar que se trata de um programa gratuito (*free software*) e distribuído com código fonte aberto (*open source software*), cujo software e bibliotecas encontram-se disponíveis na Internet (*Scilab Consortium 2010*), apresentando-se assim como alternativa ao *Matlab*.

A propriedade que é de importância primordial para uma RNA é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem (Haykin, 2001). A melhoria do desempenho ocorre com o tempo de acordo com alguma medida estabelecida previamente.

Uma RNA aprende acerca de seu ambiente por meio de um processo interativo de ajustes aplicados a seus pesos sinápticos e níveis de *bias*. Desta forma a rede se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem.

Existem inúmeras atividades associadas à noção de aprendizagem para justificar sua definição de maneira precisa. Além disso, o processo de aprendizagem depende do ponto de vista, o que causa dificuldades em se obter uma definição precisa do termo.

A definição do processo de aprendizagem implica a seguinte sequência de eventos:

- A RNA é estimulada por um ambiente;
- A RNA sofre modificações nos seus parâmetros livres, resultantes desta estimulação;
- A RNA responde de uma nova maneira ao ambiente, devido às modificações ocorridas em sua estrutura interna.

Não existe um conjunto pré-estabelecido de regras bem definidas para solucionar um problema de aprendizagem. Existe, porém uma variedade de algoritmos de aprendizagem, cada qual oferecendo vantagens específicas. Basicamente os algoritmos de aprendizagem diferem entre si pela forma de como ocorre o ajuste de um peso sináptico de um neurônio.

Portanto desenvolver uma rede neural compreende basicamente duas etapas: o treinamento ou ajuste dos pesos e *bias* (ou aprendizagem) e o teste (ou de verificação). Durante o processo de ajuste, os conjuntos de dados conhecidos de entradas e saídas (*inputs-outputs*) são repetidamente apresentados a RNA e os pesos associados a cada neurônio ajustados ciclicamente até que a entrada especificada forneça o resultado desejado. Através do ajuste, a RNA aprende o comportamento de resposta correta de entrada-saída do modelo.

Este processo de treinamento é geralmente feito usando um algoritmo especial em que uma função objetivo a ser minimizada é a soma dos erros quadrados médios entre as respostas reais do sistema e as correspondentes respostas produzidas pela rede. Quando a função objetivo aproxima-se de um mínimo, a rede é então considerada convergente.

Assim se as saídas obtidas forem estatisticamente equivalentes às suas respectivas referências, pode-se considerar que a RNA está treinada e é capaz de estimar o modelo estabelecido.

Foi utilizada neste trabalho a RNA com *perceptrons* de múltiplas camadas alimentadas adiante, uma importante classe das redes neurais. Tipicamente a rede consiste de um conjunto de unidades sensoriais que constituem a camada de entrada, uma camada oculta de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada propaga-se a frente através da rede camada por camada.

Os *perceptrons* de múltiplas camadas têm sido utilizados com sucesso para resolver diversos problemas de difícil solução. Através de seu treinamento de forma supervisionada (Haykin, 2001) combinado com o algoritmo de treinamento muito popular, cuja técnica é amplamente testada e utilizada com sucesso conhecido como algoritmo de retropropagação do erro (*backpropagation*), proposta por Rumelhart & McClelland (1986), que se baseia na regra de aprendizado por correção do erro.

A aprendizagem por retropropagação do erro consiste de dois passos através das diferentes camadas da rede: um passo a frente, a propagação e um passo para trás, a retropropagação. No passo a frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito propaga-se através da rede, camada por camada. Por fim um conjunto de saídas é produzido como a resposta real da rede.

Durante o passo de propagação, os pesos sinápticos da rede são todos fixos. Durante o passo para trás, os pesos sinápticos são todos ajustados de acordo com a regra de correção do erro. Assim, a resposta real da rede é subtraída de uma resposta desejada para produzir um sinal de erro. Este sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinápticas, motivo pelo qual se originou o nome de retropropagação do erro.


Os pesos sinápticos são então ajustados para fazer com que a resposta real da rede se movimente para um local mais próximo da resposta desejada. O processo de aprendizagem realizado com o algoritmo é chamado de aprendizagem por retropropagação.

Após o treinamento, a RNA é então submetida à fase de verificação em que outras combinações de dados são introduzidas, com a finalidade de estimar o erro residual. Com base no desempenho da RNA treinada, ajustes podem ser processados e adequados para melhorar a condição do modelo tornando-o mais preciso.



No presente trabalho, os padrões produzidos via simulação hidráulica foram utilizados como respostas do sistema real para efeito de treinamento e verificação da RNA. No estágio de verificação da RNA ajustada, combinações de dados de entrada e saída conhecidos, distintos daqueles utilizados para efeito de treinamento, serão utilizadas para estimar o erro residual e compará-lo com valores obtidos em procedimentos de simulação realizados no ambiente EPANET.

No contexto de sistemas de controle operacional, o modelo hidráulico de simulação de um SDAA água pode ser descrito para intervalos de tempo discretos por um sistema de entradas e saídas conforme esquema da Figura 4.5.



**Figura 4.5:** Modelo de entrada e saída de rede de distribuição de água (Rao & Alvarruiz, 2007) – adaptado.

sendo:

- $P_t$ : vetor das variáveis de controle representando status de funcionamento das bombas  $n_p$  no intervalo de tempo  $t = 1$  hora;
- $V_t$ : vetor das variáveis de controle representando status de funcionamento das válvulas  $n_v$  no intervalo de tempo  $\Delta_t = 1$  hora;
- $D_t$ : vetor das variáveis que representam os valores de demanda nos nós consumidores  $n_d$  da rede entre  $t$  e  $t + \Delta_t$ ;
- $S_t$ : vetor das variáveis representando o nível  $n_s$  do reservatório no intervalo de tempo  $\Delta_t = 1$  hora;
- $E_t$ : vetor de variáveis representando a potência energética  $n_p$  consumida pela bomba, entre  $t$  e  $t + \Delta_t$ ;
- $H_t$ : vetor de variáveis representando os valores de pressão  $n_h$  em nós específicos entre  $t$  e  $t + \Delta_t$ ;
- $Q_t$ : vetor que contém os valores de vazão  $n_q$  em trechos específicos da rede entre  $t$  e  $t + \Delta_t$ ;

- $S_{t+\Delta t}$ : vetor de variáveis representando o nível de armazenamento  $n_s$  de água no tempo  $t + \Delta t$ .

Obs.: Intervalo de tempo  $\Delta t = 1$  (uma) hora.

A técnica mais pesquisada para modelar as relações de entrada e saída de uma RNA multicamada é a *feedforward*.

Para fins de controle operacional ótimo, uma RNA pode ser considerada como uma função de mapeamento entre um conjunto de entradas e saídas. Neste caso particular, o conjunto de entrada contém a combinação do status de funcionamento bomba / válvula, as demandas e os níveis de reservação inicial, enquanto que o conjunto de saída corresponde ao consumo de energia elétrica das bombas, resultando níveis de água nos reservatórios, pressões e vazões em pontos críticos da rede.

Utilizando a técnica *feedforward* em uma RNA de arquitetura (I, J, K), podemos descrever:

$$I = n_p + n_v + n_d + n_s \quad (4.3)$$

$$K = n_p + n_h + n_q + n_s \quad (4.4)$$

Seja a Equação (4.3) o número total de valores das entradas  $I$ , e seja a Equação (4.4) o número total de valores das saídas  $K$ .

Seja  $n$  o número de neurônios ocultos para serem identificados durante o processo de formação e teste da rede. O valor de  $J$  é encontrado na camada intermediária usando uma estratégia de inclusão progressiva de neurônios na camada oculta, até que se alcance uma melhoria na redução do erro.

## 4.8 Arquitetura

Diferentes arquiteturas foram testadas durante o desenvolvimento da RNA, com base no método da tentativa e erro, que envolveram a escolha do número de neurônios em cada camada segundo critérios de avaliações da resposta de saída da rede.

No presente trabalho utilizou-se uma camada intermediária, tendo em vista que Cybenko (1989) e Funahashi (1989) provaram que qualquer função contínua pode ser aproximada por uma RNA do tipo *multi layer perceptron backpropagation*.

Assim utilizou-se uma RNA de múltiplas camadas e aprendizagem supervisionada por correção e erro, ou seja, contabiliza-se o erro entre a saída produzida e a desejada para realizar o ajuste dos pesos e obter saídas mais próximas às desejadas.

Para tanto se utilizou o popular algoritmo de treinamento *backpropagation* no modo de correção de erro padrão *on line*, onde a correção dos pesos acontece a cada apresentação de um conjunto de treinamento à rede.

Para evitar a ocorrência de *overfitting* foi utilizada a técnica da validação cruzada, que empregou um conjunto de validação paralelo ao conjunto de treinamento, objetivando verificar a capacidade de generalização da rede durante o treinamento. Quando o erro do conjunto de validação começa a aumentar, encerra-se o treinamento.

Pode-se identificar o início do excesso de treinamento através do uso da validação cruzada, pela qual os dados de treinamento são divididos em um subconjunto de estimação e em um subconjunto de validação. O subconjunto de exemplos de estimação é usado para treinar a rede na maneira usual, exceto por uma pequena modificação: a sessão de treinamento é interrompida periodicamente após um determinado número de ciclos de treinamento e a rede é testada com o subconjunto de validação após cada período de treinamento.

Após um período de estimação (treinamento), os pesos sinápticos e os níveis de *bias* do *perceptron* múltiplas camadas são todos fixos e a rede opera no seu modo direto para frente. O erro de validação é medido para cada exemplo do subconjunto de validação. Quando a fase de validação é completada, a estimação (treinamento) é reiniciada para um novo período e o processo é repetido.

A essência do aprendizado da rede neural através do algoritmo de retropropagação do erro consiste em realizar um mapeamento, através dos ajustes dos bias e pesos sinápticos, de pares entrada-saída de vetores. Espera-se, paralelamente, que a rede aprenda o suficiente com esta associação para ser capaz de encontrar associações válidas para os vetores de entradas desconhecidos. A rede deve, portanto, ter capacidade de generalizar o conhecimento aprendido aplicando-o em novas situações com sucesso.

O critério de parada do algoritmo de treinamento de retropropagação do erro não é bem definido, pois procura encontrar um valor mínimo global e esta deveria ser sua condição de encerramento. Na prática isto nem sempre é possível e o algoritmo pode encontrar apenas um valor mínimo local na superfície de erro.

Haykin (2001) divide o conjunto de dados disponível aleatoriamente em um conjunto de treinamento e um conjunto de teste. Sequencialmente o conjunto de treinamento é dividido adicionalmente em dois outros subconjuntos distintos:

- Subconjunto de estimação, para selecionar o modelo;
- Subconjunto de validação, para testar ou validar o modelo.

Valença (2009) subdivide os padrões apresentados em três subconjuntos distintos, os quais foram adotados neste trabalho conforme se segue:

- a) Conjunto de treinamento ou estimação: utilizado para treinar a rede neural. Composto por

- 50% dos padrões amostrados disponíveis;
- b) Conjunto de validação cruzada: utilizado para validar a rede treinada. Composto por 25% dos padrões amostrados disponíveis;
- c) Conjunto de teste: utilizado para testar a rede treinada. Composto por 25% dos padrões amostrados disponíveis.

Desta forma o conjunto de dados de treinamento foi subdividido em treinamento, validação cruzada e teste conforme exposto por Valença (2009).

A função de ativação logística foi empregada tanto na camada oculta como na de saída da RNA e os dados foram normalizados no intervalo [0,1 a 0,9] segundo a Equação (4.5), pois ao se normalizarem os dados nos limites da função de ativação, o gradiente da função logística se aproxima de zero, dificultando o treinamento da RNA (Valença, 2009).

$$x_{normalizada} = (b - a) \frac{x_{obs} - x_{min}}{x_{max} - x_{min}} + a \quad (4.5)$$

onde  $x_{normalizada}$ ,  $x_{obs}$ ,  $x_{min}$ ,  $x_{max}$ , são respectivamente os valores normalizado, observado, mínimo e máximo observados. Os coeficientes  $a$  e  $b$  representam os limites de normalização e serão adotados  $a = 0,1$  e  $b = 0,9$ .

Posteriormente os resultados gerados através da RNA, isto é os valores de saída da rede são reconvertidos ou desnormalizados para a amplitude de valores originais do modelo.

#### 4.9 Critérios de avaliação

Para avaliar os modelos utilizados em função das variáveis de entrada e taxas de aprendizagem, utilizaram-se os critérios de avaliação demonstrados na Equação 4.6 onde  $y_{obs}$  é o valor dos dados observados do período  $i$  (real) e  $y_{modelo}$  é o valor dos dados do modelo para o período  $i$ ;  $N$  é o número de períodos no conjunto de validação.

*RMSE – Root Mean Square Error*: Medida generalizada do desvio padrão entre o valor dos dados observados (reais) e o valor dos dados simulados (previstos).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{obs} - Y_{modelo})^2}{N}} \quad (4.6)$$

## 5. Resultados

Os resultados obtidos dizem respeito inicialmente ao pequeno SDAA hipotético denominado Anytown (Walsky *et. al.*, 1987) modificado por Rao & Alvarruiz (2007), com o propósito de tornar o processo de otimização mais complexo, no âmbito do Projeto POWADIMA (*Potable Water Distribution Management*), composto por três conjuntos de bombeamento, um reservatório de nível fixo, três reservatórios de nível variável, dezenove nós e quarenta e um trechos.

Posteriormente a técnica foi aplicada SDAA real e calibrado, tema da batalha de calibração realizada durante o WDSA – *Water Distribution System Analysis* 2010, realizado na cidade de Tucson, Arizona (EUA), composto por onze conjuntos de bombeamento, um reservatório de nível fixo, sete reservatórios de nível variável, trezentos e oitenta e oito nós, quatrocentos e vinte e nove trechos de rede (tubos) e quatro válvulas sendo duas redutoras de pressão, uma de controle e uma de retenção (anti-retorno).

### 5.1 Geração do conjunto de padrões para treinamento da RNA

O modelo de RNA criado tem o propósito de prever as conseqüências de diferentes estratégias operacionais (combinações de ajustes de elementos de controle tais como status das bombas, níveis de reservatório, pressões dos nós consumidores), em termos dos níveis d'água finais nos reservatórios, consumo energético das bombas, pressões nos nós e vazões a partir de condições de estado do sistema conhecidas e caracterizadas por níveis de água iniciais nos reservatórios e consumos médios para passos de tempo discretizados de hora em hora.

De acordo com Haykin (2001), o tamanho suficiente do conjunto de treinamento para uma generalização válida, é influenciado por três fatores:

- (1) – o tamanho do conjunto de treinamento, e o quão representativo do ambiente de interesse ele é;
- (2) – a arquitetura da rede neural; e
- (3) – a complexidade física do problema em questão.

Evidencia-se neste contexto o não controle sobre o último fator (3).

Quanto aos outros dois fatores pode-se considerar a questão da generalização sob duas perspectivas diferentes, a saber:

- A arquitetura da rede é fixa e a questão a ser resolvida é determinar a dimensão do conjunto de treinamento necessário para que ocorra uma boa generalização (devido à complexidade do problema);
- A dimensão do conjunto de treinamento é fixa, e a questão de interesse é determinar a melhor arquitetura para alcançar boa generalização.

Estes dois pontos de vista são válidos em seus aspectos individuais. Para o primeiro ponto de vista, existem formulações independentes para estimar a dimensão da amostra de treinamento suficiente para um bom desempenho de generalização.

Segundo Haykin (2001), constata-se com frequência que existe uma diferença numérica imensa entre o tamanho da amostra de treinamento realmente necessária e aquela prevista pelas formulações independentes mencionadas para estimar a dimensão da amostra.

É exatamente esta diferença que tem tornado o problema da complexidade da amostra uma área de pesquisa em aberto.

Por tal motivo, optou-se neste trabalho pelo segundo ponto de vista, estimando-se a dimensão do conjunto de padrões, fixando-os conforme descrito na sequência e assim variar a arquitetura cujo objetivo é alcançar uma boa generalização para os modelos em estudo.

Salomons et. al (2007) em seu trabalho desenvolvido no âmbito do projeto POWADIMA para rede HAIFA-A, obteve uma boa generalização do modelo, utilizando 12.000 padrões para treinamento e 5.000 padrões para testes, considerando uma arquitetura com 29 neurônios na camada de entrada, 80 neurônios na camada de intermediária e 15 neurônios na camada. A rede de distribuição denominada HAIFA-A, é composta por 126 tubos, 112 nós, 9 tanques de armazenamento, uma válvula de controle, 17 bombas distribuídas em 5 conjuntos de bombeamento discretos.

De maneira similar adotou-se no presente trabalho para o sistema Anytown modificado, 10.000 padrões de treinamento assim subdivididos: 5.000 padrões para treinamento, 2.500 padrões para validação cruzada e 2.500 para teste.

Já para o sistema WDSA, foram apresentados à rede 50.000 padrões de treinamento assim subdivididos: 25.000 padrões para treinamento, 12.500 padrões para validação cruzada e 12.500 padrões para teste.

- **Modelo Anytown modificado**

Para efeito comparativo, primeiramente adotou-se o conjunto de dados de entrada como sendo o número de bombas ativas, a demanda conjunta dos 19 nós consumidores do sistema e os níveis de água dos reservatórios T-65, T-165 e T-265, no instante  $t$ . O conjunto de dados de saída compreendeu o controle de pressão nos nós J-55, J-90 e J-170, os níveis de água dos reservatórios T-65, T-165 e T-265 no instante  $t + 1$ , bem como o consumo energético das bombas de número P1, P2 e P3 respectivamente.

- **SDAA utilizado na batalha de calibração WDSA 2010**

Posteriormente, para o SDAA utilizado na batalha de calibração WDSA 2010, adotou-se para o conjunto de dados de entrada os status de funcionamento (ligado / desligado) das 11 bombas e os padrões de demanda dos 5 setores de consumo do sistema para o intervalo de tempo considerado, além dos níveis de água dos 7 reservatórios (T1 a T7) no início do intervalo (instante  $t$ ). O conjunto de dados de saída compreendeu as potências consumidas pelas 5 estações de bombeamento (um para cada estação de bombeamento), níveis d'água dos 7 tanques de armazenamento (T1 a T7) no final do intervalo de tempo no instante  $t + 1$ , as pressões nos nós J-53, J-297, J-302 e J-497, bem como as vazões nos trechos P-374, P-397, P-399 e P-497.

Embora o número de neurônios nas camadas de entrada e saída sejam fixados pelo projetista da RNA, de acordo com critérios escolhidos previamente, o número de neurônios da camada escondida foi obtido via tentativa e erro, conforme proposto por Rao & Alvarruiz, (2007).

## 5.2 Rede Anytown modificada

Para rede Anytown modificada, variou-se o número de neurônios na camada oculta de 1 a 25, considerando que o uso de poucos neurônios em tal camada leva a uma capacidade de generalização maior, mas tal procedimento pode implicar em simplificação do modelo.

Cabe, porém salientar, que no trabalho de Rao & Alvarruiz (2007), são apresentados valores dos RMSE em função do número de ciclos de treinamento para um total de 30.000 iterações, porém não é feita nenhuma referência quanto ao número de padrões de treinamento, a taxa de aprendizagem utilizada e ao tempo computacional gasto no processamento das iterações de treinamento da rede.

A única informação descrita pelo autor relata que o RMSE converge para 1,65% em aproximadamente 2.000 iterações, não se alterando após atingir este patamar, com uma estrutura (arquitetura) de 5 neurônios na camada de entrada, 20 neurônios na camada intermediária e 7 neurônios na camada de saída.

Entretanto na presente pesquisa, foram obtidos melhores ajustes para a referida rede, conforme se demonstra na sequência.

Em uma base e tentativa e erro, variou-se o número de neurônios na camada intermediária de 10 a 25 visando obter a configuração que apresentasse o menor RMSE médio para as fases de treinamento e validação cruzada.

Uma boa representação foi obtida com 20 neurônios na camada intermediária, confirmando o exemplo do experimento proposto por Rao & Alvarruiz, (2007).

Tendo decidido o número adequado de neurônios na camada intermediária, a próxima questão abordada foi o número conjuntos necessários para obter adequado treinamento da RNA, cuja finalidade foi buscar uma representação mais próxima possível do modelo EPANET real, relacionado com a rede Anytown modificada.

Para o exemplo, diferentes números de conjuntos de treinamento foram utilizados para verificar o impacto sobre o RMSE entre os resultados observados nos valores de saída simulados.

Tal procedimento foi testado neste trabalho partindo-se da arquitetura [5,20,7] com taxa de aprendizagem da variando entre 0,2, e 0,8 para conjuntos compostos por 2.000, 5.000 e 10.000 ciclos treinamento respectivamente.


Observou-se que a taxa de aprendizagem de 0,4 produziu o menor RMSE médio para 2.000 ciclos de treinamento, cujo valor foi da ordem de 0,007, com tempo de processamento computacional de 451,77 minutos<sup>1</sup>, conforme Tabela 5.1 e Figuras.5.1 e 5.2.

**Tabela 5.1:** Resultados da melhor taxa de aprendizado para 2.000 ciclos de treinamento – Rede Anytown modificada


ARQ [5,20,7]		RMSE			TEMPO (min)
TAXA DE APRENDIZAGEM	2.000 ciclos	TREINO	VALIDAÇÃO	TESTE	
	0,2	0.0080	0.0081	0.0079	438,92
	0,4	0.0070	0.0070	0.0070	451,77
	0,6	0.0075	0.0076	0.0075	393,37
	0,8	0.0074	0.0074	0.0073	393,78

<sup>1</sup> Tempo computacional gasto por microcomputador Intel Core 2 Duo P 8700, 4Gb RAM e Microsoft Windows 7 32 bits.





**Figura 5.1:** Evolução do RMSE ao longo dos 2.000 ciclos de treinamento – Arquitetura [5,20,7]-taxa de aprendizagem 0,4



**Figura 5.2:** Pesquisa do número de neurônios da camada intermediária que produziu menor RMSE médio ao longo de 2.000 ciclos de treinamento – Arquitetura [5,20,7]-taxa de aprendizagem 0,4

Observou-se que a taxa de aprendizagem 0,4 também produziu o menor RMSE médio para 5.000 ciclos de treinamento, cujo valor foi da ordem de 0,0063 com tempo computacional de 799,38 minutos<sup>2</sup>, conforme Tabela 5.2 e Figura 5.3.

<sup>2</sup> Tempo computacional gasto por microcomputador Intel Core 2 Quad Q 6600, 4Gb RAM e Microsoft Windows 7 32 bits.

Tabela 5.2: Resultados da melhor taxa de aprendizagem para 5.000 ciclos de treinamento

ARQ [5,20,7]		RMSE			TEMPO (min)
TAXA DE APRENDIZAGEM	5.000 ciclos	TREINO	VALIDAÇÃO	TESTE	
	0,2	0.0070	0.0070	0.0069	983,35
	0,4	0.0064	0.0064	0.0063	799,38
	0,6	0.0069	0.0069	0.0068	799,33
	0,8	0.0071	0.0072	0.0071	798,58





Figura 5.3: Evolução do RMSE ao longo dos 5.000 ciclos de treinamento – Arquitetura [5,20,7]-taxa de aprendizagem 0,4

Finalizando as simulações, a taxa de aprendizagem 0,4 também produziu o menor RMSE médio para 10.000 ciclos de treinamento, cujo valor foi da ordem de 0,006 com tempo computacional de 1.976,22<sup>3</sup> minutos, conforme Tabela 5.3 e Figura 5.4.

Tabela 5.3: Resultados da melhor taxa de aprendizado para 10.000 ciclos de treinamento

ARQ [5,20,7]		RMSE			TEMPO (min)
TAXA DE APRENDIZAGEM	10.000 ciclos	TREINO	VALIDAÇÃO	TESTE	
	0,2	0,0061	0,0062	0,0061	1.605,98
	0,4	0,0060	0,0061	0,0060	1.976,22
	0,6	0,0067	0,0067	0,0066	1.599,22
	0,8	0,0069	0,0070	0,0068	1.980,23

<sup>3</sup> Tempo computacional gasto por microcomputador Intel Core 2 Duo P 8700, 4Gb RAM e Microsoft Windows 7 32 bits.



**Figura 5.4:** Evolução do RMSE ao longo dos 10.000 ciclos de treinamento – Arquitetura [5,20,7] – taxa de aprendizagem 0,4

Observa-se que a partir de 5.000 ciclos de treinamento, o valor de RMSE médio tende a manter-se praticamente constante, para a taxa de aprendizagem 0,4. Observa-se também que para as taxas 0,2, 0,6 e 0,8 o RMSE médio resultou em valores maiores se comparado aquele obtido à taxa 0,4.

Cabe salientar que para 5.000 e 10.000 ciclos de treinamento, o valor de RMSE médio variou muito pouco, ou seja,  $(0,0063 - 0,0060 = 0,0003)$  para tempos de processamento computacional bastante distintos, da ordem de 799,38 e 1.976,22 minutos, respectivamente.

Muito embora os processadores das máquinas utilizadas na simulação possuam características diferentes, pode-se afirmar que a quantidade de ciclos de treinamento superiores a casa dos 5.000, apresentaram um elevado tempo computacional para valores do RMSE médio praticamente idênticos.

Após a obtenção da arquitetura procedeu-se à comparação dos valores obtidos via RNA treinada e EPANET, conforme demonstrado na sequência.

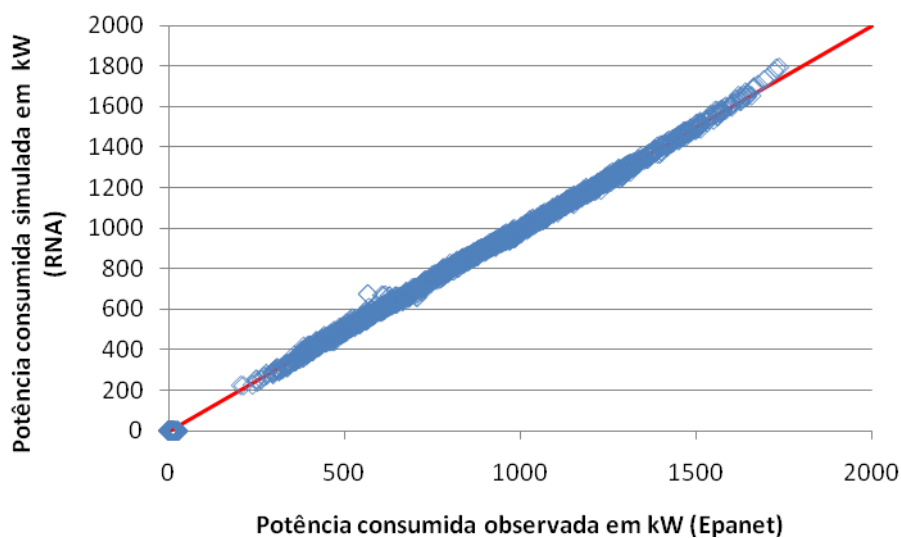
### 5.2.1 Resultados obtidos

Neste item são apresentados os gráficos e tabelas com os resultados observados para um passo horário de tempo à frente ( $t+1$ ) e o comparativo com os valores obtidos via simulação do modelo (RNA) para as potências consumidas pelos conjuntos de bombeamento, os níveis dos tanques T-65, T-165 e T-265, as pressões nos nós J-55, J-90 e J-170, bem como o bias e os pesos para os melhores ajustes de 2.000, 5.000 e 10.000 ciclos de treinamento respectivamente.


Cabe salientar que os gráficos e tabelas apresentados, estão referenciados sempre aos resultados obtidos do conjunto de testes. Não foram construídos gráficos dos conjuntos de treinamento e validação cruzada em função dos valores serem muito semelhantes aos conjuntos de testes.

### 5.2.1.1 2.000 ciclos de treinamento


A seguir são apresentadas as representações gráficas das dispersões entre os dados observados (EPANET) e os simulados (RNA) para arquitetura [5,20,7] e 2.000 ciclos de treinamento, bem como as tabelas com os resultados observados para um passo de tempo à frente ( $t+1$ ) e o comparativo com os valores obtidos via simulação do modelo (RNA) para as potências consumidas pelo conjunto de bombeamento, os níveis dos tanques T-65, T-165, T-265 e as pressões nos nós J-55, J-90 e J-170.



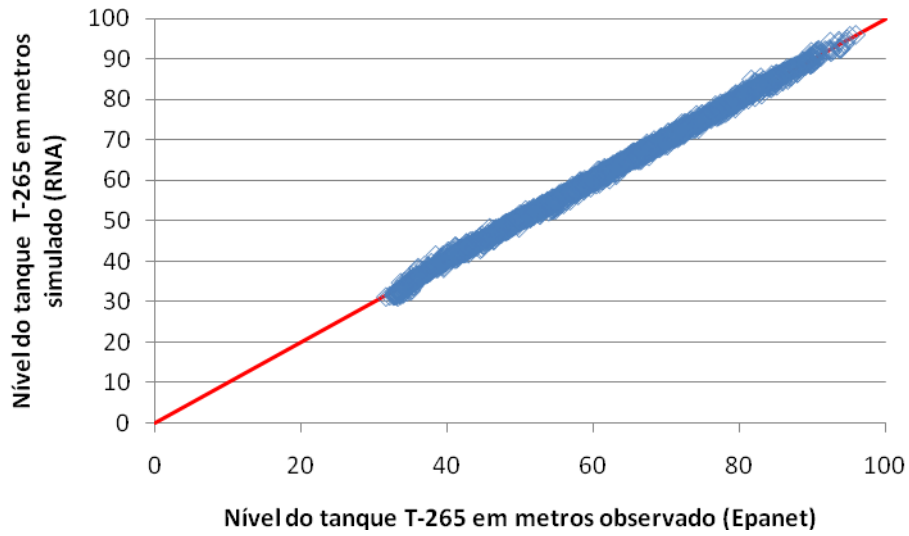
**Figura 5.5:** Comparativo das amostras observadas x simuladas  
Potência consumida pelo conjunto de bombeamento (kW)




**Figura 5.6:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-65 (m)



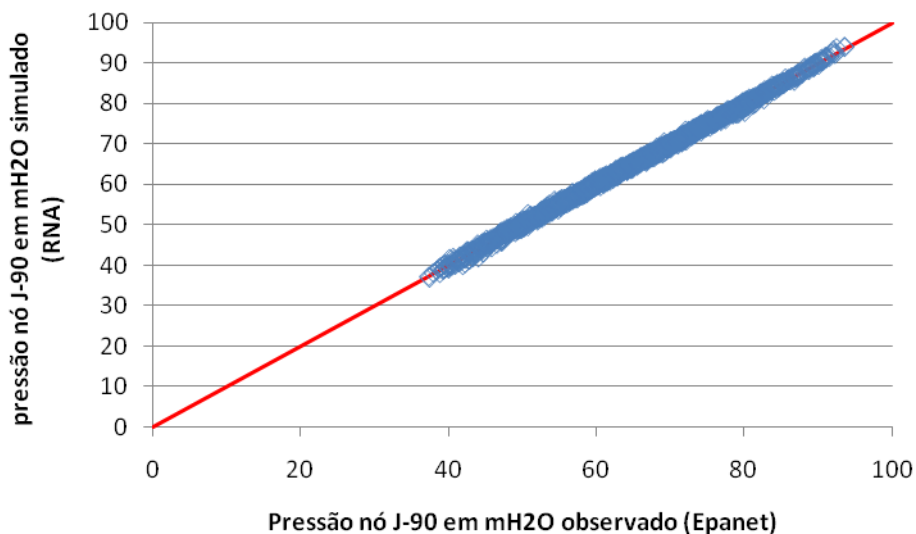
**Figura 5.7:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-165 (m)



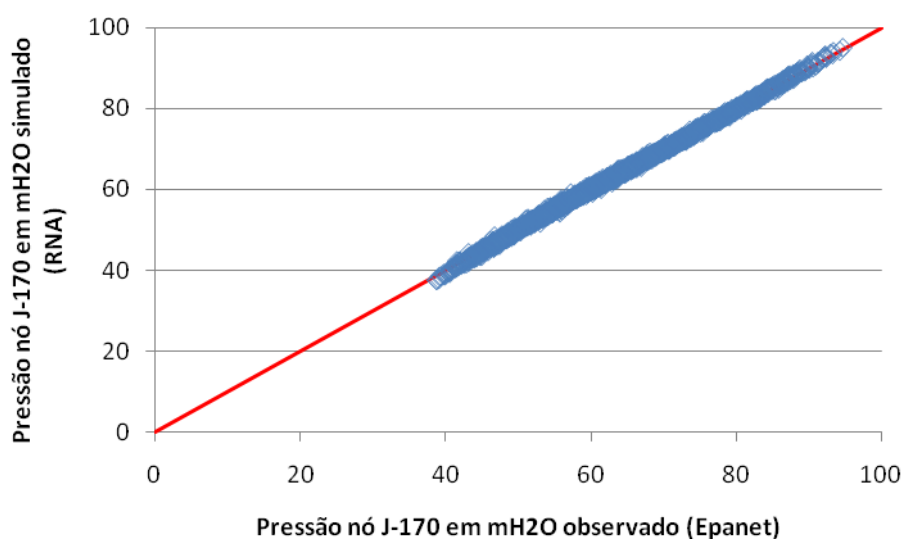
**Figura 5.8:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-265 (m)



**Figura 5.9:** Comparativo das amostras observadas x simuladas – Pressões nó J-55 (mH<sub>2</sub>O)



**Figura 5.10:** Comparativo das amostras observadas x simuladas – Pressões nó J-90 (mH<sub>2</sub>O)



**Figura 5.11:** Comparativo das amostras observadas x simuladas – Pressões nó J-170 (mH<sub>2</sub>O)

Os resultados apresentados nas figuras sugerem uma boa generalização alcançada pela simulação via RNA, tendo em vista que os pontos observados x simulados estão dispostos sobre a reta de 45°, destacada nas referidas figuras em vermelho. Na Tabela 5.4 é apresentado um resumo estatístico dos desvios para a arquitetura da rede identificada, ao final de 2.000 ciclos de treinamento.

**Tabela 5.4:** Desvios absolutos (observado x simulado) para 2.000 ciclos de treinamento.

<b>Desvios absolutos</b>	<b>Potência (kW)</b>	<b>T-65 (m)</b>	<b>T-165 (m)</b>	<b>T-265 (m)</b>	<b>J-55 (mH2O)</b>	<b>J-90 (mH2O)</b>	<b>J-170 (mH2O)</b>
<b>médio</b>	8,28	0,29	0,48	0,46	0,29	0,29	0,27
<b>mínimo</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00
<b>máximo</b>	110,60	2,11	2,85	3,26	2,17	2,15	1,86

Verifica-se que no Tank T-65 ocorreu um desvio médio inferior aos resultados de T-165 e T-265. Em relação às pressões, os desvios foram pequenos, o que sugere uma boa generalização do modelo.

Cabe salientar que os desvios absolutos máximos para os níveis dos tanques T-65, T-165 e T-265, apresentam valores 2,11, 2,85 e 3,26 metros respectivamente. Isto se deve ao intervalo de variação dos níveis dos padrões apresentados à rede para treinamento, cujos níveis dos tanques situam-se entre 20 e 90 metros aproximadamente.

Fato semelhante ocorre com as pressões, nos nós de controle, ou seja, J-55, J-90 e J-170, com os valores de 2,17, 2,15 e 1,86 mH2O respectivamente. O intervalo de variação dos níveis dos padrões apresentados a rede para treinamento, situam-se entre 30 e 90 mH2O aproximadamente.

A seguir são apresentados os valores dos bias ( $b_{ij}$ ) e dos pesos ( $W_{ij}$ ) obtidos para a arquitetura [5,20,7] considerando-se 2.000 ciclos de treinamento e taxa de aprendizagem igual a 0,4 que produziu os ajustes representados nos gráficos das figuras 5.5 a 5.11. Os valores foram extraídos do programa Scilab, utilizando-se o comando “load” para leitura do arquivo de backup denominado ‘arquitetura RNA[5-20-7].bak’. Sequencialmente aplica-se o comando “W” (peso) para obtenção dos valores ajustados de bias e pesos.



**Tabela 5.5:** Valores de bias e pesos ajustados das ligações sinápticas: (A) neurônios da camada de entrada para camada intermediária e (B) da camada intermediária para camada de saída.

Bias (bij)		PESOS (Wij)				
1	NEURÔNIOS	1	2	3	4	5
-0,5097	1	-0,8702	0,2624	-3,9870	0,0757	1,3144
2,8293	2	-1,1505	0,2750	-3,3027	5,4244	-1,2392
0,9879	3	-6,4164	0,1562	-1,6090	-0,6874	-1,1326
0,7768	4	-1,9297	0,1518	-1,3803	-1,1929	-1,1134
1,6238	5	0,5768	-0,0027	-1,4536	-0,4988	-1,5299
-2,2556	6	0,4139	-0,1575	2,3533	2,3749	-4,9557
-2,8376	7	0,9114	-0,2162	-1,5368	1,6081	1,7545
-1,1673	8	1,1748	0,2850	-1,7235	0,8319	1,0020
-0,0081	9	-0,8788	-0,0048	0,9360	1,6259	0,9401
-0,6713	10	-5,7240	0,0178	-0,1672	-0,7026	-0,2292
-2,5838	11	-0,2208	0,0804	-0,7780	0,6497	4,3866
1,2176	12	0,2840	-0,2272	2,3338	-4,1894	4,2688
7,6080	13	-0,0433	0,2029	-3,8978	-1,5057	-2,7605
-4,1010	14	-0,3027	0,0666	-0,8965	-4,7272	7,1960
2,8615	15	0,5768	-0,2298	-4,3017	2,2449	2,3546
3,8841	16	0,3619	-0,0231	0,3506	-2,2854	-2,3636
-2,0790	17	0,0061	-0,2005	1,8795	3,4396	4,4847
0,6638	18	-0,1021	-0,0265	6,9535	-0,8287	-1,5516
-1,4303	19	0,5849	-0,0866	0,5704	-1,9228	1,4246
-0,8533	20	0,0778	0,0249	0,3700	1,0046	-0,7187


(A)

Bias (bij)	1	-0,2254	0,6605	0,3073	0,2084	0,1538	-0,0059	-0,5839
PESOS (Wij)	NEURÔNIOS	1	2	3	4	5	6	7
	1	0,8817	0,3357	-0,2387	-0,0650	-2,2903	-3,3025	-0,6362
	2	0,6703	-0,9494	1,5276	-0,1292	-0,9292	-1,2416	-0,0842
	3	-4,9300	0,0447	0,2384	0,0685	-0,4629	-1,0512	-0,7414
	4	-1,6410	-2,3733	-1,7186	-0,8737	-1,3022	-0,6568	-1,1112
	5	0,4285	-1,5700	-2,3404	-2,3745	-0,4065	-0,5653	-2,0242
	6	-0,5303	1,2585	1,1827	-2,0292	0,1612	1,6507	0,6555
	7	0,2155	-0,1765	1,1852	1,2331	0,9248	0,7788	2,0003
	8	2,4972	0,4773	0,1094	1,3018	-0,3095	-0,2161	-0,0688
	9	-2,1537	1,5941	0,5413	1,6125	0,1890	0,9289	0,3973
	10	-3,7529	0,2305	-0,0220	-0,0279	0,2145	0,5818	0,8223
	11	-1,2147	0,0073	-0,1358	-2,5339	0,6674	1,3731	0,0503
	12	-0,1810	1,1521	-1,7604	1,7627	1,4217	1,1539	0,1704
	13	-0,1723	-3,7554	-1,2461	-2,4392	-2,9140	-2,3098	-2,1914
	14	0,2043	-0,4350	-1,5250	1,9467	0,4088	-0,4540	-0,5269
	15	0,4838	-1,7264	1,1309	1,5487	1,0210	1,6148	1,9255
	16	1,4527	0,8590	-2,5235	-3,2677	-1,3065	-0,4642	-1,4741
	17	-1,5979	0,5328	2,3576	2,5257	2,9291	1,4926	2,7745
	18	0,5022	2,1431	-0,3329	-0,4782	-0,7693	-1,2835	-0,4213
	19	0,5022	2,1431	-0,3329	-0,4782	-0,7693	-1,2835	-0,4213
20	1,1523	0,4877	2,4406	0,1464	-0,9551	-0,8208	0,0825	

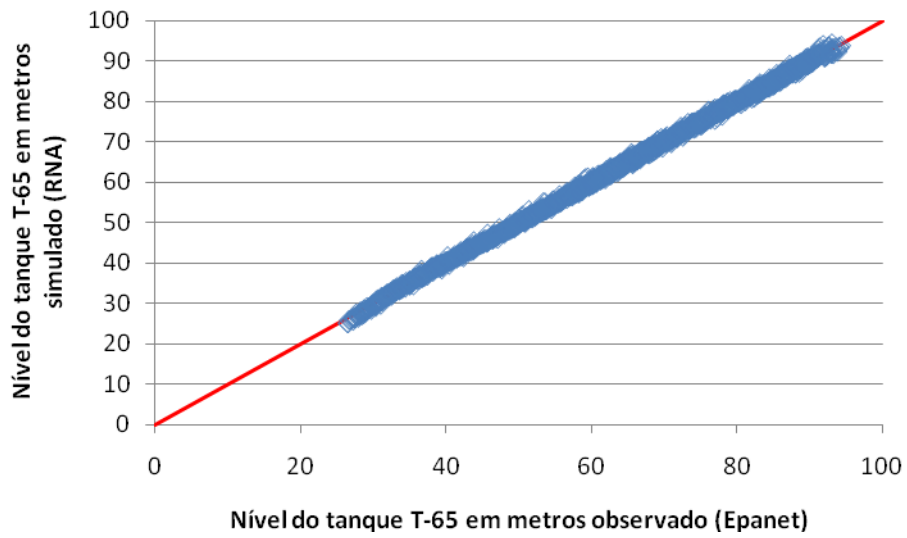
(B)

### 5.2.1.2 5.000 ciclos de treinamento


A seguir são apresentadas as representações gráficas das dispersões entre os dados observados (EPANET) e os simulados (RNA) para arquitetura [5,20,7] e 5.000 ciclos de treinamento, bem como as tabelas com os resultados observados para um passo de tempo à frente ( $t+1$ ) e o comparativo com os valores obtidos via simulação do modelo (RNA) para as potências consumidas pelo conjunto de bombeamento, os níveis dos tanques T-65, T-165, T-265 e as pressões nos nós J-55, J-90 e J-170.




**Figura 5.12:** Comparativo das amostras observadas x simuladas  
Potência consumida pelo conjunto de bombeamento (kW)




**Figura 5.13:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-65 (m)




**Figura 5.14:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-165 (m)



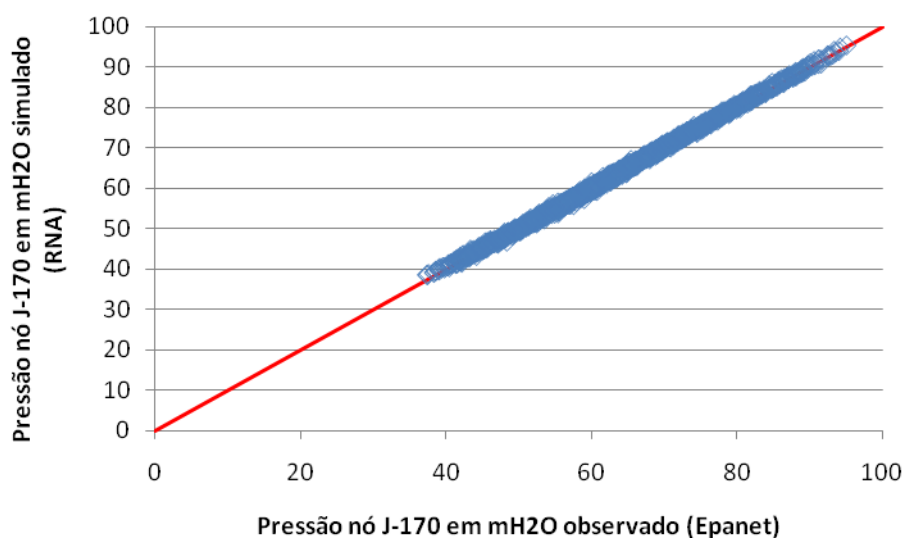
**Figura 5.15:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-265 (m).



**Figura 5.16:** Comparativo das amostras observadas x simuladas – Pressões nó J-55 (mH<sub>2</sub>O)



**Figura 5.17:** Comparativo das amostras simuladas x observadas – Pressões nó J-90 (mH<sub>2</sub>O)



**Figura 5.18:** Comparativo das amostras observadas x simuladas – Pressões nó J-170 (mH<sub>2</sub>O)

Observa-se através dos gráficos uma boa generalização dos dados alcançada pela simulação via RNA, tendo em vista a proximidade dos valores observados x simulados para 5.000 ciclos de treinamento. A seguir são apresentados os comparativos dos desvios absolutos dos dados obtidos nestas condições de simulação.

**Tabela 5.6:** Desvios absolutos (observado x simulado) para 5.000 ciclos de treinamento.

<b>Desvios absolutos</b>	<b>Potência (kW)</b>	<b>T-65 (m)</b>	<b>T-165 (m)</b>	<b>T-265 (m)</b>	<b>J-55 (mH<sub>2</sub>O)</b>	<b>J-90 (mH<sub>2</sub>O)</b>	<b>J-170 (mH<sub>2</sub>O)</b>
<b>médio</b>	6,70	0,24	0,42	0,40	0,31	0,28	0,26
<b>mínimo</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00
<b>máximo</b>	81,10	2,41	2,85	3,56	2,17	1,93	1,79

Verifica-se que no Tanque T-65 ocorreu um desvio médio inferior aos resultados de T-165 e T-265, a exemplo do que ocorreu com 2.000 ciclos de treinamento. Em relação às pressões os desvios foram pequenos, porém observa-se um incremento de valores de pequenas proporções em comparação a 2.000 ciclos de treinamento. Verifica-se ainda uma diminuição do desvio médio absoluto para as potências consumidas pelo conjunto de bombeamento, em comparação a 2.000 ciclos de treinamento.

Cabe salientar que os desvios absolutos máximos para os níveis dos tanques T-65, T-165 e T-265, apresentam valores 2,17, 2,15 e 3,56 metros respectivamente. Isto se deve ao intervalo de variação dos níveis dos padrões apresentados a rede para treinamento, cujos níveis dos tanques situam-se entre 20 e 90 metros aproximadamente.

Fato semelhante ocorre com as pressões, nos nós de controle, ou seja, J-55, J-90 e J-170, com os valores de 2,17, 1,93 e 1,79 mH<sub>2</sub>O respectivamente. O intervalo de variação das pressões dos padrões apresentados a rede para treinamento, situam-se entre 30 e 90 mH<sub>2</sub>O aproximadamente.

A seguir são apresentados os valores dos bias ( $b_{ij}$ ) e dos pesos ( $W_{ij}$ ) obtidos para a arquitetura [5,20,7] considerando-se 5.000 ciclos de treinamento e taxa de aprendizagem igual a 0,4 que produziu os ajustes representados nos gráficos das figuras 5.12 a 5.18. Os valores foram extraídos do programa Scilab, utilizando-se o comando “load” para leitura do arquivo de backup denominado ‘arquitetura RNA[5-20-7].bak’. Sequencialmente aplica-se o comando “W” (peso) para obtenção dos valores ajustados de bias e pesos.

**Tabela 5.7:** Valores de bias e pesos ajustados das ligações sinápticas: (A) neurônios da camada de entrada para camada intermediária e (B) da camada intermediária para camada de saída.

Bias (bij)	PESOS (Wij)					
	1	2	3	4	5	
	<b>NEURÔNIOS</b>					
	1	1	2	3	4	5
-0,4851	1	-0,5654	0,2496	-3,6084	1,2170	-0,6590
1,9667	2	-1,2502	0,2176	-3,3856	7,9231	-1,0688
0,2605	3	-5,1167	0,0917	-1,3391	-0,4059	-1,0545
1,3723	4	-1,2644	0,0649	-1,8500	-2,5746	-1,5861
0,9371	5	-0,2359	0,1455	-0,8036	-1,7000	-6,4622
-2,1912	6	0,1184	-0,0555	0,9575	4,7031	-5,4787
-1,2131	7	1,4490	-0,1287	-6,8427	2,2157	2,3443
-2,0410	8	1,5010	0,1479	-2,0020	1,2766	1,5015
-2,0693	9	-0,6858	0,0593	0,1466	1,9200	1,0510
0,3435	10	-6,7674	0,1112	-0,7469	-0,8706	-0,5273
-1,2148	11	-1,1301	0,5188	-4,5608	-1,5902	8,3634
3,3158	12	0,4687	-0,2204	2,2130	-7,8868	4,2706
5,8213	13	-0,2092	0,1197	-4,6552	-0,7701	-1,3298
-5,1234	14	-0,1452	0,0209	-0,1436	-6,1456	9,2078
3,9590	15	0,4538	-0,2199	-7,4199	2,6890	2,5838
7,8998	16	-0,1198	0,1325	-0,4678	-3,6959	-3,9991
-0,7219	17	-0,6982	-0,1231	2,3487	2,4783	1,6692
0,6156	18	-0,5517	0,0391	8,5642	-0,2337	-0,5497
-2,5068	19	0,1531	-0,0321	1,1336	-0,6423	3,1568
-1,1150	20	-0,6634	-0,3218	1,0451	0,3284	-0,3273


(A)

Bias (bij)	1	2,8058	0,6540	0,6116	1,5170	2,5145	2,5042	0,2173
	<b>NEURÔNIOS</b>	1	2	3	4	5	6	7
	1	1,1784	-2,1687	-0,2031	-1,2654	-3,5589	-4,1817	-0,9385
	2	0,2915	-0,3862	1,0156	-0,1320	-0,6087	-0,7940	-0,0423
	3	-4,5604	-0,9234	0,9436	0,1196	-0,8920	-1,7112	-1,0663
	4	-1,5260	-1,4932	-3,3913	-0,4930	-2,6364	-2,6724	-2,4922
	5	-0,2058	0,1625	-1,0246	-4,7969	-1,3359	0,8328	-2,0268
	6	-0,0722	0,1831	1,1234	-1,5483	-0,8550	0,0912	0,4818
	7	-0,5497	-1,0612	0,5191	0,4183	0,4653	0,6077	0,7124
	8	2,2198	1,4818	-0,2392	0,5902	0,5303	0,0727	0,0981
	9	-2,5614	0,6799	-0,1910	2,9433	1,0022	0,4019	0,5062
	10	-4,5159	0,2150	-0,4688	-0,2719	0,0840	0,5062	0,5253
	11	-0,2566	0,3108	0,2118	-0,4945	0,2980	0,5226	0,1751
	12	-0,1008	0,1655	-0,8620	0,4265	0,0889	0,0593	0,1268
	13	0,2501	-2,9623	-0,9783	-1,3403	-2,6620	-2,8707	-1,5460
	14	0,0432	-0,0445	-1,0735	1,4553	0,5634	-0,1092	-0,3297
	15	0,0398	-0,9427	0,6481	0,7295	1,0493	1,2428	1,1948
	16	0,3708	0,0162	-2,7216	-2,9032	-2,0607	-1,6868	-2,8035
	17	-4,1855	0,7499	1,7853	1,9677	2,8125	3,3520	2,7064
	18	0,8298	2,1537	-0,4643	-0,6088	-1,0231	-1,4383	-0,7184
	19	-0,1658	-0,8098	2,0208	-0,5240	-1,6426	-1,4445	0,7253
	20	-0,7449	1,3175	0,3307	-0,6686	0,9412	0,7649	1,0976

(B)


### 5.2.1.3 10.000 ciclos de treinamento

A seguir são apresentadas as representações gráficas das dispersões entre os dados observados (EPANET) e os simulados (RNA) para arquitetura [5,20,7] e 10.000 ciclos de treinamento, bem como as tabelas com os resultados observados para um passo de tempo à frente ( $t+1$ ) e o comparativo com os valores obtidos via simulação do modelo (RNA) para as potências consumidas pelo conjunto de bombeamento, os níveis dos tanques T-65, T-165, T-265 e as pressões nos nós J-55, J-90 e J-170.

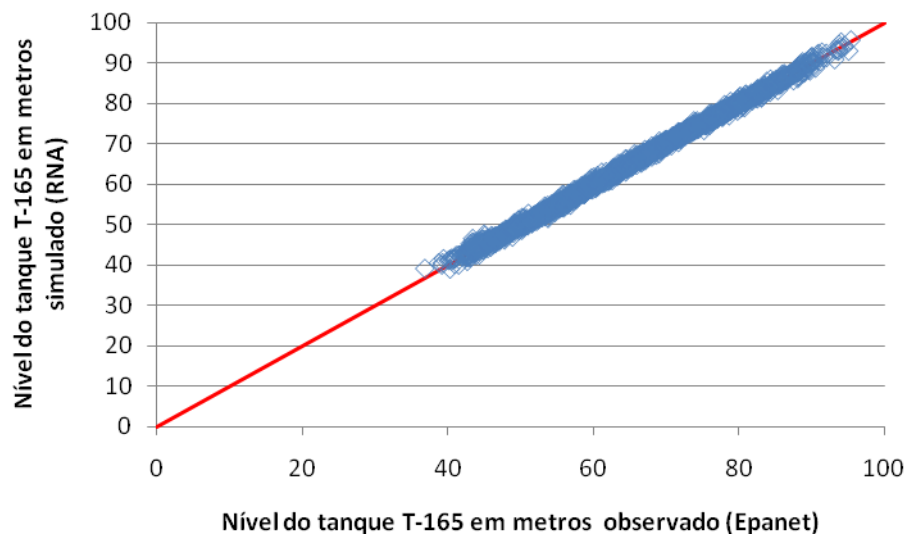


**Figura 5.19:** Comparativo das amostras observadas x simuladas  
Potência consumida pelo conjunto de bombeamento (kW)







**Figura 5.20:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-65 (m)




**Figura 5.21:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-165 (m)




**Figura 5.22:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-265 (m)



**Figura 5.23:** Comparativo das amostras observadas x simuladas – Pressões nó J-55 (mH<sub>2</sub>O)



**Figura 5.24:** Comparativo das amostras observadas x simuladas – Pressões nó J-90 (mH<sub>2</sub>O)



**Figura 5.25:** Comparativo das amostras observadas x simuladas – Pressões nó J-170 (mH<sub>2</sub>O)

Os gráficos sugerem uma boa generalização alcançada pela simulação via RNA, tendo em vista a proximidade dos valores observados x simulados para 10.000 ciclos de treinamento, porém com incrementos pequenos considerando-se os tempos computacionais gastos. A seguir são apresentados os valores comparativos com os dados obtidos nestas condições de simulação.

**Tabela 5.8:** Desvios absolutos (observado x simulado) para 10.000 ciclos de treinamento.

<b>Desvios absolutos</b>	<b>Potência (kW)</b>	<b>T-65 (m)</b>	<b>T-165 (m)</b>	<b>T-265 (m)</b>	<b>J-55 (mH<sub>2</sub>O)</b>	<b>J-90 (mH<sub>2</sub>O)</b>	<b>J-170 (mH<sub>2</sub>O)</b>
<b>médio</b>	6,01	0,24	0,37	0,32	0,32	0,30	0,22
<b>mínimo</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00
<b>máximo</b>	78,30	2,31	3,09	3,06	2,07	1,70	1,39

Novamente verifica-se que no Tanque T-65 ocorreu um desvio médio inferior aos resultados de T-165 e T-265 a exemplo do que ocorreu com 2.000 e 5.000 ciclos de treinamento. Em relação às pressões os desvios foram pequenos, porém observa-se um aumento de valores de pequenas proporções para J-55 e J-90 em relação a 5.000 ciclos de treinamento. Por outro lado, para J-170 ocorreu uma redução dos valores, em comparação com 5.000 ciclos de treinamento.

Cabe salientar que os desvios absolutos máximos para os níveis dos tanques T-65, T-165 e T-265, apresentam valores 2,31, 3,09 e 3,06 metros respectivamente. Isto se deve ao intervalo de variação dos níveis dos padrões apresentados a rede para treinamento, cujos níveis dos tanques situam-se entre 20 e 90 metros aproximadamente.

Fato semelhante ocorre com as pressões, nos nós de controle, ou seja, J-55, J-90 e J-170, com os valores de 2,07, 1,70 e 1,39 mH<sub>2</sub>O respectivamente. O intervalo de variação das pressões dos padrões apresentados a rede para treinamento, situam-se entre 30 e 90 mH<sub>2</sub>O aproximadamente.

A seguir são apresentados os valores dos bias ( $b_{ij}$ ) e dos pesos ( $W_{ij}$ ) obtidos para a arquitetura [5,20,7] considerando-se 10.000 ciclos de treinamento e taxa de aprendizagem igual a 0,4 que produziu os ajustes representados nos gráficos das figuras 5.19 a 5.25. Os valores foram extraídos do programa Scilab, utilizando-se o comando “load” para leitura do arquivo de backup denominado ‘arquitetura RNA[5-20-7].bak’. Sequencialmente aplica-se o comando “W” (peso) para obtenção dos valores ajustados de bias e pesos.

**Tabela 5.9:** Valores de bias e pesos ajustados das ligações sinápticas: (A) neurônios da camada de entrada para camada intermediária e (B) da camada intermediária para camada de saída.

Bias (bij)	PESOS (Wij)					
	1	2	3	4	5	
	<b>NEURÔNIOS</b>					
-0,0723	1	-0,5095	0,2481	-3,5168	0,2348	-0,6460
2,2341	2	-1,3248	0,2229	-3,9357	6,9875	-0,3973
-0,3860	3	-2,7578	0,3953	-2,6354	-0,1319	-3,2127
1,4612	4	-0,9046	0,0540	-1,3659	-3,7228	-2,8594
0,0069	5	-0,0528	0,0505	-0,2916	-0,4099	-8,7674
-1,3165	6	-0,0099	-0,0520	0,4371	5,7749	-7,5487
-1,3038	7	1,7406	-0,2632	-8,4493	2,7700	2,9353
-2,5233	8	1,5590	0,1251	-1,6170	1,5451	1,6590
-2,6911	9	-0,2218	0,1224	-0,3452	1,3165	3,2168
1,1510	10	-6,4894	0,0783	-1,0841	-0,9389	-0,6786
-0,8767	11	-1,3247	0,5086	-5,3211	-2,4459	9,3529
4,5191	12	0,5242	-0,1243	2,3500	-8,4789	2,7692
5,2593	13	0,0013	0,1755	-4,0403	-0,8940	-1,0828
-3,8661	14	-0,0775	0,0326	0,0469	-6,8032	7,7513
3,9644	15	0,4262	-0,1956	-7,1788	2,3442	2,4746
8,8485	16	-0,0499	0,1148	-0,1865	-3,7736	-5,0336
0,0255	17	-0,8442	-0,1252	1,8603	2,0647	1,7149
0,6869	18	-0,6023	0,0310	8,8017	-0,4775	-0,6650
-2,2594	19	0,1016	-0,0406	1,1555	-0,8692	3,7278
-1,2027	20	-0,6004	-0,0783	0,4476	1,7451	-0,2948

(A)

Bias (bij)	1	3,1893	1,6251	1,7879	2,1699	2,3095	2,7315	0,1651
	<b>NEURÔNIOS</b>	1	2	3	4	5	6	7
	1	1,7438	-2,8000	-2,0433	-1,4704	-4,6595	-5,6529	-1,5358
	2	0,4111	-0,4537	0,7105	-0,1201	-0,7184	-0,8556	-0,1158
	3	-3,2160	-1,1695	1,3343	0,3389	-1,8673	-1,9242	-2,8926
	4	-1,1256	-1,0473	-4,3189	-2,1299	-2,5013	-1,7706	-3,5160
	5	0,3077	0,3017	0,2315	-5,7638	-0,9441	0,8176	-0,3917
	6	-0,0946	0,0363	0,9655	-0,9451	-0,6320	0,0763	-0,0235
	7	-0,3375	-0,7107	0,3551	0,2733	0,3796	0,4038	0,4419
	8	2,4104	1,1604	0,0203	0,2124	0,5352	0,3687	0,7340
	9	-1,5675	0,0507	0,4706	2,6777	1,0382	0,5131	-0,6089
	10	-5,4578	-0,2735	-0,0575	-0,0662	-0,3489	-0,4811	-0,0724
	11	-0,1961	0,2522	0,2401	-0,4739	0,1601	0,4202	0,1837
	12	-0,1273	0,2250	-1,0974	0,3802	0,2885	0,2376	-0,0195
	13	0,3800	-3,6605	-2,0998	-1,6335	-3,2418	-3,6393	-2,2934
	14	0,1704	-0,0437	-1,4225	1,3006	0,5008	-0,1794	-0,2065
	15	0,0428	-0,9899	0,7363	0,7012	1,0890	1,2508	1,2205
	16	0,5105	0,1788	-2,2387	-3,3050	-1,3849	-1,1247	-2,7008
	17	-4,8996	0,5792	2,1571	2,0297	2,5412	3,0297	3,3199
	18	0,7889	1,9922	-0,6159	-0,5009	-0,9869	-1,4241	-0,7206
	19	0,1047	-0,4721	1,1703	-1,1886	-1,4044	-1,2300	0,8125
	20	-2,0172	0,9470	-0,8393	0,2766	0,9955	0,5362	1,8157


(B)

### 5.2.2 Rede WDSA


Um número de diferentes estruturas de RNA foram avaliados para indentificar a arquitetura que melhor reproduz o comportamento do sistema hidráulico utilizado na batalha de calibração WDSA 2010.

De maneira análoga ao princípio adotado para rede Anytown modificada, variou-se o número de neurônios na camada oculta desde vinte até cento e cinquenta neurônios na camada intermediária, examinando-se paralelamente os valores produzidos para o RMSE (Figura 5.8).


Verificou-se que a arquitetura que apresentava o menor RMSE, possuía sessenta e seis neurônios na camada intermediária, para um conjunto de cinquenta mil padrões e dois mil ciclos de treinamento com taxa de aprendizagem 0,4.




(A)




(B)



(C)



(D)

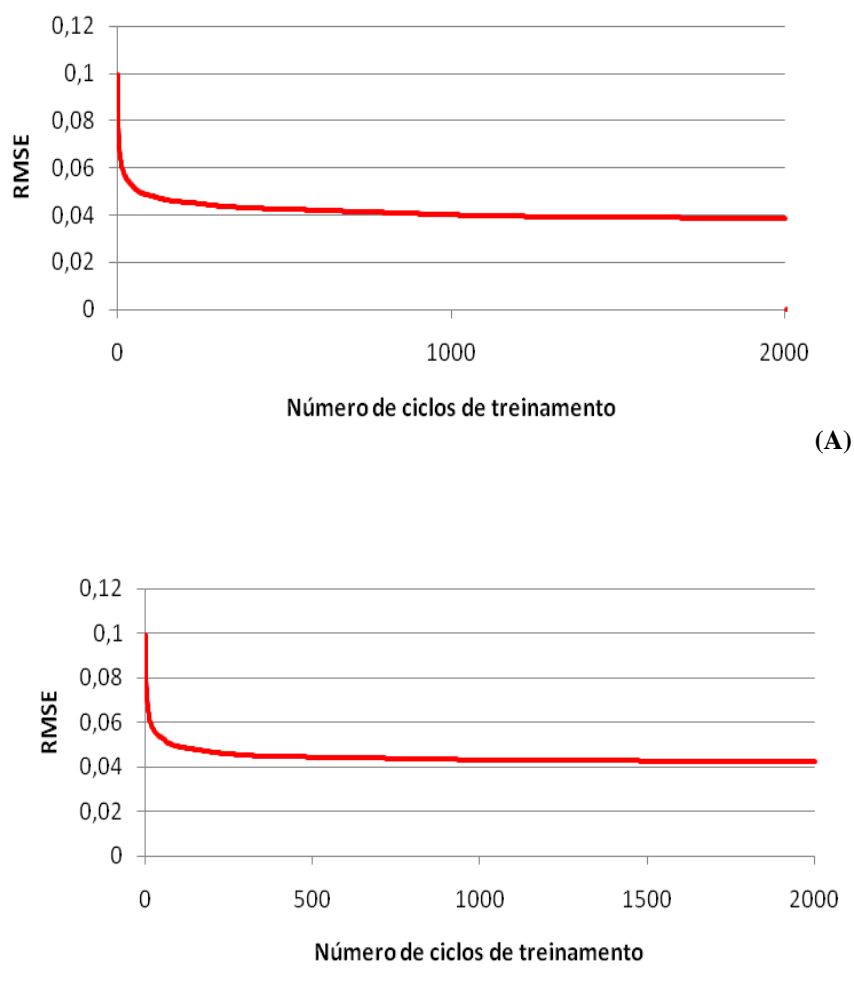


(E)

**Figura 5.26:** Evolução do RMSE ao longo de 2.000 ciclos de treinamento e taxa de aprendizagem 0,4: (A) Arquitetura [23,50,20]; (B) Arquitetura [23,66,20]; (C) Arquitetura [23,80,20]; (D) Arquitetura [23,100,20] e (E) Arquitetura [23,150,20]

Decisões relativas ao número de conjuntos de treinamento e testes são necessárias e estão sujeitas à opinião e à experiência de quem modela e, no caso, justifica-se a utilização dos cinquenta mil padrões em função do tamanho e da complexidade do SDAA.

Cabe salientar que a RNA foi treinada com vinte e cinco mil pares de vetores entrada / saída e testada para dois subconjuntos sendo um de doze mil e quinhentos pares de entrada / saída para validação cruzada e outro de igual dimensão para teste, sendo o tempo computacional gasto da ordem de 2.163 minutos em uma máquina equipada com processador Intel Core 2 Quad Q6600 com 4 Gb de memória RAM (MS Windows 7 32 bits) e de 2.583 minutos em uma máquina equipada com processador Intel Core 2 Duo P 8700 com 4 Gb de memória RAM (MS Windows 7 32 bits).



**Figura 5.27:** Evolução do RMSE para a Arquitetura [23,66,20] e taxa de aprendizagem 0,4 usando: (A) 50.000 padrões e (B) 40.000 padrões.

Reduzindo-se o número de padrões de treinamento de cinquenta para quarenta mil, na expectativa de ganho no tempo computacional, observou-se que não ocorreu melhoria significativa,




diminuindo o tempo em apenas 54 minutos, ou seja, de 2.163 minutos para 2.109 minutos. Além disso, o RMSE médio produzido nesta condição aumentou de 0,039 para 0,041 (Figura 5.26-B).

Uma vez conhecida e determinada a arquitetura procedeu-se a comparação dos valores obtidos via RNA treinada (simulados) e EPANET (observados).


### 5.2.2.1 Resultados obtidos – arquitetura [23,66,20]

Neste item são apresentadas as representações gráficas das dispersões entre os dados observados (EPANET) e simulados (RNA) para arquitetura [23,66,20] e 2.000 ciclos de treinamento, bem como as tabelas com os resultados observados para um passo de tempo à frente ( $t+1$ ) e o comparativo com os valores obtidos via simulação do modelo (RNA), para as potências consumidas pelos conjuntos de bombeamento B1, B2, B3, B4 e B5, os níveis dos tanques T-1, T-2, T-3, T-4, T-5, T-6 e T-7, as pressões nos nós J-53, J-297, J-302 e J-497, e as vazões os trechos P-374, P-397, P-399 e P-467.


Cabe salientar que os gráficos e tabelas apresentados, estão referenciados aos resultados obtidos do conjunto ao conjunto de testes. Não foram construídos gráficos dos conjuntos de treinamento e validação cruzada em função dos valores serem similares aos dos conjuntos de testes.




**Figura 5.28:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B1 (kW)




**Figura 5.29:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B2 (kW)




**Figura 5.30:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B3 (kW)




**Figura 5.31:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B4 (kW)




**Figura 5.32:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B5 (kW)




**Figura 5.33:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-1 (m)




**Figura 5.34:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-2 (m)




**Figura 5.35:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-3 (m)




**Figura 5.36:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-4 (m)




**Figura 5.37:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-5 (m)



**Figura 5.38:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-6 (m)



**Figura 5.39:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-7 (m)



**Figura 5.40:** Comparativo das amostras observadas x simuladas – Pressões nó J-53 (mH2O)




Figura 5.41: Comparativo das amostras observadas x simuladas – Pressões nó J-297 (mH2O)






Figura 5.42: Comparativo das amostras observadas x simuladas – Pressões nó J-302 (mH2O)





**Figura 5.43:** Comparativo das amostras observadas x simuladas – Pressões nó J-497 (mH2O)



**Figura 5.44:** Comparativo das amostras observadas x simuladas – Vazões trecho P-374 (L/s)




Figura 5.45: Comparativo das amostras observadas x simuladas – Vazões trecho P-397 (L/s)





Figura 5.46: Comparativo das amostras observadas x simuladas – Vazões trecho P-399 (L/s)



**Figura 5.47:** Comparativo das amostras observadas x simuladas – Vazões trecho P-467 (L/s)

Após análise gráfica dos resultados de saída da RNA, verifica-se uma inconsistência entre os valores observados e os simulados. Observa-se que para as variáveis em estudo (potência energética consumida pelos conjuntos elevatórios B-1, B-2, B-3, B-4 e B-5, pressões nos nós J-53, J-297, J302 e J497 e vazões para os trechos P-374, P-397, P-399 e P-467) não se obtém resultados satisfatórios, haja vista as discrepâncias demonstradas.

A exceção ocorre apenas para os níveis dos tanques T-1 e T-6, onde os resultados gráficos demonstram um comportamento satisfatório, com pequenos desvios absolutos médios entre os valores observados x simulados.

Diante desta constatação, evidenciou-se que os neurônios da camada de entrada não transmitiam as informações necessárias ao restante da RNA para uma boa generalização dos dados de saída.

Verificou-se também que existiam erros na geração dos padrões dos dados de potência consumida pelos conjuntos elevatórios. Por ser a potência consumida pelo conjunto elevatório, o produto da vazão pela altura manométrica de bombeamento, os resultados de saída da RNA para as vazões nos pontos de controle P-374, P-397, P-399 e P-467, também se apresentaram com valores inconsistentes.

Assim foram gerados novos padrões de treinamento e processadas mudanças na arquitetura, principalmente nos neurônios da camada de entrada cujas variáveis são:


- a) Camada de entrada com 17 neurônios representados por:
- Número de bombas em funcionamento em cada conjunto elevatório – conjunto B1 a B5 (5 neurônios);
  - Demandas totais dos setores de consumo – DMA1 a DMA5 (5 neurônios);
  - Níveis dos tanques no instante “t” – T1 a T7 (7 neurônios).
- b) Camada de saída com 20 neurônios representados por:
- Potência consumida pelos conjuntos elevatórios – B1 a B5 (5 neurônios);
  - Níveis dos tanques no instante “t+1” – T1 a T7 (7 neurônios);
  - Pressão nos nós – J-53, J-297, J-302 e J-497 (4 neurônios);
  - Vazão nos trechos – P-374, P-397, P-399 e P-467 (4 neurônios).

Iniciou-se assim nova simulação do modelo utilizando para tanto a arquitetura [17,60,20], com taxa de aprendizagem de 0,4 e 5.000 ciclos de treinamento.

O tempo computacional gasto foi da ordem de 3.869 minutos em uma máquina equipada com processador Intel Core 2 Duo modelo E-7300 de 2,66 GHz, 2Gb de RAM e sistema operacional MS Windows XP.

Verificou-se que os resultados obtidos apresentaram-se satisfatórios e uma boa generalização dos valores observados x simulados foi verificada para arquitetura proposta, ou seja, [17,60,20] com taxa de aprendizagem de 0,4 e 5.000 ciclos de treinamento.

Verificou-se ainda que a partir de 3.000 ciclos de treinamento, o valor de RMSE médio tende a manter-se constante com valor de 0,0010, para a taxa de aprendizagem 0,4, conforme demonstrado no gráfico da Figura 5.48.




**Figura 5.48:** Evolução do RMSE para a Arquitetura [17,60,20] e taxa de aprendizagem 0,4 utilizando 50.000 padrões de treinamento

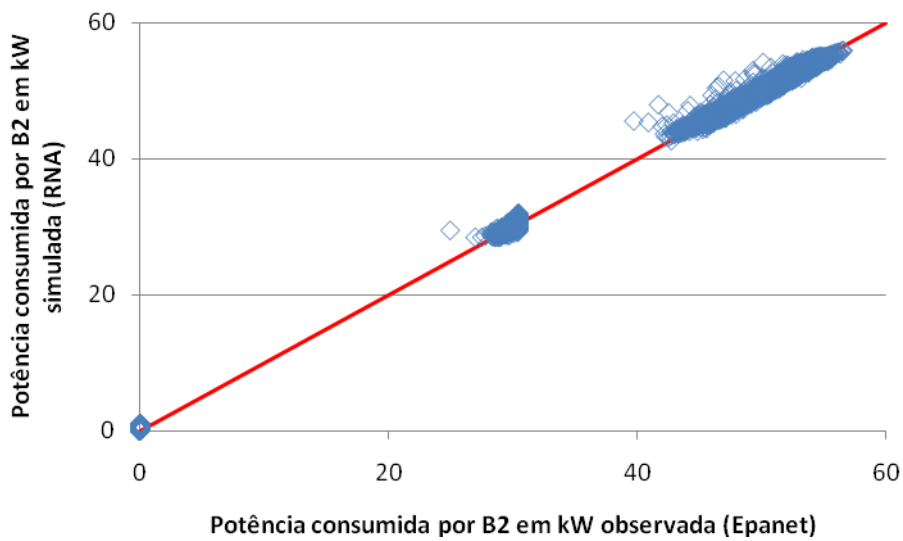
Cabe salientar que os gráficos e tabelas apresentados, estão referenciados aos resultados obtidos do conjunto de testes. Não foram construídos gráficos dos conjuntos de treino e validação cruzada, um virtude dos valores dos resultados de interesse pertencerem ao conjunto de testes.

### 5.2.2.2 Resultados obtidos – arquitetura [17,60,20]


Neste item são apresentadas as representações gráficas das dispersões entre os dados observados (EPANET) e simulados (RNA) para arquitetura [17,60,20] e 5.000 ciclos de treinamento, bem como as tabelas com os resultados observados para um passo de tempo à frente ( $t+1$ ) e o comparativo com os valores obtidos via simulação do modelo (RNA) para as potências consumidas pelos conjuntos de bombeamento B1, B2, B3, B4 e B5, os níveis dos tanques T-1, T-2, T-3, T-4, T-5, T-6 e T-7, as pressões nos nós J-53, J-297, J-302 e J-497, e as vazões os trechos P-374, P-397, P-399 e P-467.




**Figura 5.49:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B1 (kW)




**Figura 5.50:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B2 (kW)




**Figura 5.51:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B3 (kW)



**Figura 5.52:** Comparativo das amostras observadas x simuladas Potência consumida pelo conjunto de bombeamento B4 (kW)




**Figura 5.53:** Comparativo das amostras observadas x simuladas  
Potência consumida pelo conjunto de bombeamento B5 (kW)




**Figura 5.54:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-1 (m)







**Figura 5.55:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-2 (m)




**Figura 5.56:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-3 (m)




**Figura 5.57:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-4 (m)




**Figura 5.58:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-5 (m)




**Figura 5.59:** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-6 (m)




**Figura 5.60** Comparativo das amostras observadas x simuladas – Níveis de água no Tanque T-7 (m)




**Figura 5.61:** Comparativo das amostras observadas x simuladas – Pressões nó J-53 (mH2O)




**Figura 5.62:** Comparativo das amostras observadas x simuladas – Pressões nó J-297 (mH2O)




**Figura 5.63:** Comparativo das amostras observadas x simuladas – Pressões nó J-302 (mH2O)




**Figura 5.64:** Comparativo das amostras observadas x simuladas – Pressões nó J-497 (mH2O)




**Figura 5.65:** Comparativo das amostras observadas x simuladas – Vazões trecho P-374 (L/s)



**Figura 5.66:** Comparativo das amostras observadas x simuladas – Vazões trecho P-397 (L/s)



**Figura 5.67:** Comparativo das amostras observadas x simuladas – Vazões trecho P-399 (L/s)



**Figura 5.68:** Comparativo das amostras observadas x simuladas – Vazões trecho P-467 (L/s)

Os gráficos sugerem uma boa generalização alcançada pela simulação via RNA, tendo em vista a proximidade dos valores observados x simulados para 5.000 ciclos de treinamento, com exceção das vazões principalmente no trecho P-467. Há um ponto discrepante no nível T-2 e outros dois em J-302. Como se pode observar no gráfico, o ponto T-2 é único e isolado, cujo valor observado (Epanet) é 2,07 metros e o valor simulado (RNA) é 5,20 metros. Efetuando-se a

diferença em valores absolutos, obtém-se 3,13 metros, o único valor discrepante do desvio absoluto máximo para T-2 (Tabela 5.11).

Da mesma forma, para o nó J-302, verificam-se na Figura 5.63 dois únicos valores discrepantes de pressão, que, por se tratarem de amostras resultantes únicas e isoladas, podem ser consideradas exceção à regra, uma vez que a grande maioria dos padrões foi adequadamente modelada pela RNA construída.

**Tabela 5.10:** Desvios absolutos (observado x simulado) – Potência consumida pelos conjuntos de bombeamento B1 a B5.

<b>Desvios absolutos</b>	<b>Potência B1 (kW)</b>	<b>Potência B2 (kW)</b>	<b>Potência B3 (kW)</b>	<b>Potência B4 (kW)</b>	<b>Potência B5 (kW)</b>
<b>médio</b>	0,40	0,32	0,73	0,16	0,21
<b>máximo</b>	19,11	6,29	9,22	1,99	2,42
<b>mínimo</b>	0,00	0,00	0,00	0,00	0,00

**Tabela 5.11:** Desvios absolutos (observado x simulado) – Níveis dos tanques T-1 a T-7 (metros).

<b>Desvios absolutos</b>	<b>T-1 (m)</b>	<b>T-2 (m)</b>	<b>T-3 (m)</b>	<b>T-4 (m)</b>	<b>T-5 (m)</b>	<b>T-6 (m)</b>	<b>T-7 (m)</b>
<b>médio</b>	0,04	0,05	0,04	0,04	0,03	0,03	0,03
<b>máximo</b>	0,40	3,13	0,46	0,51	0,37	0,36	0,57
<b>mínimo</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00

**Tabela 5.12:** Desvios absolutos (observado x simulado) – Pressões nos nós J-53, J-297, J-302 e J-497.

<b>Desvios absolutos</b>	<b>J-53 (mH2O)</b>	<b>J-297 (mH2O)</b>	<b>J-302 (mH2O)</b>	<b>J-497 (mH2O)</b>
<b>médio</b>	0,03	0,04	0,24	0,05
<b>máximo</b>	0,38	0,88	13,95	0,77
<b>mínimo</b>	0,00	0,00	0,00	0,00



**Tabela 5.13:** Desvios absolutos (observado x simulado) – Vazões nos trechos P-374, P-397, P-399 e P-467.

Desvios absolutos	P-374	P-397	P-399	P-467
	(L/s)	(L/s)	(L/s)	(L/s)
médio	0,30	0,30	0,20	1,40
máximo	7,11	9,24	3,74	93,40
mínimo	0,00	0,00	0,00	0,00

Verifica-se que as variações dos desvios absolutos médios das potências dos conjuntos de bombeamento, dos níveis dos tanques, das pressões nos nós e das vazões nos trechos são relativamente pequenos, o que demonstra uma boa generalização do modelo por parte da RNA. No entanto a exceção fica por conta da vazão no trecho P-467.

Em análise a este trecho específico no simulador hidráulico EPANET, verifica-se que se trata de um tubo que conecta dois distritos de abastecimento (DMA-1 a DMA-2). Verifica-se a ocorrência de grandes oscilações nos fluxos de abastecimento (vazões) ora em um sentido, ora em outro sentido, regido conforme a incidência da distribuição espacial das demandas de abastecimento.

Este fato demonstra que vazões são elementos que necessitam ser verificados através de simulação hidráulica convencional. Nesse contexto, devem ser cuidadosamente avaliados os critérios e as precisões desejadas do ponto de vista da simulação por RNA. As discrepâncias verificadas para vazões no trecho P-467, ocorreram em razão da existência do elemento de controle denominado “válvula V2” no SDDA WDSA. A referida válvula obedece a uma regra operacional específica, cujo status de funcionamento não foi alvo da presente pesquisa.

A seguir são apresentados os valores de bias ( $b_{ij}$ ) e dos pesos ( $W_{ij}$ ) obtidos para a arquitetura [17,60,20] considerando-se 5.000 ciclos de treinamento e taxa de aprendizagem igual a 0,4 que produziu os ajustes representados nos gráficos das figuras 5.49 a 5.68. Os valores foram extraídos do programa Scilab, utilizando-se o comando “load” para leitura do arquivo de backup denominado ‘arquitetura RNA[17-60-20].bak’. Sequencialmente aplicou-se o comando “W” (peso) para obtenção dos valores ajustados de bias e pesos.

Devido às dimensões da tabela, a mesma foi dividida em doze partes assim compostas:

Pesos e bias da camada de entrada para camada intermediária:

- (A1): Neurônios de 1 a 9 (camada de entrada) e de 1 a 20 (camada intermediária);
- (A2): Neurônios de 10 a 17 (camada de entrada) e de 1 a 20 (camada intermediária);

- (B1): Neurônios de 1 a 9 (camada de entrada) e de 21 a 40 (camada intermediária);
- (B2): Neurônios de 10 a 17 (camada de entrada) e de 21 a 40 (camada intermediária);
- (B3): Neurônios de 1 a 9 (camada de entrada) e de 41 a 60 (camada intermediária);
- (B4): Neurônios de 10 a 17 (camada de entrada) e de 41 a 60 (camada intermediária).

Os bias encontram-se na primeira coluna das planilhas (A1), (A2), (B1), (B2), (B3) e (B4).

**Tabela 5.14:** Valores de bias e pesos ajustados das ligações sinápticas: neurônios da camada de entrada para camada intermediária - (A1), (A2), (B1), (B2), (B3), (B4) – arquitetura [17,60,20].

Bias (bij)	PESOS (Wij)									
1	NEURÔNIOS	1	2	3	4	5	6	7	8	9
-13,8133	1	0,0367	-0,1862	6,4446	-0,0195	-0,0536	-0,0463	1,0561	-0,0277	0,0274
-17,3656	2	0,0305	-0,2175	10,5374	-0,0280	-0,0765	-0,0384	-0,7023	-0,0175	0,0388
-0,3294	3	-0,0440	0,0061	0,0203	-5,2521	-0,5149	0,0776	0,0020	-0,0115	0,0166
-3,2466	4	-0,2165	-0,5195	0,0434	-0,0500	-0,0539	0,0245	-0,2281	-0,0121	0,0111
-0,5681	5	0,0448	-0,0108	-0,0112	0,1137	-5,7014	0,0104	0,0067	-0,0088	3,3574
-1,4440	6	0,1282	-0,0162	-0,0005	-5,5006	0,9226	-0,0919	-0,0094	0,0066	0,0017
-9,1025	7	-0,0455	0,1036	-3,6216	0,0070	-0,0171	0,0220	-1,0022	0,0168	0,0370
0,8426	8	0,0312	-0,0973	-4,2776	-0,0026	0,0009	-0,0344	0,1134	-0,0200	-0,0090
-3,4887	9	1,7099	-0,0449	-0,0479	-0,5751	-1,1309	-1,4613	-0,0991	-0,0347	-0,0174
2,6104	10	-4,2409	-0,0276	-0,0353	-0,0226	-0,0910	0,0733	0,0282	0,0253	0,0470
-5,7973	11	-0,0136	0,0165	0,0057	-0,0257	1,0922	-0,0008	-0,0127	-0,0270	-4,5172
6,5606	12	2,1265	2,5774	2,0634	-0,1028	-0,1430	-0,8614	1,0994	0,2514	-0,2374
0,7999	13	0,0214	-4,8829	-0,1983	0,0086	-0,0181	-0,0350	-0,0658	1,2944	0,0015
-1,2074	14	0,0128	0,3048	0,5226	-1,0225	-1,8033	-1,6019	-0,1636	-0,0641	-0,1011
-8,9892	15	-0,1546	-0,0167	0,0267	0,0390	13,8175	0,1350	-0,0050	0,0198	2,6825
0,1970	16	0,0616	1,5551	3,6711	0,0707	-0,0312	0,2794	0,7047	0,1952	-0,0107
-0,9058	17	0,0412	-0,1708	-0,2695	0,0005	-0,1064	0,0104	-0,0447	1,8749	0,0388
-2,6990	18	-0,7611	-0,6155	-0,1230	0,0006	0,0893	0,1785	-0,7026	-0,1085	-0,0151
-3,9567	19	2,8559	7,2664	1,1913	-0,1190	1,1489	0,2149	0,6333	-0,8422	-1,0199
-8,5546	20	-0,0388	0,0230	0,0150	-4,9686	-0,1576	0,0063	0,0145	0,0583	-0,0228

(A1)

Bias (bij)	PESOS (Wij)								
1	NEURÔNIOS	10	11	12	13	14	15	16	17
-13,8133	1	0,0054	0,0273	0,1518	-0,0736	16,3981	-0,0272	0,0292	-0,0190
-17,3656	2	-0,0117	0,0185	0,1150	-0,0585	21,7035	-0,0717	0,0107	-0,0153
-0,3294	3	-0,0667	0,0285	-0,0544	-0,0080	0,0043	0,0120	-0,0001	-0,0037
-3,2466	4	0,0124	-0,1463	3,5484	-0,2214	0,6069	0,0034	0,0182	-0,0132
-0,5681	5	0,0221	0,0464	0,0351	-0,0335	-0,0117	-0,0668	-0,3953	-0,7408
-1,4440	6	0,0074	0,1046	0,0642	-0,0042	0,0106	-0,0346	-0,0072	-0,0208
-9,1025	7	-0,0244	-0,0596	-0,1263	-0,0258	9,3495	-0,0138	-0,0112	-0,0145
0,8426	8	-0,0011	0,0142	0,1444	0,0316	0,0992	-0,0029	0,0054	0,0099
-3,4887	9	-0,0391	0,7756	0,7755	0,1992	0,2335	0,1915	-0,0072	0,0153
2,6104	10	0,0249	-0,0757	-0,0708	-0,0609	-0,0410	-0,0966	-0,0136	-0,0739
-5,7973	11	-0,0238	0,0029	-0,0186	0,0391	0,0438	0,1005	0,8013	5,0945
6,5606	12	0,0852	1,1665	-41,4327	-1,5232	-2,0765	0,1397	-0,1921	0,3164
0,7999	13	0,0099	0,0311	0,0800	-0,1721	-0,0057	0,0065	-0,0039	-0,0013
-1,2074	14	-0,0219	-0,3858	-6,9307	0,3102	0,2745	0,3106	-0,0097	0,1089
-8,9892	15	0,0078	-0,1241	-0,0737	-0,0075	-0,0035	-0,1311	0,0929	-6,5751
0,1970	16	-0,0615	0,4180	-23,7217	-1,0390	-2,6269	-0,1803	-0,0863	-0,1735
-0,9058	17	0,0113	0,0456	-0,0558	-0,3711	-0,0318	-0,0014	-0,0224	-0,0056
-2,6990	18	-0,0235	-0,3482	11,1726	0,6116	1,2011	0,0505	0,0688	-0,0120
-3,9567	19	-0,6133	-1,8399	-15,0389	2,6417	-1,2452	-0,4160	0,0316	0,2252
-8,5546	20	-4,8922	-0,0780	0,0215	0,0055	0,0024	11,9210	-0,0084	-0,0741

(A2)

Bias (bij)	PESOS (Wij)									
1	NEURÔNIOS	1	2	3	4	5	6	7	8	9
-6,3291	21	0,0571	-0,2403	5,5004	-0,0151	0,0586	0,0004	-8,0939	-0,0238	-0,0430
-3,7315	22	-0,0021	-9,8793	-0,0178	-0,0093	-0,0066	-0,0002	-0,0254	-0,0778	-0,0029
-4,0998	23	-0,0568	1,7486	0,2102	0,0465	-0,0951	0,0193	-0,3337	0,0100	0,0305
-13,3151	24	-0,0062	0,0213	0,0067	6,4471	-0,2462	-0,0416	0,0123	0,1312	-0,0618
4,9277	25	0,0771	0,0542	-0,0173	-0,2151	-9,7381	-0,1483	-0,0065	-0,0520	-8,0678
-3,0322	26	0,1124	0,1101	0,0288	5,2534	-0,3974	-0,1009	-0,0066	-0,0182	0,0055
1,2696	27	-0,0735	-0,0411	0,0114	0,0209	-7,4632	0,0769	0,0087	-0,0073	2,9507
2,1168	28	-2,2845	0,5157	-0,4293	0,9080	-4,4474	1,4264	-1,5994	2,3761	0,1362
4,9311	29	0,0251	-0,0719	-10,3617	-0,0028	0,0558	-0,0319	-4,5310	-0,0201	-0,0350
2,8342	30	0,4716	0,4222	4,5271	0,2216	-0,2309	0,3110	0,7275	0,3789	0,1415
-1,2842	31	-0,0225	0,0100	0,0034	0,0876	-11,2191	0,0843	0,0165	0,0193	4,4291
-20,9590	32	-0,0987	-0,1080	-0,0899	14,1909	0,0544	-0,0174	0,0050	0,0221	0,0275
-1,2337	33	-3,5013	0,2518	0,1349	0,2560	0,3789	2,4259	0,1499	0,0833	0,1570
-1,8058	34	-0,0198	0,0038	0,0140	-0,0080	0,6388	0,0105	0,0011	-0,0076	-0,0760
-3,3543	35	3,5055	0,0027	-0,0239	0,0069	-0,0094	0,1770	0,0208	-0,0072	0,0323
20,5843	36	0,0303	0,1338	0,0645	-15,1014	-0,0665	0,0610	0,0041	-0,0232	0,0015
-2,5552	37	0,0176	-0,0262	-0,0131	0,0486	-0,9192	0,0109	-0,0141	0,0029	0,6297
5,9956	38	0,0339	2,7657	3,2146	-0,0177	0,2038	0,2314	0,5624	0,3519	-0,1509
0,5890	39	0,0629	-0,0196	-0,0428	-4,8203	0,0586	-0,0336	-0,0032	0,0232	-0,0172
2,6658	40	0,0338	-0,8821	-0,0620	0,0036	-0,0313	0,0030	0,0283	0,1941	0,0126

(B1)

Bias (bij)	PESOS (Wij)								
1	NEURÔNIOS	10	11	12	13	14	15	16	17
-6,3291	21	-0,0061	0,0597	0,1271	0,1335	2,5824	-0,0126	0,0032	0,0588
-3,7315	22	0,0029	-0,0150	-0,0031	4,7960	0,0128	0,0146	-0,0132	0,0184
-4,0998	23	-0,0158	-0,1545	0,7018	3,0604	0,4232	0,0340	-0,0175	-0,0079
-13,3151	24	-6,8030	-0,0603	0,0502	-0,0088	-0,0256	17,2077	-0,0332	-0,0949
4,9277	25	-0,0446	0,0759	0,0213	0,1095	-0,0025	0,1488	0,0814	0,9776
-3,0322	26	-4,5643	0,1160	0,0798	0,1294	0,0374	-4,4261	0,0281	-0,0504
1,2696	27	0,0018	-0,0728	-0,0206	-0,0433	0,0040	-0,1264	-0,2715	-6,9666
2,1168	28	0,7706	-4,6806	-4,3532	0,0861	0,3668	-9,5642	-1,1603	-2,7421
4,9311	29	0,0287	0,0478	0,0201	-0,0192	-0,8721	-0,0032	0,0186	0,0350
2,8342	30	-0,0046	-0,2158	-20,7496	-1,1767	-9,0523	0,1167	-0,0880	-0,1177
-1,2842	31	0,0414	-0,0132	-0,0300	-0,0259	-0,0134	-0,1925	-0,5175	0,8793
-20,9590	32	0,3898	-0,1272	-0,0333	-0,1297	-0,1221	21,8664	-0,0329	0,0050
-1,2337	33	0,0287	-2,8807	-1,4874	-0,2464	-0,3872	-0,2204	-0,1028	-0,2216
-1,8058	34	0,0080	-0,0136	-0,0100	0,0068	0,0148	-0,0270	-3,7090	0,8849
-3,3543	35	0,0265	-3,3603	-0,1083	-0,0294	-0,0590	-0,0769	-0,0167	-0,0834
20,5843	36	0,9586	0,0509	0,0289	0,1562	0,0911	-22,4386	0,0528	-0,1002
-2,5552	37	-0,0173	0,0026	0,0006	-0,0267	0,0059	0,0830	2,3573	-0,7968
5,9956	38	-0,0276	-0,1532	-49,2425	-0,8869	4,2096	-0,3513	-0,1566	0,0850
0,5890	39	3,8522	0,0642	-0,0007	-0,0239	-0,0363	-6,1235	-0,0022	0,0007
2,6658	40	0,0044	0,0776	0,0527	-10,6156	-0,0829	-0,0130	0,0206	-0,0190

(B2)

Bias (bij)	PESOS (Wij)									
1	NEURÔNIOS	1	2	3	4	5	6	7	8	9
-0,3922	41	-0,02931	0,014021	0,012857	0,6799	-8,4271	0,0105	0,0031	0,0043	-0,8360
-1,4908	42	0,441402	0,44796	-2,02298	-5,5912	1,7124	2,1976	0,6698	0,5526	0,1027
-9,2082	43	0,085357	0,082653	-0,00291	-0,1538	2,3489	-0,1009	0,0677	0,0463	-2,5120
-15,5737	44	0,082449	0,179417	-0,02995	-0,1635	3,2471	-0,1402	0,1112	0,1154	-3,6737
1,7697	45	-0,00044	0,071817	-3,48041	0,0017	0,0013	-0,0128	1,6001	0,0095	-0,0009
-8,4840	46	-0,07958	-0,09899	-13,8712	-0,0023	0,0122	0,0222	-17,4814	-0,0749	0,1087
0,5646	47	0,224598	-0,01101	-0,02589	-1,4703	-5,6766	-0,1856	-0,0094	-0,0091	0,0975
-12,0596	48	0,007803	0,052455	9,958035	-0,0216	-0,0279	-0,0165	5,1915	-0,0059	0,0125
25,1423	49	0,084447	6,009064	4,906998	0,1265	0,5616	0,2068	2,4685	0,9097	-0,3644
5,3810	50	-5,4112	1,91825	1,622787	0,4766	0,7844	2,1869	0,8306	0,0502	-0,1780
-6,4267	51	0,133093	0,005797	0,006955	-0,1495	-0,1665	-1,0693	-0,0658	0,0025	-0,0803
-2,7184	52	0,068342	-0,02986	-0,01805	-3,1527	0,0017	-0,0355	0,0018	0,0014	-0,0029
14,8335	53	0,080785	0,045233	0,060934	0,0195	-14,5285	-0,0338	0,0042	0,0184	0,3324
1,5479	54	2,053451	-8,03428	-1,40709	0,0284	-1,0184	0,2151	0,5695	0,0903	0,5622
-4,6080	55	-7,21877	0,032297	0,071676	0,1730	0,3168	0,7271	0,0280	0,0041	-0,0267
-0,7952	56	0,360046	-1,21112	-0,39167	-0,2808	0,0318	0,3127	-0,1014	0,4295	0,1952
-0,1838	57	0,054455	-10,7724	-0,18606	-0,0012	-0,0580	-0,0092	-0,0088	0,3987	0,0205
-19,5587	58	0,090795	-0,12167	0,027175	-0,1317	23,7495	-0,1138	-0,0608	-0,0355	-13,8827
0,9469	59	-0,10676	0,044451	-0,01617	-1,0671	-0,1015	0,0645	0,0109	-0,0023	0,0530
16,7676	60	0,067518	0,026566	0,060221	0,0330	-19,1220	0,0068	-0,0143	0,0251	2,0210

(B3)

Bias (bij)	PESOS (Wij)								
	1	NEURÔNIOS	10	11	12	13	14	15	16
-0,3922	41	-0,0116	0,0266	-0,0344	0,0108	0,0168	0,0649	-0,0273	-0,0158
-1,4908	42	1,2851	-0,7423	-2,8289	0,1032	-2,2189	-4,3494	0,2487	-0,0609
-9,2082	43	0,0667	0,1200	0,0527	0,0943	-0,0421	-0,1558	10,2436	-1,1470
-15,5737	44	0,0697	0,0928	0,0915	0,2701	-0,1016	-0,1251	14,8777	-1,2986
1,7697	45	-0,0004	-0,0205	-0,0529	-0,0268	-5,5368	0,0021	0,0125	-0,0079
-8,4840	46	0,0375	-0,0629	0,0124	-0,0797	25,4511	-0,0844	0,0869	-0,0206
0,5646	47	-0,0157	0,1475	0,1043	0,0271	-0,0097	-0,0199	-0,0787	-0,0213
-12,0596	48	-0,0102	-0,0226	-0,0035	-0,0307	1,3254	-0,0404	0,0069	-0,0253
25,1423	49	-0,1995	-0,2997	-102,2438	-3,2810	-7,3713	-0,1023	-0,2455	0,1579
5,3810	50	-0,0155	-1,5779	-25,5651	-1,2299	-2,7410	-0,2309	-0,1588	-0,0503
-6,4267	51	-0,0769	5,6402	0,4904	0,1025	0,1559	0,2044	0,0343	0,1836
-2,7184	52	2,1323	0,0765	0,0203	-0,0182	-0,0085	-0,2834	-0,0065	0,0131
14,8335	53	-0,0194	0,0886	0,0112	0,0773	0,0903	0,0492	-0,2648	-19,9922
1,5479	54	-0,3794	1,1173	-4,1142	-5,7097	-2,1241	-0,0403	-0,3628	0,0218
-4,6080	55	-0,0154	3,6354	-0,3660	-0,0629	-0,0657	0,0230	-0,0009	0,0828
-0,7952	56	0,3468	-0,9066	-11,2037	-0,0632	0,7983	-0,5985	-0,0742	-0,2403
-0,1838	57	-0,0072	0,0558	0,0545	-0,9636	-0,0415	0,0070	0,0051	-0,0041
-19,5587	58	-0,0603	0,1506	0,0045	-0,0957	0,1227	0,1097	1,5973	14,3389
0,9469	59	-0,5337	-0,1217	-0,0066	0,0318	-0,0248	-7,0148	0,0123	-0,1830
16,7676	60	-0,0115	0,0619	0,0004	0,0457	0,0745	-0,0313	-0,4699	-22,3387

(B4)

Pesos e bias da camada intermediária para saída:

- (C1): Neurônios de 1 a 20 (camada intermediária) e de 1 a 10 (camada de saída);
- (C2): Neurônios de 1 a 20 (camada intermediária) e de 11 a 20 (camada de saída);
- (D1): Neurônios de 21 a 40 (camada intermediária) e de 1 a 10 (camada de saída);
- (D2): Neurônios de 21 a 40 (camada intermediária) e de 11 a 20 (camada de saída);
- (D3): Neurônios de 41 a 60 (camada intermediária) e de 1 a 10 (camada de saída);
- (D4): Neurônios de 41 a 60 (camada de entrada) e de 11 a 20 (camada de saída).

Os bias encontram-se na primeira linha das planilhas (C1), (C2), (D1), (D2), (D3) e (D4).

**Tabela 5.15:** Valores de bias e pesos ajustados das ligações sinápticas: neurônios da camada de entrada para camada intermediária - (C1), (C2), (D1), (D2), (D3), (D4), arquitetura [17,60,20].

Bias (bij)	1	3,1417	-0,0850	1,5467	2,2457	0,0100	1,3482	-3,0668	0,2723	0,3818	1,4827
PESOS (Wij)	NEURÔNIOS	1	2	3	4	5	6	7	8	9	10
	1	0,0283	-0,0006	-0,0025	0,0023	-0,0042	0,0269	0,4479	0,0124	-1,8966	0,0056
	2	-0,0183	-0,0046	0,0351	0,0012	0,0043	-0,0212	-0,3158	-0,0105	1,4898	-0,0040
	3	0,1426	0,0939	0,0708	-11,5284	-0,2453	0,1199	0,0392	-0,0587	-0,0741	1,1973
	4	-0,2334	0,0300	0,2403	0,0457	0,0917	-0,2339	5,6845	0,1854	-0,0176	-0,0195
	5	0,0886	-0,0697	-0,0073	0,0330	-0,2953	0,0150	-0,0353	0,0187	0,0049	-0,0393
	6	-0,2470	-0,1492	-0,1204	-7,5855	0,1703	0,0589	-0,1302	0,0310	0,0565	0,9462
	7	-0,1244	0,0268	1,1214	-0,0028	0,0289	-0,0547	-1,1683	-0,0292	6,0827	-0,0362
	8	0,0270	0,0475	-6,8692	-0,0019	0,0261	-0,0143	-0,1089	0,0380	1,6350	-0,0007
	9	1,6184	0,3101	0,1892	-0,8579	-0,4539	-0,6288	0,0825	-0,0047	-0,0419	0,0144
	10	-6,0347	0,0775	0,0105	-0,0430	0,0051	-1,6391	-0,3360	-0,0333	0,0125	0,0411
	11	-0,0632	-0,0281	0,0092	0,0715	-0,7679	-0,2289	-0,0669	0,0292	0,0255	-0,1107
	12	-0,1187	0,0166	0,0037	-0,0154	0,0392	-0,2153	0,7277	0,0176	0,0194	-0,0093
	13	-0,0049	-6,5444	0,2424	-0,0150	0,0011	0,0159	0,4411	-0,5020	0,1068	-0,0156
	14	0,4873	0,2756	0,1550	0,1080	0,0097	-0,6042	1,2534	0,1509	0,1003	0,0878
	15	0,0303	0,0225	0,0051	0,0098	2,1763	0,0094	0,0253	-0,0065	-0,0002	0,0011
	16	-0,1787	-0,0618	-0,1043	-0,0533	0,0706	-0,1339	-0,1030	-0,0013	0,0006	-0,0138
	17	0,0728	3,6677	-0,1520	-0,0159	-0,0145	-0,0048	-0,3626	-0,1801	-0,0817	0,0320
	18	-0,0539	0,1209	0,0856	-0,0132	-0,0053	-0,0921	1,6315	0,0388	0,0225	-0,0028
	19	-0,0593	0,1399	0,0430	-0,0057	-0,0304	0,0407	-0,1593	-0,0030	0,0284	0,0080
20	-0,0296	-0,0072	0,0161	-0,1746	0,0277	-0,5185	-0,0067	-0,0111	-0,0102	7,0680	

(C1)

Bias (bij)	1	-0,2245	-0,0140	1,7510	-0,0861	0,3681	1,0450	-0,2222	0,8612	0,3185	-0,5211
PESOS (Wij)	NEURÔNIOS	11	12	13	14	15	16	17	18	19	20
	1	0,0037	0,0124	0,0055	0,0083	0,0188	-1,0854	-0,0170	0,0035	-0,0011	-0,1712
	2	-0,0036	-0,0071	-0,0063	-0,0068	-0,0209	0,8665	0,0035	-0,0032	-0,0015	0,1324
	3	0,1717	-0,0380	1,9288	0,0692	1,3677	0,0686	0,0793	0,2299	-0,5389	-0,0917
	4	-0,0093	0,0022	-0,0375	-0,0098	-0,4555	0,2076	0,3600	-0,0837	-0,0739	0,1761
	5	-1,5053	-3,4527	-0,0367	-3,5876	-0,1805	0,0165	-0,0806	0,3055	0,5831	0,0004
	6	-0,0253	0,4846	1,3789	0,5637	1,3107	-0,0894	-0,1610	-5,7833	1,9594	-0,0083
	7	0,0340	-0,0129	-0,0361	0,0027	-0,1172	2,8796	0,1067	-0,0408	-0,0519	0,9936
	8	-0,0059	-0,0316	0,0094	0,0016	-0,0912	-4,6297	0,0717	-0,0538	-0,0322	0,0567
	9	0,1965	0,2301	0,2017	0,3324	4,1843	0,1674	0,1707	1,5943	0,4667	0,0873
	10	0,0267	-0,0275	0,0402	-0,0440	0,0290	0,0249	0,0915	-0,0488	-0,0168	0,0062
	11	2,0439	7,1719	-0,0826	4,0228	-0,0350	0,0059	-0,0677	-0,3899	0,0706	-0,0891
	12	-0,0159	-0,0331	-0,0145	-0,0307	-0,1846	0,0380	0,0367	-0,0390	-0,0242	1,8811
	13	-0,0344	0,0089	0,0088	0,0251	-0,0053	0,2069	-4,2611	0,0314	-0,0436	-0,2876
	14	-0,0375	0,0209	0,1674	0,0111	-2,5399	0,1578	0,4402	0,3584	0,1619	0,7807
	15	-0,2417	-2,1857	-0,0180	-1,5779	-0,3639	0,0027	0,0191	0,8791	1,2923	-0,0322
	16	0,0088	-0,0170	-0,0371	-0,0277	-0,3044	-0,0026	-0,0659	-0,1049	-0,0823	3,6768
	17	0,0075	-0,0139	0,0115	-0,0152	0,0280	-0,1611	3,5821	-0,0105	0,0159	0,1419
	18	0,0016	0,0006	0,0003	-0,0011	-0,0644	0,0919	0,1665	0,0005	0,0028	-0,3763
	19	0,0108	0,0122	0,0138	0,0121	0,1398	0,0610	0,1474	0,0263	0,0159	-0,7130
20	-0,1805	-0,3113	5,0211	-0,2848	-0,2716	0,0108	-0,0162	0,1870	0,0235	-0,0415	

(C2)

Bias (bij)	1	3,1417	-0,0850	1,5467	2,2457	0,0100	1,3482	-3,0668	0,2723	0,3818	1,4827
PESOS (Wij)	NEURÔNIOS	1	2	3	4	5	6	7	8	9	10
	21	-0,0319	-0,0327	-1,0799	0,0208	0,0147	-0,0270	-0,1703	0,0035	0,4620	0,0129
	22	-0,0857	0,0240	0,0191	0,0112	0,0009	-0,0657	-1,4583	6,3528	-0,1984	-0,0034
	23	-0,0012	0,7350	-0,0211	-0,0301	0,0257	-0,0307	2,6898	-0,7029	0,2629	0,0179
	24	-0,0111	0,0062	-0,0165	0,1184	-0,0139	0,3857	-0,0041	0,0105	0,0192	-4,1092
	25	0,0430	0,0152	0,0008	0,0059	0,2296	-0,0206	0,0019	0,0036	-0,0019	0,0006
	26	-0,0178	0,0028	0,0009	0,0240	-0,0090	-0,0133	0,0036	0,0105	0,0050	1,0661
	27	0,3359	-0,0211	-0,0139	-0,0890	-3,1320	0,2046	0,0117	-0,0014	-0,0167	0,0584
	28	-0,5119	-0,0353	-0,2236	0,8214	-0,1220	0,1210	-0,0972	0,1458	0,1877	-0,5287
	29	-0,0560	-0,0115	0,0557	0,0189	0,0148	-0,0181	-0,3483	0,0688	2,5484	-0,0035
	30	0,0429	0,0156	0,1492	0,0239	-0,0343	0,0313	0,0093	0,0018	0,0303	0,0016
	31	0,0076	0,0206	0,0059	-0,0185	-0,4439	-0,0431	-0,0029	0,0092	-0,0033	0,0055
	32	0,0289	0,0053	-0,0010	0,0214	0,0218	0,2246	-0,0037	0,0108	0,0283	-1,9538
	33	-1,8757	-0,6781	-0,5532	-0,2924	0,3658	-1,7964	-0,3493	-0,1027	-0,1681	-0,0841
	34	0,0625	-0,0532	0,0104	0,0363	-0,1789	0,0114	0,0364	0,0013	-0,0141	0,0156
	35	-0,2986	-0,0092	-0,0166	-0,0896	0,0808	-7,6966	-0,3555	-0,0545	-0,0020	0,0604
	36	0,0446	0,0097	-0,0018	0,0215	0,0159	0,1848	-0,0075	-0,0024	0,0254	-1,9892
	37	0,0116	0,0102	-0,0106	0,0334	-0,3423	-0,0521	-0,0841	0,0691	0,0211	0,0130
	38	0,1099	-0,0204	-0,0256	0,0327	-0,0232	-0,0122	0,1360	0,0023	0,0462	0,0032
	39	0,1493	0,0006	0,0126	0,0004	-0,0085	0,0738	0,0303	0,0173	-0,0086	-3,0727
40	0,0415	0,1476	-0,0220	-0,0032	-0,0010	0,0224	0,4231	-2,8336	0,0545	-0,0022	

(D1)

Bias (bij)	1	-0,2245	-0,0140	1,7510	-0,0861	0,3681	1,0450	-0,2222	0,8612	0,3185	-0,5211
PESOS (Wij)	NEURÔNIOS	11	12	13	14	15	16	17	18	19	20
	21	0,0162	-0,0107	0,0316	0,0160	-0,0034	3,6844	0,0379	-0,0056	-0,0539	-0,0083
	22	0,0519	-0,0017	-0,0122	-0,0480	-0,0468	-0,1038	-0,2039	-0,0550	0,0384	0,5340
	23	-0,0573	-0,0663	-0,0055	-0,0109	-0,0742	0,1359	-0,3358	0,0433	-0,0708	-0,7702
	24	0,1151	0,2327	-2,6974	0,2114	0,1816	-0,0146	0,0073	-0,1275	-0,0203	0,0293
	25	0,2288	1,0962	0,0031	1,9079	0,0520	-0,0015	0,0091	-0,1585	-0,1717	0,0015
	26	-0,0087	0,0132	2,0699	0,0059	0,1124	0,0056	-0,0170	-0,1997	0,0431	-0,0900
	27	-1,5127	-6,8064	0,0956	-4,4918	0,6049	0,0088	-0,0238	-1,0044	-1,7980	0,0693
	28	0,0104	0,1451	-0,1954	0,1455	-0,5882	0,0940	-0,1960	-0,2655	-0,0383	4,8938
	29	-0,0141	0,0243	0,0128	0,0134	-0,0241	4,0865	-0,0048	0,0012	-0,0133	0,0928
	30	-0,0063	-0,0001	0,0056	0,0097	0,1612	0,1237	0,0217	0,0360	0,0358	-1,3917
	31	0,7582	2,8502	0,0375	1,7992	0,3532	-0,0038	0,0250	-0,3234	-1,2176	0,0395
	32	0,0350	0,1180	-2,1098	0,0896	-0,0282	0,0063	0,0076	0,1457	-0,0076	-0,0822
	33	-0,0762	-0,2384	-0,2749	-0,2453	-2,7122	-0,5262	-0,8811	-1,1595	-0,8204	0,8609
	34	-7,8397	0,2424	0,0282	0,1270	0,0196	0,0154	-0,0362	0,0612	0,0003	-0,0136
	35	0,0129	-0,0612	0,0257	-0,0913	-0,4137	0,0088	0,0291	-0,1632	-0,1087	-0,0028
	36	0,0390	0,1076	-2,0737	0,0776	-0,0179	0,0065	0,0016	0,1452	-0,0085	-0,0684
	37	6,4998	0,0121	0,0263	0,0242	0,0694	0,0187	0,0242	-0,1004	-0,1779	-0,0485
	38	0,0020	0,0083	0,0090	0,0176	0,1625	-0,0248	-0,0484	0,0321	0,0224	-1,6001
	39	0,0489	0,0233	-3,4143	0,0206	0,0233	0,0257	-0,0163	0,1278	0,0263	-0,1545
40	-0,0084	-0,0054	0,0018	0,0086	0,0258	0,0188	-0,0764	0,0232	-0,0128	-0,1623	

(D2)

Bias (bij)	1	3,1417	-0,0850	1,5467	2,2457	0,0100	1,3482	-3,0668	0,2723	0,3818	1,4827
PESOS (Wij)	NEURÔNIOS	1	2	3	4	5	6	7	8	9	10
	41	-0,0236	-0,0387	0,0150	-0,1696	-5,3350	0,1164	0,0081	-0,0253	-0,0087	0,0953
	42	-0,0808	0,1264	0,0764	-0,6559	0,2557	-0,0463	-0,0861	0,1183	-0,0017	0,2720
	43	-0,0198	0,0022	0,0055	-0,0043	0,1253	0,0030	0,0089	-0,0290	-0,0078	0,0100
	44	0,0065	0,0217	0,0214	-0,0525	0,3650	-0,0170	-0,0289	0,0340	0,0375	-0,0635
	45	0,1159	0,0104	0,3897	0,0088	-0,0016	0,0550	0,9084	0,0188	-5,7368	0,0175
	46	0,0572	0,0086	0,2607	-0,0112	-0,0226	0,0207	0,4914	-0,0315	-2,9665	0,0146
	47	-0,2247	-0,1001	-0,0399	0,2027	-1,8365	0,1231	-0,0834	0,0007	0,0283	-0,0489
	48	0,0107	-0,0073	0,7136	0,0062	0,0056	-0,0046	0,0272	-0,0234	-0,4117	-0,0060
	49	-0,1174	0,0727	0,0613	0,0029	0,0394	-0,0064	-0,0474	0,0049	-0,0090	0,0022
	50	0,1279	0,0278	-0,0126	-0,0123	-0,0114	0,0618	-0,4421	-0,0110	-0,0118	-0,0036
	51	-1,4589	-0,0681	-0,0396	0,1066	-0,2066	5,8419	0,2046	-0,0149	-0,0379	-0,0398
	52	-0,1817	0,0180	-0,0076	-0,7693	-0,0212	-0,1310	-0,1022	-0,0435	0,0335	4,8827
	53	0,0210	-0,0051	-0,0005	-0,0132	0,0981	-0,1042	0,0061	0,0065	-0,0085	-0,0468
	54	0,2201	-1,1428	0,0944	-0,0470	-0,0613	0,1524	0,4443	-0,0105	-0,1232	-0,1067
	55	1,3710	-0,0256	-0,0008	-0,0783	0,2431	4,6296	0,2119	0,0897	0,0521	-0,0458
	56	-0,7032	-0,4185	-0,1717	-0,1907	-0,1606	-0,2511	0,6603	-0,0899	-0,0924	-0,0075
	57	0,1248	3,8438	-0,3166	0,0551	0,0019	0,0018	0,6044	-3,0426	-0,0118	0,0432
	58	-0,3112	0,0409	0,0045	0,0068	0,0543	0,3739	0,1223	-0,0184	0,0159	0,2265
	59	0,0958	-0,0139	0,0072	-0,0695	-0,0235	-0,0185	0,0406	-0,0127	-0,0280	-4,2431
60	-0,0202	0,0054	0,0016	0,0252	-0,0946	0,0943	-0,0023	0,0017	0,0081	0,0459	

(D3)

Bias (bij)	1	-0,2245	-0,0140	1,7510	-0,0861	0,3681	1,0450	-0,2222	0,8612	0,3185	-0,5211
PESOS (Wij)	NEURÔNIOS	11	12	13	14	15	16	17	18	19	20
	41	-0,8126	-2,1819	0,2355	-3,6813	1,3397	0,0188	-0,0164	0,2796	-4,7317	-0,0847
	42	0,0633	0,1688	0,4185	0,0565	-0,4308	-0,1076	0,3112	-0,1085	-0,0018	2,8264
	43	2,1630	-0,3758	-0,0140	-0,5580	-0,0818	-0,0036	0,0092	0,0173	0,0465	0,1471
	44	-3,3284	2,9732	0,0644	4,7904	0,5174	0,0411	-0,0126	-0,5550	-0,8392	-0,5295
	45	0,0008	0,0030	0,0371	0,0035	0,0196	-4,4209	-0,0825	0,0558	-0,0008	0,0603
	46	0,0083	-0,0117	-0,0035	-0,0142	0,0475	-2,0357	0,0201	0,0219	0,0265	-0,1570
	47	-0,5784	-1,2365	-0,1959	-2,1018	-0,2351	-0,0457	-0,0779	-4,8691	-2,4737	0,0691
	48	0,0022	-0,0196	-0,0019	-0,0061	0,0005	-1,4823	-0,0294	-0,0056	-0,0054	-0,0461
	49	0,0027	0,0061	-0,0105	-0,0093	-0,2479	0,0739	0,1755	-0,0444	-0,0445	2,2947
	50	-0,0063	0,0068	0,0033	0,0041	0,0183	-0,0424	-0,0262	0,0185	0,0229	-1,9965
	51	0,0197	0,1264	0,0256	0,1941	1,3479	-0,0856	-0,1262	0,3365	0,1824	0,2618
	52	-0,1053	-0,1383	-1,1556	-0,1154	0,0058	-0,0540	0,0290	-0,1640	-0,1118	0,2362
	53	0,6705	2,5220	-0,0306	1,7839	0,0071	-0,0069	-0,0245	-0,0907	-0,1289	-0,0161
	54	0,0572	0,1175	-0,0076	0,1086	0,3975	-0,1800	1,4448	0,1549	-0,0148	-4,4496
	55	-0,0379	-0,0445	-0,1425	-0,1142	-1,5804	0,0365	-0,0588	-0,3415	-0,2437	-0,4728
	56	0,0064	-0,0218	-0,0047	-0,0119	0,8381	-0,2276	-0,6735	-0,0221	0,0388	-4,7199
	57	0,0247	-0,0225	-0,0110	-0,0418	-0,0023	-0,0792	-4,7566	-0,0339	0,0805	0,2997
	58	-2,1773	-8,3828	0,1883	-6,2725	0,0378	0,0472	0,0770	0,2356	0,1109	0,0259
	59	0,0597	-0,0253	-4,8285	0,0110	-0,0359	-0,0074	0,0275	0,1070	-0,0385	0,0684
60	-0,6379	-2,3138	0,0307	-1,6196	0,0027	0,0014	0,0306	0,0617	0,0899	-0,0341	

(D4)



## 6. Conclusões

Até recentemente o modelo de simulação hidráulica era considerado o único meio disponível para representar o comportamento complexo e não-linear das redes de distribuição de água. No entanto, para prever as consequências de diferentes configurações de controle em relação às condições iniciais e as variações de curto prazo na demanda, os modelos de simulação hidráulica apresentam limitações devido à carga computacional que lhe é imposta.

O presente trabalho perseguiu o objetivo de verificar as potencialidades do emprego das RNAs em substituição aos modelos de simulação hidráulica tradicionais, com vistas à sua utilização futura no problema de operação em tempo real dos sistemas.

Duas RNAs foram construídas: a primeira, Anytown modificada, com o objetivo de reprodução da performance verificada por Rao & Alvarruiz (2007), e uma segunda, WDSA 2010, com grau de complexidade superior e compatível com a de SDAAs existentes.

De uma forma geral, pode-se dizer que tanto o número de neurônios da camada de entrada como dos ciclos de treinamento aumentam o tempo de processamento computacional e não necessariamente reduzem o RMSE da RNA. Ao contrário, os resultados sugerem um melhor desempenho da RNA com menor número de neurônios na camada de entrada. Isso foi verificado quando se tentou uma nova arquitetura para a WDSA em que os status de funcionamento das bombas idênticas foram substituídos pelos números de bombas ativas de cada conjunto elevatório.

### Resultados obtidos para rede Anytown modificada

Para a **rede Anytown modificada** foi investigado o número de padrões de treinamento (entrada/saída), a melhor arquitetura em termos do número de neurônios da camada oculta, bem como a taxa de aprendizagem e o número de ciclos de treinamento necessários. Assim, diversas conclusões foram possíveis: 2000 ciclos de treinamento foram suficientes para que os valores de RMSE dos dados normalizados para os conjuntos de treinamento, validação cruzada e testes, respectivamente, fossem minimizados. Verificou-se ainda que dentre as taxas de aprendizagem 0,2, 0,4, 0,6 e 0,8, o valor 0,4 mostrou-se mais eficiente em reduzir o valor de RMSE.

Os resultados apresentados para a melhor configuração de RNA[5,20,7] modelada no desenvolvimento do presente trabalho produziu o valor 0,64% para RMSE, sugerindo um ajuste

superior àquele atingido por Rao & Alvarruiz (2007) [RMSE=1,67%] para a mesma arquitetura de rede.

### **Resultados obtidos para rede WDSA 2010**

Especificamente no caso do sistema WDSA 2010, ao capturar o conhecimento de um modelo de simulação hidráulica, a RNA é inicialmente utilizada com a função de relacionar dados de entrada [status de funcionamento - ligado / desligado - das 11 bombas e os padrões de demanda dos 5 setores de consumo do sistema para o intervalo de tempo considerado, além dos níveis de água dos 7 tanques de armazenamento no início do intervalo (instante  $t$ )] e saída [potências consumidas pelas 5 estações de bombeamento (um para cada estação de bombeamento), níveis de água dos 7 tanques de armazenamento no final do intervalo de tempo (instante  $t + 1$ ), bem como pressão e vazão em 4 pontos críticos do SDAA], através de uma camada intermediária de neurônios, cujas funções e pesos determinam um modelo alternativo ao primeiro.

Para tanto, foram investigados o número de padrões de treinamento (entrada/saída), a melhor arquitetura em termos do número de neurônios da camada oculta, bem como a taxa de aprendizagem e o número de ciclos de treinamento necessários. Assim, diversas conclusões foram possíveis:

-2000 ciclos de treinamento foram suficientes para que o RMSE dos dados normalizados para os conjuntos de treinamento, validação cruzada e testes respectivamente fosse minimizado para a taxa de aprendizagem 0,4;

- a redução do número de padrões de treinamento não representou um ganho considerável no tempo de processamento computacional e, além disso, fez com que o RMSE médio fosse incrementado.

Entretanto, a análise dos resultados sugere que a arquitetura inicialmente adotada não produzia boa generalização do modelo observado.

Assim, houve necessidade de rever o conceito inicial das variáveis que compunham o número de neurônios na camada de entrada. Alterando-se o status de funcionamento de cada bomba para o número de bombas ativas por conjunto, processaram-se novas simulações, cujos resultados mostraram-se satisfatórios, indicando que não há necessidade de um número de neurônios superior a 60 na camada oculta. Pelo contrário, quanto maior o número de neurônios na camada oculta, maior é o tempo computacional gasto e pouco ou nenhum ganho em termos de diminuição do RMSE foi verificado.

Especial atenção foi direcionada aos pontos de monitoramento da rede WDSA que apresentaram desvios discrepantes em relação aos demais elementos monitorados. Destaca-se aqui que apenas um valor de nível do tanque T-2, e dois valores de pressões em J-302 foram previstos com desvios consideráveis, que devem ser compreendidas, portanto, como uma exceção à regra.

Quanto às vazões no trecho P-467, os desvios absolutos máximos ocorreram em razão da existência do elemento de controle denominado “válvula V2” no SDAA WDSA. A discrepância verificada permite que se conclua que as RNAs são modelos mais adequados às previsões de níveis e pressões que vazões, especialmente quando elementos que podem promover inversões de fluxo fazem-se presentes. Assim especial atenção deve ser dada na presença de elementos de controle desta natureza, principalmente quando se pretende modelar a grandeza vazão. Essa conclusão reforça as conclusões obtidas por Salomons *et al.*(2007), ao reportar os resultados da modelagem via RNAs para a rede da cidade de Haifa, Israel.

Assim, pode-se dizer que as RNAs são poderosas ferramentas que devem ser estudadas e utilizadas cada vez mais para realizar a previsão de pressões e níveis nos reservatórios dos SDAAs.

Recomenda-se que futuras pesquisas avaliem de uma maneira mais precisa e eficiente o comportamento das vazões frente à ocorrência de elementos de controle regidos por regras operacionais específicas, com o objetivo de melhorar o desempenho dos modelos de RNAs.

Pesquisas futuras devem investigar também a função de ativação linear em substituição à sigmóide, usada neste trabalho, para a camada de saída.

## Referências

- [ABNT] Associação Brasileira de Normas Técnicas. NBR 12218: Projeto de rede de distribuição de água para abastecimento público. Rio de Janeiro, julho 1994.
- AINOLA, L.; KOPPEL, T.; TIITER K.; VASSILJEV, A. (2000). Water Network Model Calibration Based on grouping with Similar Leakage and Roughness Estimates. *Proceedings of the joint Conference on Water Resources Engineering and Water Resources Planning and Management*, Minneapolis, MN.
- ALBANO, G. D.(2004) Integração de um Modelo Matemático de Quantidade de Água em Rede de Fluxo ACQUANET) com um Modelo Matemático de Qualidade de Água em Represas (CE-QUALR1). Estudo de Caso: Represa Jaguari-Jacaréi – Sistema Cantareira. Escola Politécnica da Universidade de São Paulo, São Paulo/SP.
- ARAÚJO, J. K.(2002) Calibração de Redes de Distribuição de água pelo método inverso aplicado a escoamento transiente. Escola de Engenharia de São Carlos – USP. São Carlos/SP, 2002. (Tese de Doutorado).
- AZEVEDO, L. G. T. et al. (2000). Integration of Water Quantity and Quality in Strategic River Basin Planning. *Journal of Water Resources Planning and Management*. March/April.
- BRAGA, A. P., CARVALHO, A. C. P. L. F., LUDEMIR, T. B. (2007). Redes Neurais Artificiais: Teoria e Aplicação. 2ª Ed. Rio de Janeiro: Ed. LTC, 2007. Vol. 1. 226 p.
- CALIMAN, R. O. (2002). Determinação dos Parâmetros do Modelo Pressão X Vazamento para Sub-setores da Rede de Distribuição de Água de São Carlos – SP. São Carlos. 110 p. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo, Brasil.
- CHEUNG, P. B. (2001). Investigação dos Métodos Clássicos de Calibração de Redes Hidráulicas. Campo Grande. 132 p. Dissertação (Mestrado). Universidade Federal de Mato Grosso do Sul, Brasil.
- COULBECK, B. (1988). A review of methodologies for modelling and control of water supply. In *Computer Applications in Water Supply. Vol2 systems Optimization and Control* (ed. B. Coulbeck & C. H. Orr), Research Studies Press Ltd, Letchworth, UK, pp. 80-109.
- CUNHA, A. A. R (2009). Otimização Energética em Tempo Real de Sistemas de Abastecimento de Água. Dissertação (Mestrado em Engenharia Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, Conselho Nacional de Desenvolvimento Científico e Tecnológico. Orientadora: Profª. Titular Drª. Luisa Fernanda Ribeiro Reis.
- CYBENKO, G. (1989). “Approximation by superpositions of a sigmoidal function”, *Mathematics of Control, Signals, and Systems*, vol. 2, pp. 303-314.
- DEMOYER, R. & HOROWITZ, L. (1975). *Computer Applications in Water Supply*. Lexington, MA. Research Studies Press Ltd. Letchworth, UK.

- 
- EGGENER, C. L.; POLKOWSKI, L. B. (1976). Network models and the impact of modeling assumptions. *Journal of AWWA: management and operations*, p.189-196, apr.1976.
- FALLSIDE, F. & PERRY, P. F. (1975). Hierarchical optimization of a water-supply network. *Proc.IEE* **122** (2), 202-208.
- FUJIWARA, O.; LI, J. (1998). Reliability Analysis of Water Distribution Networks in Consideration of Equity, Redistribution, and Pressure-Dependent Demand. *Water Resources Research*, v. 34, n. 7, p. 1843-1850, July.
- FUNAHASHI, K. I. (1989). On the approximate realization of continuous mappings by neural networks, *Neural Netw.* 2, pp. 183-192.
- GARCÍA-SERRA, J. (1988). Estudio y mejora de las técnicas de calibración de modelos de redes hidráulicas. 1988. Tese (Doutorado em Engenharia Industrial) – Universidade Politécnica de Valência, Valência, Espanha.
- GOMES, H. P. (2009). Sistemas de Abastecimento de Água: Dimensionamento Econômico e Operação de Redes e Elevatórias. 3ª Ed. – João Pessoa: Ed. Univesitária/UFPB, 2009, p. 11-49, 183-237.
- HAYKIN, S. (2001). Redes Neurais: Princípios e prática. Tradução Paulo Martins Engel. 2ª Ed. – Porto Alegre: Ed. Bookman, 2001, p.27- 40, 63-69, 159-161, 183-188, 239-244, 316-318.
- JAMIESON, D. G., SHAMIR, U., MARTINEZ, F. & FRANCHINI, M. (2007). Conceptual design of a generic, real-time, near-optimal control system for water distribution networks. *J. Hydroinformatics* 9 (1), 3–14.
- JOWITT, P. & GERMANOPOULOS, G. (1992) Optimal pump scheduling in water-supply networks. *J. Wat. Res. Plann Mngmnt.*, ASCE **118** (4), 406-422.
- KOLMOGOROV, A. N. (1957) On the representation of continuous functions of several variables by superimposition of one variable and additions. *Dokl. Akad. Nauk USSR* 114, 369-373.
- LITTLE, K. W. & McCRODDEN, B. J. (1989) Minimization of raw water pumping costs using MILP. *J.Wat. Res. Plann. Mmngmnt*, ASCE 115 (4), 511-522.
- LUVIZOTTO Jr., E., SOLIANI, R., PIZZO, H. S., JAQUIÊ, L. (2000). Análise de técnicas de busca para um modelo de detecção de fugas. In: CONGRESO LATINOAMERICANO DE HIDRÁULICA, 19., 2000, Córdoba. Anais... p.309-318.
- MARTINEZ, F., HERNANDEZ V., ALONSO, J. M., RAO, Z. & ALVISI, S. (2007) Optimizing the operation of the Valencia water-distribution network. *J. Hydroinformatics* 9 (1), 65-78.
- MARTINEZ, F.; SIGNES, M.; SAVALL, R.; ANDRÉS, M.; PONZ, R.; CONEJOS, P. (1999). Construction and Use of Dynamic Simulation Model for the Valencia Water Supply and Distribution Network. In: SAVIC, D. A. (ed); WALTERS, G. A. (ed): *Water Industry Systems: Modeling and Optimization Applications*, vol 1, p.155-174.

- McCULLOCK W. S. & PITTS W. (1943). "A logical calculus of the ideas immanent in nervous activity", *Bulletin of mathematical Biophysics*, vol. 5, p. 115-133.
- ODAN, F. K. (2010). Previsão de demanda para sistemas de abastecimento de água. 77 p. Dissertação (Mestrado em Engenharia Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo. Orientadora: Prof<sup>a</sup>. Titular Dr<sup>a</sup>. Luisa Fernanda Ribeiro Reis.
- ORMSBEE, L. E. LINGIREDDY, S. (1997). Calibrating Hydraulic Network Models. *Journal of the American Water Works Association*, v 89, n 2, p. 42 – 50.
- RAO Z. & ALVARRUIZ F. (2007). Use of an artificial neural network to capture the domain knowledge of a conventional hydraulic simulation model. *Journal of Hydroinformatics*, 09.1 IWA Publishing 2007, p. 15-24.
- ROGERS, L. L. & DOWLA, F. U. (1994). Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling. *Wat. Res. Res.* **30** (2), 457-481.
- ROSSMAN, L. A. (2000) *EPANET User's Manual*. US EPA, Cincinnati OHIO, 2000.
- RUMELHART, D. E. & McCLELLAND, D. E. (1986). *Parallel Distributed Processing*, vol 1 MIT Press, Cambridge, MA.
- SALOMONS, E., GORYASHKO, A., SHAMIR, U., RAO, Z. & ALVISI, S. (2007). Optimizing the operation of the Haifa-A water-distribution network. *Journal Hydroinformatics* **9** (1), 51-64.
- SHAMIR, U.; HOWARD, C. D. D. Engineering analysis of water-distribution systems. *Journal of AWWA: water technology/distribution*, p. 510-514, sep.1977.
- SILVA, Fernando G. B. (2003). Estudos de Calibração de Redes de Distribuição de Água através de Algoritmos Genéticos – Tese de doutorado apresentada a Universidade de São Paulo, Campus de São Carlos. São Carlos/SP.
- SILVA, F. G. B.; REIS, L. F. R.; CALIMAN, R. O.; CHAUDHRY, F. H.; (2002). Análise de Calibração de Redes de Distribuição de Água para Abastecimento Aplicada a setor de Rede Real – Uma Aproximação que Contempla Vazamentos. *Revista ABRH*.
- SOARES, A. K. (2003). Calibração de Modelos de Redes de Distribuição de Água para Abastecimento Considerando Vazamento e Demandas Dirigidas pela Pressão. São Carlos. 153 p. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo, Brasil.
- SOUZA, R. S.(1994). Aspectos Computacionais da Análise de Redes de Distribuição de Água com Componentes Hidráulicos em Regime Permanente, EESC-USP. São Carlos/SP.
- STERLING, M. J. H. & COULBECK, B. (1975). A dynamic programming solution to the optimization of pumping costs. *Proc. ICE* **59** (2), 813-818.
- TABESH, M.; KARIMZADEH, A. (2000). Optimum Design of Reliable Distribution Systems Considering Pressure Dependency of Outflows. In: SAVIC, D. A. (ed.); WALTERS, G.A. (ed.): *Water Network Modeling for Optimal Desing and Management*, p. 211-220.

- TODINI, E. & PILATI, S. A gradient method for the analysis of pipe networks. Procedure of the International Conference on Computers Applications for Water Supply and Distribution. Leicester Polytechnic, Leicester, UK, n. 9, p. 8-10, 1987.
- TUCCI, C. E. M. (1998) (Coordenador). Modelos Hidrológicos. Associação Brasileira de Recursos Hídricos (ABRH). Universidade Federal do Rio Grande do Sul. Porto Alegre/RS.
- TUCCIARELLI, T.; CRIMINISI, A.; TERMINI, D. (1999). Leak Analysis in Pipeline Systems by Optimal Valve Regulation. *Journal of Hydraulic Engineering*, v. 125, n. 3, p. 277-285, Mar.
- TUCCIARELLI, T.; TERMINI, D.(1998). Optimal Valves Regulation for Calibration of Pipe Network Models. *Proceedings, Hydroinformatics 98 Conf.*, Balkema, Rotterdam, The Neurtherlands, p. 1029-1036.
- VALENÇA, M. J. S. (2009). Fundamentos das Redes Neurais: Exemplos em Java. 2ª edição revisada e ampliada. Olinda – PE. Editora Livro Rápido. 348 p.
- WALSKI, T. M. (1990). Sherlock Holmes meets Hardy-Cross or model calibration in Austin, Texas. *Journal of AWWA: management and operations*, p. 34-38, mar.1990.
- WANG, C. G. & JAMIENSON, D. G. (2002). An objective approach to regional wastewater-treatment planning. *Wat. Res. Res.* **38** (3), 4.1-4.

## Anexo 1

### Rede Anytown modificada (arquivo .inp)

[TITLE]

Any Town Model. Initial model for ANN training  
Tank levels unlimited

[JUNCTIONS]

;ID Nudo	Cota	Demanda	Curva de Modulac.
20	6.096	113.56235	DEM ;
30	15.24	45.42494	DEM ;
110	15.24	113.56235	DEM ;
70	15.24	113.56235	DEM ;
60	15.24	113.56235	DEM ;
90	15.24	227.1247	DEM90 ;
100	15.24	113.56235	DEM ;
40	15.24	45.42494	DEM ;
50	15.24	45.42494	DEM ;
80	15.24	113.56235	DEM ;
150	36.576	45.42494	DEM ;
140	24.384	45.42494	DEM ;
170	36.576	45.42494	DEM170 ;
130	36.576	45.42494	DEM ;
160	36.576	181.69976	DEM ;
120	36.576	45.42494	DEM ;
55	24.384	22.71247	DEM55 ;
75	24.384	22.71247	DEM ;
115	24.384	22.71247	DEM ;

[RESERVOIRS]

;ID Nudo	Altura	Curva modulac.
10	3.048	;

[TANKS]

;ID Nudo	Cota	NivelIni	NivelMín	NivelMáx	Diámetro	VolMín	CurvCubic
65	0	67.032	0	100	21.55	0	;
165	0	67.032	0	100	21.55	0	;
265	0	67.032	0	100	21.55	0	;

[PIPES]

;ID Línea	Nudo1	Nudo2	Longitud	Diametro	Rugos	PérdMen	Estado
4	20	30	3657.6	609.6	120	0	Open ;
30	30	60	1828.8	508	120	0	Open ;
16	60	90	1828.8	152.4	120	0	Open ;
14	70	60	1828.8	406.4	120	0	Open ;
12	70	90	1828.8	254	120	0	Open ;
2	20	70	3657.6	609.6	120	0	Open ;
6	20	110	3657.6	457.2	120	0	Open ;
48	110	100	1828.8	304.8	120	0	Open ;
24	100	90	1828.8	508	120	0	Open ;
10	70	100	1828.8	609.6	120	0	Open ;
32	30	40	1828.8	203.2	120	0	Open ;
36	40	50	1828.8	304.8	120	0	Open ;
38	50	80	1828.8	203.2	120	0	Open ;
18	80	60	1828.8	457.2	120	0	Open ;
20	80	90	1828.8	406.4	120	0	Open ;
66	50	140	3657.6	203.2	120	0	Open ;
40	140	80	1828.8	304.8	120	0	Open ;
28	80	150	1828.8	457.2	120	0	Open ;
22	150	90	1828.8	152.4	120	0	Open ;
26	150	100	1828.8	609.6	120	0	Open ;
42	150	140	1828.8	508	120	0	Open ;
64	140	170	3657.6	304.8	120	0	Open ;
60	170	130	1828.8	304.8	120	0	Open ;
58	130	160	1828.8	406.4	120	0	Open ;
44	160	150	1828.8	355.6	120	0	Open ;
50	160	110	1828.8	304.8	120	0	Open ;
52	110	120	1828.8	355.6	120	0	Open ;
56	120	130	1828.8	304.8	120	0	Open ;



62	140	160	1828.8	508	120	0	Open	;
46	100	160	1828.8	457.2	120	0	Open	;
34	50	30	2743.2	355.6	120	0	Open	;
78	65	60	30.48	508	120	0	Open	;
80	165	160	30.48	406.4	120	0	Open	;
8	70	30	2743.2	355.6	120	0	Open	;
74	50	55	1828.8	304.8	120	0	Open	;
76	55	75	1828.8	304.8	120	0	Open	;
72	75	115	1828.8	304.8	120	0	Open	;
68	115	140	1828.8	304.8	120	0	Open	;
70	75	140	1828.8	304.8	120	0	Open	;
178	140	265	30.48	406.4	120	0	Open	;
54	160	120	2743.2	304.8	120	0	Open	;

## [PUMPS]

:ID línea	NudoAsp	NudoImp	Parámetros			
222	10	20	HEAD 1	PATTERN PMP2		;
111	10	20	HEAD 1	PATTERN PMP1		;
333	10	20	HEAD 1	PATTERN PMP3		;

## [VALVES]

:ID línea	NudoAgArr	NudoAgAbj	Diámetro	Tipo	Consigna	PérdMen
-----------	-----------	-----------	----------	------	----------	---------

## [TAGS]

## [DEMANDS]

:ID Nudo	Demanda Base	Curva Modulación	Tipo Demanda
----------	--------------	------------------	--------------

## [STATUS]

:ID línea	Estado/Consigna
-----------	-----------------

## [PATTERNS]

:ID Curva	Multiplicadores					
:General demand pattern						
DEM	0.7	0.7	0.7	0.6	0.6	0.6
DEM	1.2	1.2	1.2	1.3	1.3	1.3
DEM	1.2	1.2	1.2	1	1	1
DEM	0.9	0.9	0.9	0.7	0.7	0.7
;						
PMP1	1	0	1	1	1	1
PMP1	1	0	1	0	1	1
PMP1	0	0	0	1	0	0
PMP1	0	0	0	1	1	0
;						
PMP2	0	1	0	0	0	1
PMP2	0	0	1	1	1	1
PMP2	1	0	0	1	1	0
PMP2	0	1	1	1	1	0
;						
PMP3	0	0	1	1	1	0
PMP3	1	0	1	1	0	0
PMP3	1	0	1	0	0	0
PMP3	0	1	0	1	1	0
;						
PRICES	18.14	18.14	18.14	18.14	18.14	18.14
PRICES	18.14	35.28	35.28	35.28	35.28	35.28
PRICES	35.28	35.28	35.28	35.28	35.28	80.97
PRICES	80.97	80.97	80.97	18.14	18.14	18.14
:Demand patter for node 90						
DEM90	0.7	0.7	0.7	0.6	0.6	0.6
DEM90	1.2	1.2	1.2	1.3	1.3	1.3
DEM90	1.2	1.2	1.2	1	1	1
DEM90	0.9	0.9	0.9	0.7	0.7	0.7
:Demand pattern for node 55						
DEM55	0.7	0.7	0.7	0.6	0.6	0.6
DEM55	1.2	1.2	1.2	1.3	1.3	1.3
DEM55	1.2	1.2	1.2	1	1	1
DEM55	0.9	0.9	0.9	0.7	0.7	0.7
:Demand pattern for node 170						
DEM170	0.7	0.7	0.7	0.6	0.6	0.6
DEM170	1.2	1.2	1.2	1.3	1.3	1.3
DEM170	1.2	1.2	1.2	1	1	1

DEM170            0.9        0.9        0.9        0.7        0.7        0.7

[CURVES]

;ID Curva            Valor X            Valor Y

;PUMP:

1	0	91.44
1	454.2494	89.0016
1	908.4988	82.296
1	1362.7482	70.104
1	1816.9976	55.1688

;EFFICIENCY:

2	0	0
2	454.2494	50
2	908.4988	65
2	1362.7482	55
2	1816.9976	40

[CONTROLS]

;

LINK 78 OPEN AT TIME 0  
 LINK 78 OPEN AT TIME 1  
 LINK 78 OPEN AT TIME 2  
 LINK 78 OPEN AT TIME 3  
 LINK 78 OPEN AT TIME 4  
 LINK 78 OPEN AT TIME 5  
 LINK 78 OPEN AT TIME 6  
 LINK 78 OPEN AT TIME 7  
 LINK 78 OPEN AT TIME 8  
 LINK 78 OPEN AT TIME 9  
 LINK 78 OPEN AT TIME 10  
 LINK 78 OPEN AT TIME 11  
 LINK 78 OPEN AT TIME 12  
 LINK 78 OPEN AT TIME 13  
 LINK 78 OPEN AT TIME 14  
 LINK 78 OPEN AT TIME 15  
 LINK 78 OPEN AT TIME 16  
 LINK 78 OPEN AT TIME 17  
 LINK 78 OPEN AT TIME 18  
 LINK 78 OPEN AT TIME 19  
 LINK 78 OPEN AT TIME 20  
 LINK 78 OPEN AT TIME 21  
 LINK 78 OPEN AT TIME 22  
 LINK 78 OPEN AT TIME 23  
 LINK 78 OPEN AT TIME 24  
 LINK 178 OPEN AT TIME 0  
 LINK 178 OPEN AT TIME 1  
 LINK 178 OPEN AT TIME 2  
 LINK 178 OPEN AT TIME 3  
 LINK 178 OPEN AT TIME 4  
 LINK 178 OPEN AT TIME 5  
 LINK 178 OPEN AT TIME 6  
 LINK 178 OPEN AT TIME 7  
 LINK 178 OPEN AT TIME 8  
 LINK 178 OPEN AT TIME 9  
 LINK 178 OPEN AT TIME 10  
 LINK 178 OPEN AT TIME 11  
 LINK 178 OPEN AT TIME 12  
 LINK 178 OPEN AT TIME 13  
 LINK 178 OPEN AT TIME 14  
 LINK 178 OPEN AT TIME 15  
 LINK 178 OPEN AT TIME 16  
 LINK 178 OPEN AT TIME 17  
 LINK 178 OPEN AT TIME 18  
 LINK 178 OPEN AT TIME 19  
 LINK 178 OPEN AT TIME 20  
 LINK 178 OPEN AT TIME 21  
 LINK 178 OPEN AT TIME 22  
 LINK 178 OPEN AT TIME 23  
 LINK 178 OPEN AT TIME 24  
 LINK 80 OPEN AT TIME 0  
 LINK 80 OPEN AT TIME 1  
 LINK 80 OPEN AT TIME 2

```

LINK 80 OPEN AT TIME 3
LINK 80 OPEN AT TIME 4
LINK 80 OPEN AT TIME 5
LINK 80 OPEN AT TIME 6
LINK 80 OPEN AT TIME 7
LINK 80 OPEN AT TIME 8
LINK 80 OPEN AT TIME 9
LINK 80 CLOSED AT TIME 10
LINK 80 OPEN AT TIME 11
LINK 80 OPEN AT TIME 12
LINK 80 OPEN AT TIME 13
LINK 80 OPEN AT TIME 14
LINK 80 OPEN AT TIME 15
LINK 80 OPEN AT TIME 16
LINK 80 OPEN AT TIME 17
LINK 80 OPEN AT TIME 18
LINK 80 OPEN AT TIME 19
LINK 80 OPEN AT TIME 20
LINK 80 OPEN AT TIME 21
LINK 80 OPEN AT TIME 22
LINK 80 OPEN AT TIME 23
LINK 80 OPEN AT TIME 24
;
[RULES]

[ENERGY]
Global Efficiency 75
Global Price 0
Demand Charge 0
Pump 222 Efficiency 2
Pump 222 Price 1
Pump 222 Pattern PRICES
Pump 111 Efficiency 2
Pump 111 Price 1
Pump 111 Pattern PRICES
Pump 333 Efficiency 2
Pump 333 Price 1
Pump 333 Pattern PRICES

[EMITTERS]
;ID Nudo_Caud Coeficiente

[QUALITY]
;ID Nudo Calidad Inicial

[SOURCES]
;ID Nudo Tipo Calidad Curva Modul

[REACTIONS]
;Tipo Tub/Depós Coeficiente

[REACTIONS]
Order Bulk 1
Order Wall 1
Global Bulk 0
Global Wall 0
Limiting Potential 0
Roughness Correlation 0

[MIXING]
;ID Depósito Modelo Fracción Mezcla

[TIMES]
Duration 24:00
Hydraulic Timestep 0:06
Quality Timestep 0:05
Pattern Timestep 1:00
Pattern Start 0:00
Report Timestep 1:00
Report Start 0:00
Start ClockTime 0:00

```

Statistic           None

[REPORT]

Status            NO  
 Summary          No  
 Page              0

[OPTIONS]

Units             CMH  
 Headloss         H-W  
 Specific Gravity   1  
 Viscosity         1  
 Trials            40  
 Accuracy         0.01  
 Unbalanced       Continue 10  
 Pattern           DEM  
 Demand Multiplier 1  
 Emitter Exponent 2  
 Quality           None mg/l  
 Diffusivity       1  
 Tolerance         0.01

[COORDINATES]

;ID Nudo	Coord X	Coord Y
20	98.2200012207031	10
30	98.2200012207031	71.5599975585938
110	49.3300018310547	10
70	72.2200012207031	30.6700000762939
60	72.2200012207031	71.5599975585938
90	55.560001373291	53.1100006103516
100	51.560001373291	30.8899993896484
40	98.2200012207031	94.2200012207031
50	42.439998626709	94.2200012207031
80	38.2200012207031	73.7799987792969
150	31.5599994659424	52.8899993896484
140	8.22000026702881	66.6699981689453
170	-16.6700000762939	42
130	-3.32999992370605	21.1100006103516
160	8.22000026702881	36.2200012207031
120	16	8.67000007629395
55	31.5300006866455	110.589996337891
75	11.2299995422363	102.559997558594
115	-4.1100001335144	87.4599990844727
10	118.669998168945	10
65	53.1699981689453	81.5999984741211
165	-1.9099999666214	42.7900009155273
265	-7.96000003814697	72.25

[VERTICES]

;ID Línea	Coord X	Coord Y
111	108.269996643066	19.1900005340576
333	107.930000305176	2.50999999046326

[LABELS]

;Coord X	Coord Y	Rótulo y Nudo Anclaje
----------	---------	-----------------------

[BACKDROP]

DIMENSIONS	-23.44	3.57	125.44	115.68
UNITS	None			
FILE				
OFFSET	0	0		

[END]

## Anexo 2

### Rede WDSA (arquivo .inp)

[TITLE]

[JUNCTIONS]

:ID	Elev	Demand	Pattern	
J511	105.08	1.175912	DMA2_pat	;
J411	8.95	.8890401	DMA1_pat	;
J414	34.36	.9658645	DMA1_pat	;
J415	65	0		;
J416	42.6	0		;
J417	37.38	1.291233	DMA1_pat	;
J418	37.39	0		;
J419	40.5	0		;
J310	51.84	1.357483	DMA4_pat	;
J311	55.95	1.18173	DMA4_pat	;
J312	68.48	7.558805E-02	DMA4_pat	;
J313	67.66	.6900545	DMA4_pat	;
J314	14.94	1.437699	DMA1_pat	;
J315	16.03	1.317467	DMA1_pat	;
J316	12.98	.6225603	DMA1_pat	;
J318	53.67	1.603255	DMA4_pat	;
J319	39.29	1.45241	DMA4_pat	;
J210	7.01	9.372806E-02	DMA1_pat	;
J211	11.27	1.582595	DMA1_pat	;
J212	7.87	.6066978	DMA1_pat	;
J214	8.67	.8747806	DMA1_pat	;
J217	10.98	1.27852	DMA1_pat	;
J218	7.68	8.917417E-02	DMA1_pat	;
J219	52	.9874303	DMA5_pat	;
J110	15.92	.781167	DMA1_pat	;
J420	39.99	0		;
J421	37.09	1.037828	DMA1_pat	;
J422	38.81	0		;
J1153	22.14	.439655	DMA1_pat	;
J1154	14.61	.46557	DMA1_pat	;
J1155	15.54	1.383003	DMA1_pat	;
J425	64.42	0		;
J426	72.71	0		;
J1157	22.21	1.643489	DMA1_pat	;
J427	67.65	0		;
J1158	28.25	.37811	DMA1_pat	;
J428	16.2	1.158526	DMA1_pat	;
J429	12.56	1.633339	DMA1_pat	;
J320	46.73	.4065523	DMA4_pat	;
J321	44.59	.8897884	DMA4_pat	;
J322	48.02	.1772828	DMA4_pat	;
J324	42.38	1.665691	DMA4_pat	;
J1056	7.64	1.12696	DMA1_pat	;
J327	49.68	2.617306E-02	DMA4_pat	;
J1058	13.58	.9586397	DMA1_pat	;
J328	45.69	.1667536	DMA4_pat	;
J329	44.05	.1717045	DMA4_pat	;
J220	80	1.331474	DMA5_pat	;
J221	97.07	.4741339	DMA4_pat	;
J225	13.33	7.608195E-02	DMA1_pat	;
J226	11.1	.4929547	DMA1_pat	;
J50	71.8	.6366845	DMA4_pat	;
J51	77.42	.5016175	DMA4_pat	;
J53	85	1.580952	DMA5_pat	;
J54	80	1.633049	DMA5_pat	;
J128	85.26	.6689573	DMA2_pat	;
J55	71	.4638	DMA5_pat	;
J129	62.85	.2674025	DMA2_pat	;
J56	72	.2713695	DMA5_pat	;
J57	59	1.077645	DMA5_pat	;
J58	76	.6834553	DMA5_pat	;
J59	57	.6879447	DMA5_pat	;

J1160	24.91	1.187884	DMA1_pat	;
J1161	25.25	.543677	DMA1_pat	;
J431	16.9	1.055298	DMA1_pat	;
J432	19.88	.3459353	DMA1_pat	;
J433	27.35	.3100225	DMA1_pat	;
J434	16.48	.9722651	DMA1_pat	;
J435	12.15	.1345244	DMA1_pat	;
J436	17.68	.7632859	DMA1_pat	;
J438	10.43	1.50955	DMA1_pat	;
J1169	55.42	.4356139	DMA3_pat	;
J439	17.78	1.308687	DMA1_pat	;
J330	58.25	.6315042	DMA4_pat	;
J331	59.26	.482775	DMA4_pat	;
J332	44.18	1.324	DMA1_pat	;
J333	25.7	1.052904	DMA1_pat	;
J334	29.28	1.04607	DMA1_pat	;
J335	25.08	.7140939	DMA1_pat	;
J336	23.81	.1632897	DMA1_pat	;
J337	22.11	.935067	DMA1_pat	;
J231	71.9	1.157476	DMA4_pat	;
J232	69.81	1.522863	DMA4_pat	;
J233	74.23	0	;	;
J234	64.06	.03	DMA2_pat	;
J236	58	.9056011	DMA5_pat	;
J237	73.14	1.52694	DMA5_pat	;
J130	54.52	.717102	DMA2_pat	;
J131	88.05	1.129913	DMA2_pat	;
J132	74.55	.8374234	DMA2_pat	;
J133	69.58	.8562292	DMA2_pat	;
J60	55	.7716334	DMA5_pat	;
J134	80.7	.5891212	DMA2_pat	;
J135	70	.6747236	DMA2_pat	;
J62	60	.4495525	DMA5_pat	;
J64	82	9.265584E-02	DMA5_pat	;
J65	82	.4064086	DMA5_pat	;
J66	72	1.631797	DMA5_pat	;
J67	81	.1015269	DMA5_pat	;
J68	73	.6504859	DMA5_pat	;
J69	71	.6083255	DMA5_pat	;
J1170	54.54	.8164911	DMA3_pat	;
J441	69	0	;	;
J444	29.46	.7907653	DMA1_pat	;
J341	14.89	.4287795	DMA1_pat	;
J344	54.7	1.04792	DMA3_pat	;
J345	49.97	.9034503	DMA3_pat	;
J347	54.4	.2605036	DMA3_pat	;
J348	62.18	1.564242	DMA4_pat	;
J349	36.41	1.090832	DMA4_pat	;
J241	70	.8434789	DMA5_pat	;
J242	65	.6507859	DMA5_pat	;
J243	60	.1789589	DMA5_pat	;
J244	70	1.306659	DMA5_pat	;
J245	71	.7660681	DMA5_pat	;
J246	55	1.256147	DMA5_pat	;
J247	57	.9934909	DMA5_pat	;
J248	54	1.387884	DMA5_pat	;
J249	50	3.126389E-02	DMA5_pat	;
J142	5.53	.3506145	DMA1_pat	;
J143	6.3	.1232556	DMA1_pat	;
J70	70	.1757545	DMA5_pat	;
J144	4.17	.5528242	DMA1_pat	;
J71	77	.2137497	DMA5_pat	;
J72	75	4.019444E-04	DMA5_pat	;
J73	80	.8946567	DMA5_pat	;
J74	75	1.095092	DMA5_pat	;
J76	70	.9066901	DMA5_pat	;
J77	76	1.37902	DMA5_pat	;
J78	60.56	.1364892	DMA4_pat	;
J350	33.82	.3198709	DMA3_pat	;
J351	25.51	1.131522	DMA4_pat	;
J352	47.55	.7570131	DMA4_pat	;
J353	22.64	.5950387	DMA4_pat	;

J354	18.68	.2499683	DMA4_pat	;
J355	28.87	1.173993	DMA4_pat	;
J358	22.3	1.547977	DMA4_pat	;
J359	17.57	.8836875	DMA4_pat	;
J250	67	.1494022	DMA5_pat	;
J251	75.19	1.262882	DMA2_pat	;
J252	83.82	.6697367	DMA2_pat	;
J253	74.69	.7697906	DMA2_pat	;
J254	74.59	.8202762	DMA2_pat	;
J257	105.58	.3460456	DMA2_pat	;
J154	43.69	.54956	DMA1_pat	;
J155	44.41	.1590483	DMA1_pat	;
J82	70.87	.9829875	DMA4_pat	;
J156	56.16	.2831225	DMA1_pat	;
J83	61.07	1.546028	DMA4_pat	;
J84	43.82	.1632164	DMA5_pat	;
J85	45	.7397709	DMA5_pat	;
J159	37.41	.4549114	DMA1_pat	;
J86	50	1.454245	DMA5_pat	;
J87	42.63	1.251146	DMA5_pat	;
J89	68.29	.4549039	DMA2_pat	;
J360	20.71	1.122745	DMA4_pat	;
J361	26.67	.427715	DMA4_pat	;
J362	43.66	.1498275	DMA4_pat	;
J363	72.23	0		;
J364	65	0		;
J365	29.83	1.316882	DMA1_pat	;
J366	14.46	.49543	DMA1_pat	;
J1208	42.74	.392137	DMA4_pat	;
J367	13.6	.8007911	DMA1_pat	;
J369	20.27	.4243364	DMA1_pat	;
J160	43.69	.5676775	DMA1_pat	;
J161	22.81	7.488973E-02	DMA1_pat	;
J162	36.88	.8040467	DMA1_pat	;
J163	16.2	.343362	DMA1_pat	;
J164	17.34	1.440891	DMA1_pat	;
J91	64.09	.9810478	DMA2_pat	;
J165	16.69	1.258181	DMA1_pat	;
J166	23.95	1.546472	DMA1_pat	;
J167	23.91	.5516948	DMA1_pat	;
J94	30.75	.904902	DMA3_pat	;
J95	22.56	.1344856	DMA1_pat	;
J96	30	1.057287	DMA1_pat	;
J97	34.19	.6833945	DMA1_pat	;
J976	6.3	1.600705	DMA1_pat	;
J571	77.11	.1910389	DMA2_pat	;
J572	76.4	1.539075	DMA2_pat	;
J573	81.62	1.033683	DMA2_pat	;
J574	67.36	.5795442	DMA2_pat	;
J575	75.27	.2487428	DMA2_pat	;
J576	80.8	.7999637	DMA2_pat	;
J370	20.46	.365682	DMA1_pat	;
J371	68.81	0		;
J372	23.2	.2173675	DMA1_pat	;
J373	27.22	4.814306E-02	DMA1_pat	;
J374	13.7	.5756528	DMA1_pat	;
J375	22.72	.9127809	DMA1_pat	;
J376	12.18	1.538258	DMA1_pat	;
J377	13.12	.8970772	DMA1_pat	;
J1219	14.48	.6773689	DMA1_pat	;
J379	10.25	1.412076	DMA1_pat	;
J171	8.81	1.377043	DMA1_pat	;
J172	6.25	1.120713	DMA1_pat	;
J173	13	1.203158	DMA1_pat	;
J174	6.11	1.661286	DMA1_pat	;
J175	6.84	.5663434	DMA1_pat	;
J177	13.14	.8253523	DMA1_pat	;
J179	15.01	.6882797	DMA1_pat	;
J580	113.08	1.158803	DMA2_pat	;
J486	86.11	.2984822	DMA2_pat	;
J487	79	.7048636	DMA2_pat	;
J488	89.16	.9052951	DMA2_pat	;

J489	85.02	1.357773	DMA2_pat	;
J381	36.02	.9015225	DMA4_pat	;
J1223	3.48	.7125556	DMA1_pat	;
J382	70.42	.848447	DMA4_pat	;
J384	42.51	0		;
J385	76.6	0		;
J180	8.77	.816384	DMA1_pat	;
J181	10.94	1.134699	DMA1_pat	;
J1024	5.83	1.477667	DMA1_pat	;
J183	13.28	.6175256	DMA1_pat	;
J1025	8.61	.5041625	DMA1_pat	;
J186	9.38	.4881114	DMA1_pat	;
J187	9.81	.2505189	DMA1_pat	;
J188	8.51	.8830353	DMA1_pat	;
J189	7.58	.3721031	DMA1_pat	;
J490	103.84	.9742156	DMA2_pat	;
J491	76.93	.6057645	DMA2_pat	;
J492	94.67	1.459958	DMA2_pat	;
J493	77.62	.7966903	DMA2_pat	;
J494	112.76	.3177222	DMA2_pat	;
J495	91.15	1.140104	DMA2_pat	;
J496	106.34	1.245693	DMA2_pat	;
J497	112.63	1.023225	DMA2_pat	;
J498	90.12	1.303565	DMA2_pat	;
J500	75.52	.2695728	DMA2_pat	;
J499	72.24	1.3463	DMA2_pat	;
J501	80.97	.3376972	DMA2_pat	;
J502	80.99	1.594604	DMA2_pat	;
J503	99.65	.1097517	DMA2_pat	;
J504	66.71	.1025369	DMA2_pat	;
J394	70.53	0		;
J509	99.94	.6326745	DMA2_pat	;
J399	75	0		;
J401	70	0		;
J406	71.74	0		;
J295	56.42	.2896222	DMA4_pat	;
J407	68	0		;
J296	30.91	1.191361	DMA4_pat	;
J408	7.93	.8883706	DMA1_pat	;
J297	99.05	.9350156	DMA4_pat	;
J298	77.46	.3612225	DMA4_pat	;
J191	5.76	.7800094	DMA1_pat	;
J303	50.42	1.243924	DMA4_pat	;
J192	12.4	1.253851	DMA1_pat	;
J193	12.99	.6648872	DMA1_pat	;
J305	47.11	1.505165	DMA4_pat	;
J194	13.46	1.243345	DMA1_pat	;
J195	15.39	.1475992	DMA1_pat	;
J196	13.35	1.057619	DMA1_pat	;
J308	33.24	1.18838	DMA1_pat	;
J198	18.54	2.613722E-02	DMA1_pat	;
J200	15.75	.7185739	DMA1_pat	;
J199	16.26	.6699712	DMA1_pat	;
J201	44.86	.4588259	DMA1_pat	;
J202	10.41	1.64229	DMA1_pat	;
J203	11.03	1.337646	DMA1_pat	;
J204	21.51	1.160168	DMA1_pat	;
J205	16.66	.6959986	DMA1_pat	;
J206	14.12	1.224147	DMA1_pat	;
J207	18.86	.4619472	DMA1_pat	;
J208	11.25	.5943106	DMA1_pat	;
J101	28.65	.7224287	DMA1_pat	;
J102	46.96	1.574952	DMA1_pat	;
J109	17.47	.2025833	DMA1_pat	;
J1	16.82	1.076586	DMA1_pat	;
J2	11.97	.5797212	DMA1_pat	;
J3	29.02	.1740539	DMA1_pat	;
J4	20.88	.3090042	DMA1_pat	;
J5	22.75	.1294744	DMA1_pat	;
J6	15.25	.7212659	DMA1_pat	;
J7	24.91	1.598785	DMA1_pat	;
J8	31.17	.9033823	DMA1_pat	;



---

J9	31.89	.8239611	DMA1_pat	:
J10	14.62	1.621611	DMA1_pat	:
J11	18.43	.3629998	DMA1_pat	:
J12	29.27	.631652	DMA1_pat	:
J13	32.04	.6597406	DMA1_pat	:
J14	37.91	0		:
J15	102.84	0		:
J16	88.89	0		:
J17	82.75	0		:
J18	84.96	0		:
J19	90.94	0		:
J20	80	0		:
J21	80	0		:
J22	82.74	0		:
J23	75.96	0		:
J25	94.13	.1074853	DMA2_pat	:
J26	76.35	1.260154	DMA2_pat	:
J27	82.08	1.167524	DMA2_pat	:
J28	45	.8284517	DMA2_pat	:
J29	49	.2590595	DMA2_pat	:
J30	72.01	.3728958	DMA2_pat	:
J31	69.78	.5435734	DMA2_pat	:
J32	45	1.307481	DMA2_pat	:
J33	48	8.377139E-02	DMA2_pat	:
J34	50	.86336	DMA2_pat	:
J35	67.78	1.261716	DMA2_pat	:
J36	51.08	1.33445	DMA2_pat	:
J37	66.19	.5420092	DMA2_pat	:
J38	47	1.621215	DMA2_pat	:
J24	34.53	1.340445	DMA1_pat	:
J39	45.88	1.12471	DMA1_pat	:
J40	12.8	1.508549	DMA1_pat	:
J123	38.41	1.459633	DMA3_pat	:
J140	39.94	.694414	DMA3_pat	:
J141	41.45	.2051381	DMA3_pat	:
J157	31.49	1.590263	DMA3_pat	:
J158	25.88	1.328829	DMA3_pat	:
J168	40.21	1.160475	DMA3_pat	:
J170	46.87	.6693408	DMA3_pat	:
J176	50.64	2.716278E-02	DMA3_pat	:
J178	58.87	.2796047	DMA3_pat	:
J184	56.09	.2737236	DMA3_pat	:
J185	43.71	.8495334	DMA3_pat	:
J190	58.49	.6767712	DMA3_pat	:
J197	41.86	.1768897	DMA3_pat	:
J213	52.07	.4602056	DMA3_pat	:
J215	75.76	1.071745	DMA3_pat	:
J216	53.06	1.415167	DMA3_pat	:
J227	52.89	.8299486	DMA3_pat	:
J238	44.16	.3129586	DMA3_pat	:
J239	43.49	1.494361	DMA3_pat	:
J255	35.31	.6213573	DMA3_pat	:
J256	40	0		:
J258	51.24	1.284721	DMA3_pat	:
J260	32.53	.3633339	DMA3_pat	:
J265	50.87	.7449886	DMA3_pat	:
J266	39.83	.3933797	DMA3_pat	:
J267	22.31	1.463974	DMA4_pat	:
J61	72	1.017388	DMA5_pat	:
J92	72	.6240537	DMA5_pat	:
J268	69.68	.6491698	DMA4_pat	:
J278	104.29	1.434316	DMA2_pat	:
J281	83.72	.9765631	DMA2_pat	:
J283	94.06	1.552599	DMA2_pat	:
J284	77.38	.8619875	DMA2_pat	:
J136	81.8	.5505014	DMA2_pat	:
J137	9.11	1.447423	DMA1_pat	:
J145	47.46	.4317684	DMA3_pat	:
J118	75	.4325689	DMA5_pat	:
J52	54.7	.2978225	DMA4_pat	:
J81	50	.578262	DMA2_pat	:
J88	45	4.176111E-03	DMA2_pat	:

J90	84	1.237237	DMA2_pat	;
J93	65	4.204435	DMA2_pat	;
J147	68	.4643159	DMA2_pat	;
J148	50	1.171617	DMA2_pat	;
J149	40	.6747745	DMA2_pat	;
J150	60	1.352619	DMA2_pat	;
J151	60	1.236301	DMA2_pat	;
J152	32	.7294397	DMA2_pat	;
J153	60	.1299675	DMA2_pat	;
J169	42	.6843861	DMA2_pat	;
J182	40	.5656253	DMA2_pat	;
J222	32	1.184257	DMA2_pat	;
J224	37	.5204803	DMA2_pat	;
J230	30	1.331289	DMA4_pat	;
J235	53	.2529269	DMA4_pat	;
J240	87	.9883186	DMA2_pat	;
J269	56	0	;	;
J273	56	0	;	;
J274	56	0	;	;
J276	56	0	;	;
J280	56	0	;	;
J285	56	0	;	;
J287	40	0	;	;
J288	40	0	;	;
J289	40	0	;	;
J290	40	0	;	;
J291	65	0	;	;
J292	40	0	;	;
J299	40	0	;	;
J300	40	0	;	;
J301	44	0	;	;
J302	44	0	;	;
J304	44	0	;	;
J306	44	0	;	;
J307	44	0	;	;
J309	44	0	;	;
J317	44	0	;	;
J323	44	0	;	;

## [RESERVOIRS]

;ID	Head	Pattern	
R1	59		;

## [TANKS]

;ID	Elevation	InitLevel	MinLevel	MaxLevel	Diameter	MinVol	VolCurve	
T3	112.9	3	0	6.75	13.73	0		;
T1	71.5	3	0	6.5	31.3	0		;
T7	102	2.5	0	5	7.14	0		;
T6	101.5	5.2	0	5.5	8.33	0		;
T5	105.8	1.0	0	4.5	11.89	0		;
T2	65	.5	0	5.9	20.78	0		;
T4	132.5	2.5	0	4.7	11.64	0		;

## [PIPES]

;ID	Node1	Node2	Length	Diameter	Roughness	MinorLoss	Status	
P1	J175	J174	52.9	203	72.4549266	0	Open	;
P10	J335	J336	79.23	76	108.0095074	0	Open	;
P100	J159	J160	107.88	406	76.51422883	0	Open	;
P1000	J341	J204	109.27	203	76.94614787	0	Open	;
P101	J166	J162	243.37	254	84.20845169	0	Open	;
P1016	J22	J233	164.77	305	85.23817366	0	Open	;
P102	J109	J408	1280.3	508	92.94722922	0	Open	;
P1022	J281	J283	200.76	102	99.58078005	0	Open	;
P1023	J278	J283	136.34	102	95.68850653	0	Open	;
P1024	J580	J278	375.62	102	89.62069894	0	Open	;
P1025	J575	J132	39.18	76	97.77659267	0	Open	;
P1026	J132	J493	45.61	76	88.45039526	0	Open	;
P1027	J486	J488	82.32	51	92.0106009	0	Open	;
P1028	J489	J486	9.57	51	86.99339612	0	Open	;
P1029	J489	J492	122.62	76	91.33959845	0	Open	;
P103	J2	J1219	35.98	254	79.37099717	0	Open	;
P1030	J493	J489	95.25	76	104.6083303	0	Open	;

P1031	J494	J490	188.28	152	84.37414232	0	Open	;
P1032	J490	J492	143.29	152	98.43095137	0	Open	;
P1033	J492	J131	128.79	152	84.68939593	0	Open	;
P1034	J254	J253	52.87	203	97.41854735	0	Open	;
P1035	J253	J128	122.47	152	97.7581413	0	Open	;
P1036	J131	J128	83.33	203	74.29791874	0	Open	;
P1039	J573	J128	121.38	203	92.14229573	0	Open	;
P104	J166	J167	33.11	203	99.88658284	0	Open	;
P1040	J136	J573	29.45	152	94.68876721	0	Open	;
P1041	J136	J129	307.54	102	112.5081558	0	Open	;
P1042	J89	J573	84.54	152	76.15024112	0	Open	;
P1044	T5	J64	65.8	203	100.2182444	0	Open	;
P1045	J64	J53	68.63	203	118.82139	0	Open	;
P106	J102	J101	270.38	102	63.55113264	0	Open	;
P107	J171	J172	357	203	80.50983232	0	Open	;
P108	J101	J109	183.53	203	78.72048108	0	Open	;
P109	J175	J172	218.52	203	76.89340854	0	Open	;
P11	J318	J235	83.45	101.6	96.83442437	0	Open	;
P110	J179	J177	425.83	508	98.99414116	0	Open	;
P111	J976	J143	126.36	152	72.41174834	0	Open	;
P112	J142	J976	646.98	305	68.60087459	0	Open	;
P113	J137	J181	310.73	152	85.35380111	0	Open	;
P115	J408	J435	99.88	102	91.23151293	0	Open	;
P116	J186	J187	204.54	152	93.47394033	0	Open	;
P117	J435	J431	104	102	67.96195457	0	Open	;
P118	J431	J432	115.91	102	84.66525677	0	Open	;
P119	J188	J189	64.88	305	78.1411898	0	Open	;
P12	J208	J337	85.24	406	89.66261184	0	Open	;
P120	J432	J1160	91.4	102	88.38904641	0	Open	;
P121	J192	J193	42.23	152	100.3675691	0	Open	;
P122	J173	J194	45.06	305	78.97804998	0	Open	;
P123	J1160	J3	51.21	152	61.06139089	0	Open	;
P124	J376	J225	99.09	102	78.83034804	0	Open	;
P125	J163	J196	193.35	508	84.73893721	0	Open	;
P126	J225	J316	109.6	76	89.73794074	0	Open	;
P127	J316	J40	87.22	102	73.67740117	0	Open	;
P128	J40	J374	165.63	102	90.94829628	0	Open	;
P129	J374	J377	79.59	102	78.06619059	0	Open	;
P13	J337	J24	62.56	406	83.04378688	0	Open	;
P130	J376	J226	56.79	76	70.70724159	0	Open	;
P131	J206	J207	86.5	76	74.72670795	0	Open	;
P132	J226	J379	67.35	76	88.54168235	0	Open	;
P134	J4	J5	68.79	76	78.56802703	0	Open	;
P136	J5	J431	241.77	102	75.73324573	0	Open	;
P138	J203	J217	19.28	254	72.48528099	0	Open	;
P139	J208	J211	73.66	406	68.718495	0	Open	;
P14	J24	J39	151.39	406	72.00911504	0	Open	;
P140	J219	J220	222.3	102	107.8347395	0	Open	;
P141	J221	J51	169.94	102	103.7880571	0	Open	;
P142	J37	J93	16.61	152.4	85.39068455	0	Open	;
P144	J382	T6	130.79	76	99.91906661	0	Open	;
P147	J232	J231	60.08	203	92.837036	0	Open	;
P148	J233	J234	561.69	305	96.43940809	0	Open	;
P15	J39	T1	395.29	406	90.48302153	0	Open	;
P150	J82	J50	93.19	152	103.1527295	0	Open	;
P154	J245	J66	170.64	152	108.8315571	0	Open	;
P155	J60	J219	59.38	101.6	105.7092049	0	Open	;
P156	J242	J243	80.34	102	110.8685183	0	Open	;
P157	J244	J245	232.93	102	102.9010036	0	Open	;
P158	J236	J246	69.88	76	105.0723995	0	Open	;
P159	J204	J336	118.78	203	80.14718268	0	Open	;
P16	J1208	J353	252.34	102	97.24831268	0	Open	;
P160	J248	J246	68.68	76	104.6278726	0	Open	;
P161	J361	J355	40.31	76	90.01325959	0	Open	;
P162	J249	J85	190.67	152	98.76064267	0	Open	;
P163	J251	J90	67.74	203	94.23019998	0	Open	;
P165	J135	J234	143.81	305	92.93426098	0	Open	;
P166	J352	J382	235	101.6	93.60266001	0	Open	;
P17	J408	J1025	32.42	508	77.28134214	0	Open	;
P174	J6	J7	278.59	102	89.32071004	0	Open	;
P177	J305	J303	56.8	102	100.6056442	0	Open	;
P18	J1025	J411	283.3	508	100.3	0	Open	;

P184	J1208	J352	59.38	101.6	95.91470923	0	Open	;
P19	J411	J1056	750.87	508	97.7	0	Open	;
P195	J7	J4	144.33	76	80.6314204	0	Open	;
P2	J175	J181	295.25	203	62.04782884	0	Open	;
P20	J1056	J214	579.67	508	89.67250259	0	Open	;
P201	J7	J8	102.19	76	96.62781785	0	Open	;
P21	J214	J212	176.48	406	86.69368007	0	Open	;
P211	J295	J296	202.33	76	84.05170372	0	Open	;
P215	J419	T2	140.76	254	81.42351414	0	Open	;
P218	J310	J311	54.55	102	81.77139586	0	Open	;
P219	J312	J313	67.98	102	86.8360308	0	Open	;
P22	J159	J192	567.3	406	81.11362312	0	Open	;
P220	J314	J315	68.33	76	93.73758011	0	Open	;
P223	J318	J319	108.98	203	93.21702289	0	Open	;
P225	J321	J322	120.77	102	92.68551418	0	Open	;
P228	J327	J328	42.72	76	99.28890046	0	Open	;
P23	J192	J196	316.91	508	77.16263034	0	Open	;
P230	J330	J327	114.61	76	77.39533937	0	Open	;
P231	J331	J330	12.21	76	98.41544449	0	Open	;
P233	J333	J334	58.66	76	97.29593266	0	Open	;
P234	J335	J333	41.63	76	87.20981831	0	Open	;
P235	J336	J337	92.74	76	84.32189979	0	Open	;
P237	J415	J441	12.01	305	5.0585	0	Open	;
P238	J441	J416	12.59	304.8	104.739957	0	Open	;
P24	J177	J194	71.05	508	88.62083113	0	Open	;
P241	J344	J345	49.46	102	114.8367119	0	Open	;
P242	J36	J29	25.06	152.4	99.0149834	0	Open	;
P243	J36	J88	57.08	203.2	82.79621449	0	Open	;
P245	J87	J84	18.65	152.4	120.3989086	0	Open	;
P246	J249	J250	56.94	152.4	121.5967586	0	Open	;
P248	J250	J245	6.96	152.4	110.0672989	0	Open	;
P249	J359	J360	28.43	51	85.38083927	0	Open	;
P25	J196	J194	4.3	508	74.37733692	0	Open	;
P251	J329	J362	11.49	152	103.73326	0	Open	;
P252	J363	J364	135.44	305	82.30042619	0	Open	;
P255	J369	J370	76.14	51	71.46719262	0	Open	;
P256	J371	J364	55.17	305	94.85911557	0	Open	;
P258	J372	J373	79.53	102	75.51228399	0	Open	;
P259	J374	J375	136.09	102	83.09359309	0	Open	;
P26	J163	J1	22.94	508	88.00750201	0	Open	;
P264	J242	J241	11.73	101.6	112.505063	0	Open	;
P266	J250	J242	55.29	101.6	107.0557801	0	Open	;
P267	J572	J147	344.62	152.4	95.59127017	0	Open	;
P268	J130	J149	146.46	152.4	86.83782705	0	Open	;
P27	J1	J161	163.63	254	69.10553047	0	Open	;
P270	J149	J150	88.36	101.6	92.76968792	0	Open	;
P272	J8	J9	143.88	102	73.95290985	0	Open	;
P275	J149	J148	172.96	152.4	98.1648787	0	Open	;
P28	J1	J164	117.42	152	88.26665116	0	Open	;
P280	J407	J401	333.4	203	88.34304078	0	Open	;
P282	J436	J10	131.93	102	86.72041921	0	Open	;
P284	J574	J151	198.97	76.2	89.12500159	0	Open	;
P285	J151	J153	130.71	76.2	90.18255066	0	Open	;
P286	J169	J182	155.58	101.6	90.00536972	0	Open	;
P287	J419	J420	45.12	254	78.34930836	0	Open	;
P288	J169	J222	226.74	76.2	85.05269358	0	Open	;
P29	J1	J165	20.51	152	89.48380518	0	Open	;
P290	J222	J224	46.28	76.2	89.4448254	0	Open	;
P291	J425	J426	132.94	305	107.0799731	0	Open	;
P292	J416	J427	13.54	305	97.26629793	0	Open	;
P293	J427	J425	125.2	305	92.15913275	0	Open	;
P294	J428	J429	101.2	102	79.96510184	0	Open	;
P295	J10	J435	133.23	76	72.40920176	0	Open	;
P296	J432	J433	231.87	76	82.95723709	0	Open	;
P297	J411	J438	42.53	406	73	0	Open	;
P298	J438	J434	40.11	305	84.55106971	0	Open	;
P299	J436	J429	61.51	102	87.70989261	0	Open	;
P3	J181	J173	136.52	300	73.64913862	0	Open	;
P30	J161	J166	40.89	254	86.70955075	0	Open	;
P301	J434	J11	45.31	305	85.18923941	0	Open	;
P302	J11	J433	178.28	305	80.34022293	0	Open	;
P303	J428	J439	131.94	76	88.33454494	0	Open	;

P304	J222	J152	268.74	101.6	89.39267725	0	Open	;
P305	J407	J441	43.41	203	90.79931312	0	Open	;
P307	J433	J12	47.3	305	60.51223799	0	Open	;
P308	J426	J363	334.57	305	88.07717274	0	Open	;
P309	J235	J230	128.8	101.6	94.95597676	0	Open	;
P31	J171	J186	144.67	152	108.7731191	0	Open	;
P310	J269	J156	9	610	87.26802597	0	Open	;
P316	R1	J280	11.62	610	70.45194642	0	Open	;
P319	J274	J269	10.54	610	76.59274096	0	Open	;
P32	J186	J2	84.44	152	103.5584403	0	Open	;
P320	J273	J269	11.47	610	76.51881041	0	Open	;
P322	J280	J285	11.5	610	89.43312359	0	Open	;
P323	J280	J276	11.47	610	84.68719833	0	Open	;
P329	J503	J501	134.52	152	100.1835818	0	Open	;
P33	J1219	J179	22.81	254	73.03598003	0	Open	;
P330	J501	J499	66.79	76	96.42287802	0	Open	;
P331	J486	J487	93.46	51	93.19325097	0	Open	;
P336	J495	J496	182.99	152	92.1736733	0	Open	;
P337	J497	J494	20.49	305	5.6181	0	Open	;
P338	J499	J500	74.38	76	100.3553057	0	Open	;
P339	J501	J502	307.49	102	88.65301931	0	Open	;
P34	J179	J110	98	508	78.50596539	0	Open	;
P340	J494	J496	96.21	305	101.082424	0	Open	;
P341	J496	J498	189.74	305	94.6355163	0	Open	;
P343	J495	J576	111.65	152	100.2909021	0	Open	;
P344	J576	J571	45.26	152	85.90916474	0	Open	;
P346	J499	J504	54.91	51	93.91341161	0	Open	;
P347	J509	T4	385.56	305	96.23520379	0	Open	;
P348	J503	J509	42.47	305	88.72950781	0	Open	;
P349	J503	J511	39.12	305	97.01243523	0	Open	;
P35	J50	J51	64.56	152	84.3826461	0	Open	;
P350	J509	J240	400.16	203	99.85976755	0	Open	;
P37	J348	J52	180.61	203	97.80387751	0	Open	;
P372	J219	J86	6.42	101.6	113.1146519	0	Open	;
P374	J287	J288	15.83	254	91.91560418	0	Open	;
P375	J288	J300	7.79	254	75.48935679	0	Open	;
P376	J300	J299	6.64	254	102.6856466	0	Open	;
P378	J292	J256	6.47	254	112.4496521	0	Open	;
P379	J287	J289	6.43	254	101.7753453	0	Open	;
P38	J55	J56	169.49	76	106.4650405	0	Open	;
P380	J289	J290	4.79	254	87.81324875	0	Open	;
P381	J291	J415	5.53	304.8	119.20713	0	Open	;
P383	J571	J491	19.56	152	80.14926659	0	Open	;
P384	J491	J575	26.14	76	101.9126563	0	Open	;
P385	J498	J134	106.53	305	76.02373041	0	Open	;
P386	J134	J576	8.12	152	79.90108822	0	Open	;
P39	J490	J488	190.12	102	95.4375542	0	Open	;
P397	J332	J301	13.16	203.2	87.42718755	0	Open	;
P398	J301	J302	6.75	203.2	91.05042408	0	Open	;
P399	J302	J307	9.71	203.2	81.41362338	0	Open	;
P40	J59	J60	143.64	102	107.9143544	0	Open	;
P402	J307	J309	6.12	203.2	89.1549467	0	Open	;
P403	J304	J306	6.86	152.4	111.4725023	0	Open	;
P409	J306	J87	26.38	152.4	89.89786692	0	Open	;
P410	J323	J317	7.7	203.2	85.6676939	0	Open	;
P42	J54	J73	32.93	152	114.9190666	0	Open	;
P424	J317	J384	27.8	203.2	124.9856956	0	Open	;
P43	J64	J65	36.18	203	88.53730832	0	Open	;
P44	J66	J67	247.65	152	115.1681772	0	Open	;
P443	J13	J12	67.31	305	85.57602477	0	Open	;
P445	J417	J421	7.8	254	86.21060196	0	Open	;
P446	J418	J421	31.15	254	102.1976464	0	CV	;
P450	J418	J422	19.47	254	96.96505055	0	Open	;
P46	J69	J70	70.86	102	112.662633	0	Open	;
P465	J421	J14	18.2	254	86.56539928	0	Open	;
P467	J422	J420	15.17	254	96.15411097	0	Open	;
P468	J420	J287	31.29	254	105.2733756	0	Open	;
P48	J73	J71	28.98	152	113.5196498	0	Open	;
P482	J9	J3	321.89	152	78.90389206	0	Open	;
P484	J438	J13	336.57	203	79.98	0	Open	;
P49	J72	J74	134.92	152	121.7050339	0	Open	;
P492	J86	J243	157.32	101.6	114.1136636	0	Open	;

P5	J1223	J218	588.97	406	83.56188054	0	Open	;
P500	J90	J252	24.23	203	112.6227522	0	Open	;
P501	J571	J572	11.32	152.4	111.4535058	0	Open	;
P502	J89	J574	9.19	76.2	99.5945589	0	Open	;
P51	J68	J77	57.47	102	92.23786036	0	Open	;
P510	J16	J15	193.37	102	104.9547114	0	Open	;
P52	J78	J51	83.26	102	89.65416834	0	Open	;
P524	J511	J580	170.54	305	96.22781415	0	Open	;
P527	J580	J497	149.04	305	73.12421582	0	Open	;
P529	J278	J281	212.31	102	103.917751	0	Open	;
P53	J384	J1208	10.32	203	87.56071617	0	Open	;
P54	J488	J491	111.67	51	92.39787511	0	Open	;
P55	J82	J83	99.86	76	87.65298441	0	Open	;
P57	J84	J85	288.77	152	99.59669568	0	Open	;
P58	J86	J84	503.91	102	100.8491608	0	Open	;
P596	J56	J58	76.39	76	112.8056283	0	Open	;
P597	J281	J284	79.68	102	101.1211685	0	Open	;
P6	J180	J171	199.39	152	94.64505119	0	Open	;
P609	J57	J56	86.07	76	111.6336079	0	Open	;
P610	J15	J17	206.58	76	95.7997832	0	Open	;
P63	J96	J95	165.95	254	88.72727612	0	Open	;
P633	J54	J67	173.88	152	119.1332558	0	Open	;
P64	J96	J97	126.63	203	80.24772732	0	Open	;
P65	J353	J351	164.93	102	101.9472625	0	Open	;
P67	J97	J102	330.24	203	74.11384494	0	Open	;
P670	J17	J18	54.41	152	98.70407263	0	Open	;
P671	J18	J16	62.97	152	94.83787887	0	Open	;
P68	J195	J188	302.74	305	83.22085413	0	Open	;
P69	J1223	J40	103.63	152	72.35176717	0	Open	;
P697	J16	J19	88.89	102	97.76254098	0	Open	;
P7	J218	J211	60.22	508	78.45371492	0	Open	;
P70	J40	J375	88.36	152	72.84389475	0	Open	;
P71	J188	J191	419.4	254	84.7287395	0	Open	;
P72	J95	J110	247.46	305	85.0356826	0	Open	;
P724	J78	J268	92.72	152	96.70704964	0	Open	;
P725	J78	J295	117.32	152	105.2924295	0	Open	;
P752	J297	T7	70.36	152	106.1657491	0	Open	;
P753	J297	J221	71.91	152	89.52407649	0	Open	;
P754	J19	J15	92.49	51	84.82770733	0	Open	;
P755	J140	J141	47.12	305	114.1298526	0	Open	;
P756	J123	J141	41.66	305	107.9166509	0	Open	;
P757	J1024	J142	568.43	305	99.83133104	0	Open	;
P758	J1025	J1024	102.21	305	93.35734311	0	Open	;
P759	J221	J298	97.19	152	104.4350261	0	Open	;
P760	J298	J312	88.54	152	101.8544486	0	Open	;
P761	J312	J83	171.27	152	96.99210802	0	Open	;
P763	J141	J157	387.59	305	112.2055437	0	Open	;
P766	J318	J303	37.85	152	95.03726284	0	Open	;
P767	J157	J94	227.5	305	109.3148967	0	Open	;
P768	J157	J158	217.03	254	116.5115918	0	Open	;
P769	J94	J168	154.26	305	110.6185664	0	Open	;
P771	J168	J170	69.36	203	99.63218871	0	Open	;
P772	J168	J176	215.02	305	85.80309439	0	Open	;
P775	J176	J178	129.42	203	108.382028	0	Open	;
P776	J178	J184	421.07	102	114.3497002	0	Open	;
P777	J176	J185	402.31	305	111.7656211	0	Open	;
P779	J185	J190	524.49	203	87.90984792	0	Open	;
P780	J18	J406	153.56	203	104.9547114	0	Open	;
P781	J83	J318	130.18	152	90.91406861	0	Open	;
P783	J190	J197	674.96	203	115.0802063	0	Open	;
P784	J213	J190	88.96	102	98.4320195	0	Open	;
P785	J190	J215	184.71	102	89.6475285	0	Open	;
P786	J197	J216	166.27	203	110.0001555	0	Open	;
P787	J216	T3	127.08	102	130.1224074	0	Open	;
P788	J216	J227	107.85	152	113.9140977	0	Open	;
P789	J1056	J366	285.95	203	74.96865627	0	Open	;
P791	J227	J238	82.5	152	115.9461135	0	Open	;
P794	J238	J239	39.04	203	123.9466201	0	Open	;
P795	J239	J255	129.41	203	97.7802756	0	Open	;
P796	J256	J238	22.42	203	89.87622094	0	Open	;
P797	J227	J258	21.64	102	117.0541964	0	Open	;
P798	J255	J260	684.07	203	116.0879492	0	Open	;

P8	J218	J212	11.35	406	76.077444	0	Open	;
P800	J344	J1170	15.93	203	109.6676101	0	Open	;
P801	J1170	J347	9.47	203	104.4688588	0	Open	;
P804	J1169	J265	68.27	102	103.0053454	0	Open	;
P805	J265	J266	96.57	152	114.5601573	0	Open	;
P806	J266	J260	32.51	152	103.8989922	0	Open	;
P807	J260	J350	162.82	203	100.1492592	0	Open	;
P808	J83	J311	253.47	203	92.06420424	0	Open	;
P809	J321	J324	17.35	102	109.3502993	0	Open	;
P810	J406	J394	64.3	203	88.93896444	0	Open	;
P811	J320	J321	50.17	102	89.56723202	0	Open	;
P813	J328	J320	30.85	152	76.0415565	0	Open	;
P815	J329	J328	50.52	102	84.34217359	0	Open	;
P817	J1158	J1153	253.3	203	72.65810772	0	Open	;
P819	J1153	J1157	8.02	203	105.0732947	0	Open	;
P821	J354	J267	64.78	102	83.94520189	0	Open	;
P822	J267	J353	11.71	102	99.59355845	0	Open	;
P823	J236	J237	18.84	76	113.3617729	0	Open	;
P826	J237	J244	335.29	76	99.14858764	0	Open	;
P827	J244	J247	119.07	76	103.740183	0	Open	;
P83	J155	J160	15.14	610	75.66382855	0	Open	;
P830	J247	J248	89.3	76	99.04404122	0	Open	;
P831	J248	J249	62.2	76	86.2917659	0	Open	;
P84	J183	J187	148.63	203	97.41353032	0	Open	;
P840	J311	J320	235.28	203	97.77044222	0	Open	;
P841	J297	J331	347.83	76	93.67657919	0	Open	;
P842	J62	J55	64.41	52	95.52120444	0	Open	;
P844	J59	J62	12.49	102	113.808278	0	Open	;
P846	J58	J118	94.84	203	103.9804942	0	Open	;
P847	J55	J118	68.63	152	91.07111508	0	Open	;
P85	J132	J133	36.6	76	69.9267053	0	Open	;
P850	J59	J57	241.13	101.6	112.5310973	0	Open	;
P851	J62	J57	228.78	76	121.9332034	0	Open	;
P852	J58	J67	40.39	203	105.3809228	0	Open	;
P853	J67	J53	295.68	203	118.6474037	0	Open	;
P855	J92	J76	37.88	102	114.8547426	0	Open	;
P858	J92	J68	195.38	102	113.4099875	0	Open	;
P859	J71	J77	90.81	152	95.28589543	0	Open	;
P86	J134	J135	161	305	110.5	0	Open	;
P861	J77	J72	110.79	152	87.94104359	0	Open	;
P866	J68	J61	17.37	102	92.17383193	0	Open	;
P87	J187	J137	80.03	203	76.39854111	0	Open	;
P871	J61	J69	48.15	102	91.80712367	0	Open	;
P880	J1160	J1161	112.84	76	86.03497853	0	Open	;
P889	J1169	J1170	15.72	203	88.74112608	0	Open	;
P89	J375	J372	104.3	152	78.43046596	0	Open	;
P892	J414	J13	30.39	254	69.84847395	0	Open	;
P9	J212	J217	49.95	254	66.74918886	0	Open	;
P90	J372	J376	98.94	102	62.31894921	0	Open	;
P91	J143	J144	572.34	102	94.33889253	0	Open	;
P914	J399	J20	38.61	203	91.1800276	0	Open	;
P915	J1208	J362	10.58	152	72.77251422	0	Open	;
P92	J137	J180	63.12	203	83.1066216	0	Open	;
P924	J195	J1219	82.38	254	74.45899818	0	Open	;
P927	J210	J1223	348.88	406	84.53153832	0	Open	;
P929	J401	J399	83.31	203	90.08263129	0	Open	;
P930	J399	J21	78.95	203	88.2	0	Open	;
P931	J20	J406	248.4	203	87.08307229	0	Open	;
P932	J17	J399	381.56	203	84.96153948	0	Open	;
P933	J371	J23	130.54	305	87.94687626	0	Open	;
P934	J23	J385	18.46	254	102.9935452	0	Open	;
P935	J385	J22	152.13	305	100.0547405	0	Open	;
P937	J385	J251	198.09	254	74.27786438	0	Open	;
P938	J251	J257	168.95	254	74.4754521	0	Open	;
P939	J26	J25	248.76	152	95.78927854	0	Open	;
P94	J123	J145	51.35	305	139.0834768	0	Open	;
P940	J25	J27	187.99	152	99.28214747	0	Open	;
P941	J27	J30	142.58	152	79.37276275	0	Open	;
P942	J26	J27	85.08	152	83.59468263	0	Open	;
P943	J81	J28	84.21	76	86.77484454	0	Open	;
P944	J26	J31	59.58	254	82.35304046	0	Open	;
P946	J30	J31	143.03	102	98.06099167	0	Open	;

P947	J28	J32	122.43	152	76.80448613	0	Open	;
P948	J32	J29	74.71	152	104.8490736	0	Open	;
P949	J31	J35	24.39	254	92.68704895	0	Open	;
P95	J140	J145	50.7	305	118.4307393	0	Open	;
P951	J257	J37	338.8	254	94.71306209	0	Open	;
P953	J37	J35	495.66	254	85.4054411	0	Open	;
P954	J36	J34	294.07	203	78.6689048	0	Open	;
P955	J34	J33	131.74	102	85.18129613	0	Open	;
P956	J34	J38	115.17	152	68.25287125	0	Open	;
P957	J38	J33	51.05	152	98.15140681	0	Open	;
P958	J38	J32	122.41	102	105.3080501	0	Open	;
P959	J33	J28	123.42	102	98.22065346	0	Open	;
P96	J414	J417	53.72	254	87.90275096	0	Open	;
P961	J444	J366	234.55	203	85.65392299	0	Open	;
P962	J6	J1058	49.83	152	90.74777544	0	Open	;
P963	J366	J205	93.54	203	85.5303454	0	Open	;
P964	J205	J369	129.91	152	96.26374712	0	Open	;
P965	J205	J367	135.06	203	93.94273938	0	Open	;
P966	J367	J206	31.32	203	82.50879936	0	Open	;
P967	J206	J200	207.54	203	82.10707555	0	Open	;
P968	J200	J198	68.17	102	78.39635991	0	Open	;
P969	J200	J1154	149.16	203	86.26720664	0	Open	;
P97	J154	J155	24.41	610	88.89531663	0	Open	;
P970	J1154	J199	165.04	203	87.79507815	0	Open	;
P971	J367	J370	136.94	152	77.82946049	0	Open	;
P972	J370	J1158	219.42	152	82.66945023	0	Open	;
P973	J1158	J365	164.68	203	71.9318762	0	Open	;
P974	J365	J444	186.4	203	72.71874828	0	Open	;
P975	J369	J365	159.56	152	74.72359293	0	Open	;
P976	J359	J358	83.33	76	83.20228114	0	Open	;
P977	J89	J91	45.98	102	102.4316821	0	Open	;
P978	J358	J355	178.97	76	78.85562406	0	Open	;
P98	J156	J154	174.53	610	71.75234195	0	Open	;
P981	J361	J351	36.19	76	80.21622813	0	Open	;
P982	J351	J349	87.24	203	98.51140755	0	Open	;
P983	J349	J352	180.2	101.6	91.89644795	0	Open	;
P984	J349	J381	16.03	101.6	108.9554876	0	Open	;
P986	J381	J348	229.54	101.6	87.08395905	0	Open	;
P987	J348	J232	94.56	101.6	96.40637069	0	Open	;
P988	J232	J382	9.74	101.6	102.5172429	0	Open	;
P989	J1153	J1155	91.59	51	82.07033197	0	Open	;
P99	J110	J109	452.37	508	96.63823156	0	Open	;
P990	J1155	J1154	78.87	102	85.78766419	0	Open	;
P991	J214	J202	20.25	203	74.3133426	0	Open	;
P992	J202	J314	69.15	203	80.64075409	0	Open	;
P993	J314	J199	63.52	203	80.23202717	0	Open	;
P994	J199	J1157	115.39	203	83.09435479	0	Open	;
P995	J1157	J201	228.99	152	82.49961346	0	Open	;
P996	J332	J201	10.22	203	84.57606945	0	Open	;
P997	J201	J308	154.87	203	96.61744961	0	Open	;
P998	J308	J204	107.98	203	90.64077339	0	Open	;
P999	J203	J341	81.67	254	68.70464794	0	Open	;

## [PUMPS]

;ID	Node1	Node2	Parameters
PU1	J285	J273	HEAD 8 ;
PU2	J280	J269	HEAD 8 ;
PU3	J276	J274	HEAD 8 ;
PU4	J299	J292	HEAD 9 ;
PU5	J300	J256	HEAD 9 ;
PU6	J289	J415	HEAD 10 ;
PU7	J290	J291	HEAD 10 ;
PU8	J301	J304	HEAD 9 ;
PU9	J302	J306	HEAD 9 ;
PU10	J307	J317	HEAD 11 ;
PU11	J309	J323	HEAD 11 ;

## [VALVES]

;ID	Node1	Node2	Diameter	Type	Setting	MinorLoss
v1	J35	J88	203.2	PRV	40	0.0000 ;
V45	J253	J130	152.4	PRV	40	0.0000 ;
V47	J129	J169	101.6	PRV	40	0.0000 ;



V2 J14 J422 254 TCV 0 0 ;

[TAGS]

[DEMANDS]

:Junction Demand Pattern Category

[STATUS]

:ID Status/Setting  
 PU1 Closed  
 PU3 Closed  
 PU4 Closed  
 PU5 Closed  
 PU6 Closed  
 PU7 Closed  
 PU8 Closed  
 PU9 Closed  
 PU10 Closed  
 PU11 Closed  
 V2 Closed

[PATTERNS]

:ID Multipliers

```

DMA1_pat 0.5691504 0.46466868 0.43854825 0.3604161 0.309779115 0.334524795
DMA1_pat 0.384703515 0.471542475 0.55013289 0.680505915 0.70364769 0.67088259
DMA1_pat 0.79690221 0.719915685 0.770552655 0.73847493 0.81477408 0.72426909
DMA1_pat 0.806983785 0.779259465 0.866785815 0.740766195 0.67042434 0.632389335
DMA1_pat 0.52252044 0.506709855 0.445588455 0.45465063 0.47547432 0.53389635
DMA1_pat 0.662501925 0.62239704 0.67599876 0.72593706 0.803061855 0.70144995
DMA1_pat 0.69335184 0.653825385 0.621432975 0.65228289 0.571880295 0.57901434
DMA1_pat 0.58209933 0.711668985 0.70453494 0.665779725 0.741747645 0.692194965
DMA1_pat 0.72708954 0.619247205 0.46304505 0.45095511 0.309260895 0.282421215
DMA1_pat 0.433303785 0.40670589 0.545014905 0.69928266 0.739904895 0.6434271
DMA1_pat 0.680905935 0.691061505 0.67727895 0.626259375 0.626742975 0.7142742
DMA1_pat 0.681873135 0.788264685 0.75779802 0.788264685 0.802047225 0.845571045
DMA1_pat 0.604884255 0.443633715 0.5131584 0.36476118 0.31782714 0.463887405
DMA1_pat 0.39572595 0.64149669 0.671098245 0.668761275 0.79456785 0.674603685
DMA1_pat 0.754255215 0.808394895 0.713747835 0.68570427 0.68122509 0.549576105
DMA1_pat 0.68219883 0.569829795 0.74334939 0.832154025 0.67888812 0.746270595
DMA1_pat 0.601325505 0.503529285 0.51908778 0.35946171 0.29924835 0.453216765
DMA1_pat 0.42957594 0.539495655 0.896330625 0.89673474 0.682552935 0.57990732
DMA1_pat 0.428969775 0.4200792 0.62941161 0.691039395 0.670631505 0.618904575
DMA1_pat 0.682552935 0.832884315 0.90279648 0.821771115 0.84945309 0.691039395
DMA1_pat 0.716292135 0.54775281 0.53349507 0.419645895 0.35601804 0.33814266
DMA1_pat 0.45241743 0.509874015 0.56456418 0.760767795 0.62159517 0.67820055
DMA1_pat 0.6928839 0.639257745 0.619892745 0.659686755 0.65628192 0.631809675
DMA1_pat 0.604145385 0.70394961 0.772471905 0.88546986 0.88334184 0.752042895
DMA1_pat 0.71409849 0.457925235 0.446544345 0.42936957 0.40184853 0.43309422
DMA1_pat 0.469926885 0.52227894 0.590771145 0.754862745 0.67996827 0.644778585
DMA1_pat 0.73210098 0.70954614 0.548144565 0.577734855 0.592426545 0.624499935
DMA1_pat 0.55973238 0.766864395 0.716995455 0.77452062 0.90446958 0.85749759
;
DMA2_pat 0.61842105 0.45394737 0.444736845 0.3381579 0.31578948 0.313157895
DMA2_pat 0.414473685 0.448684215 0.49868421 0.58157895 0.684210525 0.72763158
DMA2_pat 0.669736845 0.79210527 0.66842106 0.815789475 0.771052635 0.830263155
DMA2_pat 0.807894735 0.793421055 0.83552631 0.83684211 0.677631585 0.661842105
DMA2_pat 0.567746055 0.470813805 0.470813805 0.42607584 0.428206215 0.474009375
DMA2_pat 0.57946314 0.623135925 0.683851725 0.774392835 0.77119728 0.79569663
DMA2_pat 0.66254793 0.73604601 0.71154666 0.59544099 0.63485301 0.616744785
DMA2_pat 0.58159353 0.596506185 0.700894755 0.650830845 0.71580741 0.73178526
DMA2_pat 0.681082545 0.73368099 0.49901097 0.373583895 0.315590715 0.276479055
DMA2_pat 0.347959005 0.461247975 0.528681885 0.625786725 0.66894444 0.7647006
DMA2_pat 0.66624708 0.651411615 0.75660852 0.561050175 0.655457655 0.64466823
DMA2_pat 0.71614818 0.840226575 0.771443985 0.790325475 0.848318655 0.821345085
DMA2_pat 0.66520308 0.501646545 0.49286499 0.41602635 0.361141605 0.437980245
DMA2_pat 0.394072455 0.654226125 0.60592755 0.81119649 0.769484085 0.64324917
DMA2_pat 0.69703623 0.67618002 0.70801317 0.70801317 0.705817785 0.538968165
DMA2_pat 0.58068057 0.565312845 0.75411636 0.825466515 0.693743145 0.795633365
DMA2_pat 0.75185274 0.5080086 0.48529764 0.380109975 0.33707865 0.39445374
DMA2_pat 0.48410232 0.64188381 0.812813775 0.84628257 0.68252451 0.59287593
DMA2_pat 0.42553191 0.41955534 0.583313415 0.6239541 0.58689936 0.562993065
DMA2_pat 0.659813535 0.811618455 0.811618455 0.882142005 0.85823571 0.857040405
DMA2_pat 0.670350795 0.574243155 0.502162425 0.43248438 0.373618455 0.35439693
DMA2_pat 0.467323395 0.46612206 0.59346468 0.717203265 0.58625661 0.58625661
DMA2_pat 0.6811629 0.647525235 0.68957232 0.716001915 0.70759251 0.68236425
DMA2_pat 0.660740025 0.734022105 0.806102835 0.796492065 0.8421432 0.71239788
DMA2_pat 0.59427819 0.4651884 0.494262675 0.44541789 0.326794845 0.512870205
DMA2_pat 0.514033185 0.525662895 0.58264848 0.60125601 0.77919057 0.66289347
DMA2_pat 0.68266398 0.72918282 0.5896263 0.603581955 0.588463335 0.65940456
DMA2_pat 0.625678395 0.6977826 0.78267948 0.81756861 0.929213835 0.789657315
;
DMA3_pat 0.54445029 0.481325625 0.422146245 0.35507628 0.32351394 0.359021565
DMA3_pat 0.41031036 0.47343504 0.56023146 0.67464492 0.75355077 0.729879015
DMA3_pat 0.670699635 0.7338243 0.70620726 0.76144134 0.714097845 0.83640189
DMA3_pat 0.871909515 0.7377696 0.725933715 0.74960547 0.670699635 0.7338243
DMA3_pat 0.587013555 0.426322695 0.44271972 0.413205075 0.432881505 0.491910795
DMA3_pat 0.554219505 0.67883691 0.754263225 0.74442501 0.795616085 0.682116315
    
```

DMA3_pat	0.695233935	0.646042845	0.593572365	0.59685177	0.639484035	0.646042845
DMA3_pat	0.64276344	0.682116315	0.728027985	0.67883691	0.69195453	0.75754263
DMA3_pat	0.7140936	0.70199031	0.50430339	0.395373855	0.314685315	0.28644432
DMA3_pat	0.41958042	0.431683695	0.49623453	0.697955895	0.58902636	0.693921465
DMA3_pat	0.693921465	0.766541145	0.693921465	0.5809575	0.70602474	0.70199031
DMA3_pat	0.66568047	0.823023135	0.738300165	0.859332975	0.814954275	0.71005917
DMA3_pat	0.60602679	0.485491065	0.455357145	0.391741065	0.368303565	0.411830355
DMA3_pat	0.408482145	0.662946335	0.602678565	0.703125	0.65959821	0.619419645
DMA3_pat	0.709821435	0.810267855	0.763392855	0.8203125	0.763392855	0.599330355
DMA3_pat	0.6796875	0.60602679	0.689732145	0.813616065	0.703125	0.666294645
DMA3_pat	0.622706415	0.57454128	0.454128435	0.36811926	0.330275235	0.44036697
DMA3_pat	0.4059633	0.61926606	0.89105505	0.94610091	0.739678905	0.564220185
DMA3_pat	0.457568805	0.40252293	0.670871565	0.64678899	0.591743115	0.557339445
DMA3_pat	0.622706415	0.82568808	0.89105505	0.85321101	0.75344037	0.770642205
DMA3_pat	0.745526835	0.59269383	0.48832008	0.380218695	0.335487075	0.37649106
DMA3_pat	0.44731611	0.562872765	0.525596415	0.71570577	0.63742545	0.58151094
DMA3_pat	0.674701785	0.667246515	0.63742545	0.641153085	0.67097415	0.68588469
DMA3_pat	0.6001491	0.730616295	0.8499006	0.86853876	0.84244533	0.7417992
DMA3_pat	0.6641934	0.527764485	0.513403545	0.45955002	0.359023455	0.477501195
DMA3_pat	0.527764485	0.56366682	0.610339875	0.63547152	0.8006223	0.71804691
DMA3_pat	0.61393011	0.60674964	0.62111058	0.61393011	0.71804691	0.574437525
DMA3_pat	0.581617995	0.667783635	0.678554325	0.91550982	0.825753945	0.72522738
:						
DMA4_pat	0.52452531	0.448575945	0.43670886	0.31803798	0.31803798	0.327531645
DMA4_pat	0.424841775	0.43196202	0.574367085	0.664556955	0.69066456	0.740506335
DMA4_pat	0.761867085	0.764240505	0.71914557	0.68591772	0.828322785	0.828322785
DMA4_pat	0.74525316	0.80933544	0.830696205	0.702531645	0.77373417	0.65031645
DMA4_pat	0.497324115	0.45033285	0.438585045	0.4346691	0.426837225	0.532567545
DMA4_pat	0.634381935	0.708784755	0.76360788	0.71661663	0.761649915	0.79493538
DMA4_pat	0.76948179	0.62655006	0.59913849	0.58347474	0.60109647	0.59326458
DMA4_pat	0.56781099	0.59326458	0.628508025	0.771439755	0.698994915	0.8066832
DMA4_pat	0.731355255	0.66639936	0.534081795	0.39695268	0.324779475	0.257417805
DMA4_pat	0.423416205	0.43785084	0.548516445	0.69286287	0.61347234	0.75060144
DMA4_pat	0.772253415	0.673616685	0.695268645	0.663993585	0.579791505	0.685645545
DMA4_pat	0.67121091	0.83239776	0.73857258	0.878107455	0.75060144	0.680833995
DMA4_pat	0.67206477	0.487854255	0.530364375	0.414979755	0.346153845	0.421052625
DMA4_pat	0.467611335	0.578947365	0.65991903	0.710526315	0.720647775	0.619433205
DMA4_pat	0.71862348	0.71255061	0.763157895	0.70850202	0.6659919	0.526315785
DMA4_pat	0.62955465	0.63360324	0.716599185	0.76518219	0.7611336	0.769230765
DMA4_pat	0.716646015	0.584469225	0.499793475	0.396530355	0.311854605	0.452292435
DMA4_pat	0.4378356	0.607187115	0.824039655	0.830235435	0.745559685	0.6464271
DMA4_pat	0.419248245	0.46468401	0.59066502	0.636100785	0.59273028	0.660883935
DMA4_pat	0.70425444	0.743494425	0.75175548	0.81164808	0.875671215	0.695993385
DMA4_pat	0.66012042	0.58486239	0.498853215	0.432196095	0.341886465	0.348337155
DMA4_pat	0.46875	0.520355505	0.53110665	0.64076835	0.645068805	0.58056192
DMA4_pat	0.6880734	0.73107798	0.733228215	0.66227064	0.66012042	0.642918585
DMA4_pat	0.62141628	0.75258027	0.78698394	0.80633601	0.84073968	0.82138761
DMA4_pat	0.592819365	0.473838015	0.46131366	0.45505149	0.37364319	0.44670192
DMA4_pat	0.457138875	0.475925415	0.651266355	0.738936825	0.72641247	0.707625945
DMA4_pat	0.66170331	0.64500417	0.638742	0.617868075	0.66170331	0.642916785
DMA4_pat	0.6324979815	0.713888115	0.778597275	0.74311161	0.930976905	0.77233509
:						
DMA5_pat	0.536089695	0.44148564	0.40732305	0.28644009	0.32323056	0.33111423
DMA5_pat	0.3679047	0.504555015	0.588647505	0.622810095	0.725297835	0.73843728
DMA5_pat	0.769971975	0.69376314	0.69376314	0.75946041	0.814646115	0.806762445
DMA5_pat	0.851436585	0.814646115	0.76734408	0.71478627	0.79887876	0.64120533
DMA5_pat	0.55547391	0.49559886	0.454077885	0.436443795	0.49816311	0.53122704
DMA5_pat	0.61058046	0.601763415	0.745040415	0.745040415	0.689933865	0.68111682
DMA5_pat	0.654665685	0.68111682	0.62821455	0.59515062	0.63923586	0.614988975
DMA5_pat	0.65686995	0.58853784	0.614988975	0.740631885	0.826598085	0.71418075
DMA5_pat	0.766876695	0.70477047	0.4860486	0.36723672	0.30783078	0.30783078
DMA5_pat	0.40774077	0.44824482	0.50495049	0.68316831	0.66426642	0.73987398
DMA5_pat	0.69396939	0.64266426	0.772277235	0.55355535	0.58865886	0.758775885
DMA5_pat	0.65346534	0.826282635	0.818181825	0.815481555	0.812781285	0.6750675
DMA5_pat	0.655253835	0.45823494	0.52021842	0.354191265	0.34312278	0.438311685
DMA5_pat	0.45823494	0.626475795	0.668536005	0.75044274	0.719451	0.697314045
DMA5_pat	0.768152295	0.803571435	0.63311688	0.66410862	0.728305785	0.59327037
DMA5_pat	0.672963405	0.66632232	0.60655254	0.799144035	0.7216647	0.653040135
DMA5_pat	0.6371388	0.55660824	0.558976785	0.41686404	0.305542395	0.42870678
DMA5_pat	0.41686404	0.59687352	0.779251545	0.83135955	0.743723355	0.67740408
DMA5_pat	0.45712932	0.414495495	0.549502605	0.575556615	0.618190425	0.603979155
DMA5_pat	0.667929885	0.81951681	0.78162009	0.902415915	0.878730465	0.78162009
DMA5_pat	0.702570165	0.57067974	0.454007445	0.426107535	0.367771395	0.352553265
DMA5_pat	0.443862015	0.50219817	0.598579635	0.733006425	0.6898884	0.58336152
DMA5_pat	0.765979035	0.613797765	0.644234025	0.649306725	0.644234025	0.62394318
DMA5_pat	0.593506935	0.76090632	0.763442685	0.88011498	0.84206967	0.79387893
DMA5_pat	0.59737737	0.48324429	0.44924721	0.43224867	0.3569694	0.446818845
DMA5_pat	0.50024283	0.5755221	0.66779991	0.752792625	0.755220975	0.628946085
DMA5_pat	0.721223895	0.66294318	0.541525005	0.55852356	0.582807195	0.67022826
DMA5_pat	0.672656625	0.66779991	0.755220975	0.88392423	0.847498785	0.78921807

[CURVES]

:ID	X-Value	Y-Value
:PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP:		
6	16.88889	156.7
6	19.5	146.5
6	22.13889	136.2
6	25.94445	117.9
6	33.33334	50
:PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP:		
7	18.25	75
7	23.38889	64

```

7          30.63889      46
7          38.88889      0
:PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP:
4          30.12222      221.76
4          37.63612      202.41
4          43.73056      182.16
4          47.22223      160
:PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP:
5          31.91389      217.27
5          37.87778      201.91
5          42.55278      187.15
5          50           140
:PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP:
2          9.888889      72.2
2          12.52778      62.3
2          13.33333      57.9
2          18.05556      0
:PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP:
3          11.30278      76.59
3          12.65833      68.19
3          14.03056      60.29
3          18.05556      0
:PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP: PUMP:
1          3.997222      64.86
1          41.90556      48.48
1          56.13611      43.96
1          69.46667      39.56
1          77.29445      34.53
1          97.66111      28.83
1          138.8889      1
:PUMP: PUMP:
8          0           70
8          60          50
8          100         30
:PUMP: PUMP:
9          0           90
9          30          70
9          50          30
:PUMP: PUMP:
10         0           120
10         30          110
10         70          30
:PUMP: PUMP:
11         0           90
11         30          50
11         40          10

```

## [CONTROLS]

```

;----- Tank 1 -----
LINK      PU1 OPEN IF  NODE    T1      BELOW    4
LINK      PU1 CLOSED IF NODE   T1      ABOVE    6.3

LINK      PU2 OPEN IF  NODE    T1      BELOW    1
LINK      PU2 CLOSED IF NODE   T1      ABOVE    4.5

;----- Valve to T2 ---
LINK      V2 OPEN IF  NODE    T2      BELOW    .5
LINK      V2 CLOSED IF NODE   T2      ABOVE    5.5

;----- T3 ---
LINK      PU4 OPEN IF  NODE    T3      BELOW    3
LINK      PU4 CLOSED IF NODE   T3      ABOVE    5.3

LINK      PU5 OPEN IF  NODE    T3      BELOW    1
LINK      PU5 CLOSED IF NODE   T3      ABOVE    3.5

;----- T4 ---
LINK      PU6 OPEN IF  NODE    T4      BELOW    2
LINK      PU6 CLOSED IF NODE   T4      ABOVE    3.5

LINK      PU7 OPEN IF  NODE    T4      BELOW    3
LINK      PU7 CLOSED IF NODE   T4      ABOVE    4.5

```

```

;----- T5 ---
LINK  PU8 OPEN IF NODE    T5    BELOW    1.5
LINK  PU8 CLOSED IF NODE  T5    ABOVE    4.5

;----- T7 ---
LINK  PU10 OPEN IF NODE   T7    BELOW    2.5
LINK  PU10 CLOSED IF     NODE   T7    ABOVE    4.8

LINK  PU11 OPEN IF NODE   T7    BELOW    1
LINK  PU11 CLOSED IF     NODE   T7    ABOVE    3

```

[RULES]

[ENERGY]

```

Global Efficiency  70.0000
Global Price      0
Demand Charge     0.0000
Pump  PU1         Price  1.0000
Pump  PU2         Price  1.0000
Pump  PU3         Price  1.0000
Pump  PU4         Price  1.0000
Pump  PU5         Price  1.0000
Pump  PU6         Price  1.0000
Pump  PU7         Price  1.0000
Pump  PU8         Price  1.0000
Pump  PU9         Price  1.0000
Pump  PU10        Price  1.0000
Pump  PU11        Price  1.0000

```

[EMITTERS]

```

;Junction          Coefficient

```

[QUALITY]

```

;Node              InitQual

```

[SOURCES]

```

;Node              Type      Quality  Pattern

```

[REACTIONS]

```

;Type  Pipe/Tank    Coefficient

```

[REACTIONS]

```

Order Bulk        1.00
Order Tank        1.00
Order Wall        1
Global Bulk       0.000000
Global Wall       0.000000
Limiting Potential 0
Roughness Correlation 0

```

[MIXING]

```

;Tank              Model

```

[TIMES]

```

Duration          168:00
Hydraulic Timestep 0:15
Quality Timestep  0:05
Pattern Timestep  1:00
Pattern Start     0:00
Report Timestep   1:00
Report Start      0:00
Start ClockTime   0:00:00
Statistic         NONE

```

[REPORT]

```

Status           No
Summary          No
Page             0

```

[OPTIONS]

Units	LPS
Headloss	H-W
Specific Gravity	1.000000
Viscosity	1.000000
Trials	100
Accuracy	0.01000000
CHECKFREQ	2
MAXCHECK	10
DAMPLIMIT	0
Unbalanced	Continue 10
Pattern	1
Demand Multiplier	1
Emitter Exponent	0.5000
Quality	NONE mg/L
Diffusivity	1.000000
Tolerance	0.01000000

## [COORDINATES]

:Node	X-Coord	Y-Coord
J511	-246643.52	150768.11
J411	-248212.98	148750.19
J414	-247493.99	148416.24
J415	-246594.18	149477.91
J416	-246486.73	149817.86
J417	-247408.47	148278.46
J418	-246985.61	148482.76
J419	-246866.83	148824.85
J310	-247788.57	148853.36
J311	-247845.59	148962.64
J312	-247850.34	149138.43
J313	-247802.83	149048.16
J314	-248553.52	149542.29
J315	-248634.29	149613.56
J316	-248943.12	149247.71
J318	-247964.37	148976.89
J319	-248030.89	148896.12
J210	-248791.08	149048.16
J211	-248900.36	149390.25
J212	-248672.30	149242.96
J214	-248495.29	148973.68
J217	-248681.81	149471.02
J218	-248767.33	149299.98
J219	-247413.22	150126.69
J110	-247921.61	147893.61
J420	-246919.09	148962.64
J421	-247060.44	148293.87
J422	-246957.10	148767.84
J1153	-247793.32	149509.03
J1154	-247988.12	149547.04
J1155	-247874.09	149551.79
J425	-246759.83	149576.07
J426	-246649.40	149729.45
J1157	-247870.26	149649.69
J427	-246649.40	149594.48
J1158	-247931.11	149437.76
J428	-247978.62	148382.99
J429	-248002.38	148297.46
J320	-247617.53	148915.13
J321	-247555.76	148763.09
J322	-247451.23	148767.84
J324	-247545.10	148625.15
J1056	-248271.79	148956.04
J327	-247684.04	148981.64
J1058	-246843.07	148050.40
J328	-247589.02	149057.66
J329	-247517.75	149086.17
J220	-247384.72	150017.41
J221	-247650.79	149356.99
J225	-249057.15	149171.69
J226	-249218.70	149029.16
J50	-247845.59	149276.22
J51	-247788.57	149366.49

---

J53	-247612.78	150639.83
J54	-247723.02	150717.18
J128	-247446.48	151143.46
J55	-247802.77	150140.49
J129	-247140.19	151214.11
J56	-247608.02	150250.23
J57	-247527.25	150155.20
J58	-247688.80	150388.01
J59	-247551.01	149960.40
J1160	-247379.97	148131.17
J1161	-247194.67	148226.19
J431	-247802.83	148088.41
J432	-247579.52	148159.68
J433	-247741.06	148235.70
J434	-247935.86	148487.51
J435	-248007.13	148107.41
J436	-247973.87	148230.95
J438	-248026.13	148644.30
J1169	-246120.89	148877.12
J439	-248030.89	148449.50
J330	-247636.53	149143.19
J331	-247598.52	149214.45
J332	-247538.97	149631.29
J333	-248368.22	149946.15
J334	-248262.89	150005.52
J335	-248506.01	149941.39
J336	-248648.55	149912.89
J337	-248857.60	149722.84
J231	-247037.88	148853.36
J232	-247132.90	148843.86
J233	-246827.31	149717.18
J234	-246913.17	149873.54
J236	-247281.30	150502.45
J237	-247408.47	150445.03
J130	-247698.30	151076.94
J131	-247109.52	151079.14
J132	-247199.42	150943.91
J133	-247280.19	150967.66
J60	-247484.49	150055.42
J134	-246919.09	150364.26
J135	-246995.51	149926.48
J62	-247650.79	150131.44
J64	-247565.26	150720.60
J65	-247446.94	150674.23
J66	-247612.78	150426.02
J67	-247630.99	150551.53
J68	-247855.09	150658.83
J69	-247950.11	150497.29
J1170	-246291.93	148881.87
J441	-246519.12	149644.17
J444	-248244.69	149157.44
J341	-248610.54	149798.86
J344	-246282.43	148739.33
J345	-246149.39	148739.33
J347	-246396.46	148748.83
J348	-247151.91	148725.08
J349	-247322.95	148853.36
J241	-247455.99	150273.98
J242	-247322.95	150226.47
J243	-247342.65	150152.76
J244	-247470.24	150364.26
J245	-247551.24	150367.49
J246	-247037.88	150516.30
J247	-247170.87	150477.91
J248	-247033.12	150316.74
J249	-247208.92	150378.51
J142	-248363.47	148668.06
J143	-248558.27	148729.83
J70	-248011.88	150435.52
J144	-248696.06	148672.81
J71	-247888.66	150796.93
J72	-248040.39	150692.09

---

J73	-247796.64	150778.53
J74	-248078.40	150616.07
J76	-247851.85	150447.24
J77	-247969.12	150777.61
J78	-247912.10	149337.99
J350	-246111.38	149062.41
J351	-247417.98	148896.12
J352	-247223.17	149005.40
J353	-247351.46	149033.91
J354	-247541.51	148881.87
J355	-247305.84	148569.94
J358	-247246.93	148653.81
J359	-247170.91	148630.05
J250	-247299.19	150311.99
J251	-246796.64	150257.06
J252	-246486.73	150240.72
J253	-247436.98	151034.18
J254	-247565.26	151152.96
J257	-246638.77	150207.46
J154	-246391.71	147798.58
J155	-246500.98	147798.58
J82	-247893.10	149204.95
J156	-246301.43	147793.83
J83	-247940.61	149081.42
J84	-247189.27	150152.76
J85	-247201.54	150269.33
J159	-246692.34	147821.47
J86	-247256.43	150050.67
J87	-247056.88	150026.92
J89	-247341.96	151305.00
J360	-247227.93	148530.27
J361	-247398.97	148611.05
J362	-247408.47	149124.18
J363	-246532.83	149938.04
J364	-246649.40	149876.69
J365	-248230.44	149309.48
J366	-248344.47	149247.71
J1208	-247256.43	149157.44
J367	-248477.50	149399.75
J369	-248287.45	149361.74
J160	-246577.00	147812.84
J161	-246961.86	147675.05
J162	-246771.81	147513.51
J163	-247227.93	147803.33
J164	-246871.58	147675.05
J91	-247262.89	151306.14
J165	-246895.34	147770.08
J166	-246895.34	147556.27
J167	-246890.59	147432.74
J94	-245797.80	148363.98
J95	-247774.32	147884.11
J96	-247622.28	147950.62
J97	-247717.30	147964.88
J976	-248468.00	148706.07
J571	-247099.64	150635.08
J572	-247164.73	150717.18
J573	-247361.05	151207.98
J574	-247441.73	151243.24
J575	-247161.41	150858.38
J576	-246937.74	150539.26
J370	-248173.42	149447.26
J371	-246630.99	150054.60
J372	-249128.42	148934.13
J373	-249180.69	148843.86
J374	-248981.13	148934.13
J375	-249014.39	149090.92
J376	-249128.42	149067.17
J377	-248800.59	148900.87
J1219	-247660.29	147741.57
J379	-249275.71	148929.38
J171	-247332.45	147546.77
J172	-247199.42	147485.00

---

J173	-247332.45	147751.07
J174	-247109.14	147432.74
J175	-247085.39	147575.27
J177	-247622.28	147808.09
J179	-247774.32	147817.59
J580	-246686.28	150677.84
J486	-246995.11	150801.37
J487	-247066.57	150876.69
J488	-246974.55	150686.50
J489	-247080.64	150986.67
J381	-247322.95	148739.33
J1223	-248795.84	149190.70
J382	-247118.65	148948.38
J384	-247161.41	149214.45
J385	-246876.33	150098.19
J180	-247227.93	147570.52
J181	-247123.40	147698.81
J1024	-248287.45	148587.29
J183	-247408.47	147708.31
J1025	-248225.69	148468.51
J186	-247413.22	147627.54
J187	-247265.94	147622.79
J188	-247536.76	147565.77
J189	-247446.48	147561.02
J490	-246876.39	150753.99
J491	-247072.71	150784.66
J492	-246913.20	150858.28
J493	-247226.08	151054.60
J494	-246771.81	150668.33
J495	-246881.08	150616.07
J496	-246781.31	150511.54
J497	-246765.96	150803.07
J498	-246857.33	150483.04
J500	-246610.26	150920.15
J499	-246471.48	150925.77
J501	-246440.81	150864.42
J502	-246391.73	150956.44
J503	-246462.97	150782.36
J504	-246538.97	151036.20
J394	-246173.15	149604.06
J509	-246325.19	150806.12
J399	-246287.43	149888.96
J401	-246348.78	149809.20
J406	-246201.54	149661.96
J295	-248026.13	149290.47
J407	-246424.96	149665.82
J296	-248116.41	149228.71
J408	-248235.19	148268.96
J297	-247536.76	149299.98
J298	-247712.55	149242.96
J191	-247479.74	147461.24
J303	-247897.85	148858.11
J192	-247033.12	147850.85
J193	-246957.10	147926.87
J305	-247817.08	148758.33
J194	-247493.99	147793.83
J195	-247584.27	147651.29
J196	-247375.21	147850.85
J308	-248005.22	149796.93
J198	-248311.21	149594.55
J200	-248149.67	149547.04
J199	-248250.62	149698.77
J201	-247741.42	149704.91
J202	-248591.53	149366.49
J203	-248734.07	149594.55
J204	-248306.46	149798.86
J205	-248472.75	149314.23
J206	-248339.72	149513.78
J207	-248477.50	149499.53
J208	-248843.35	149613.56
J101	-247926.36	148017.14
J102	-247812.33	147993.38



---

J109	-248045.14	148007.64
J1	-247075.89	147770.08
J2	-247536.76	147694.06
J3	-247265.94	148064.65
J4	-247508.25	148007.64
J5	-247641.28	148045.65
J6	-247042.63	147988.63
J7	-247170.91	147964.88
J8	-246990.36	148221.44
J9	-247109.14	148164.43
J10	-247926.36	148178.68
J11	-247836.08	148411.49
J12	-247579.52	148363.98
J13	-247731.56	148554.03
J14	-247132.90	148463.76
J15	-246353.70	149570.80
J16	-246258.67	149437.76
J17	-246287.43	149729.45
J18	-246256.76	149551.53
J19	-246404.00	149459.51
J20	-246238.35	149778.53
J21	-246391.71	149974.65
J22	-246815.04	149974.85
J23	-246759.83	150011.66
J25	-246115.65	150361.35
J26	-246152.46	150250.92
J27	-246211.16	150440.28
J28	-246054.37	149418.76
J29	-245864.32	149732.34
J30	-246268.17	150373.76
J31	-246277.68	150259.73
J32	-245750.29	149485.27
J33	-246072.71	149563.80
J34	-245949.84	149699.08
J35	-246238.35	150097.55
J36	-245935.59	149808.36
J37	-246538.99	150083.93
J38	-245907.06	149600.61
J24	-249004.89	149756.10
J39	-249114.17	149808.36
J40	-248909.87	149033.91
J123	-245474.72	148321.22
J140	-245517.48	148444.75
J141	-245579.24	148363.98
J157	-245688.52	148316.47
J158	-245588.75	148202.44
J168	-245892.83	148397.24
J170	-246021.11	148354.48
J176	-245987.85	148511.27
J178	-245888.07	148482.76
J184	-245745.54	148459.01
J185	-246078.12	148573.04
J190	-246196.91	148539.78
J197	-246358.45	148554.03
J213	-246201.66	148401.99
J215	-246258.67	148644.30
J216	-246448.72	148587.29
J227	-246557.37	148643.56
J238	-246698.48	148643.56
J239	-246524.74	148834.35
J255	-246396.46	148948.38
J256	-246771.81	148824.85
J258	-246567.50	148516.02
J260	-246296.68	148976.89
J265	-245959.34	148706.07
J266	-245945.09	148905.62
J267	-247465.49	148976.89
J61	-247916.86	150582.81
J92	-247857.99	150551.53
J268	-247992.88	149195.45
J278	-246662.53	150506.79
J281	-246458.22	150573.31

J283	-246524.74	150682.59
J284	-246330.38	150600.61
J136	-247256.76	151232.52
J137	-247185.16	147641.79
J145	-245403.45	148430.50
J118	-247765.96	150269.33
J52	-247052.13	148710.82
J81	-246164.73	149312.27
J88	-246072.71	149827.61
J90	-246581.76	150316.74
J93	-246379.46	150201.84
J147	-247275.44	150663.58
J148	-247798.07	151015.18
J149	-247790.50	151122.09
J150	-247913.20	151048.47
J151	-247527.25	151262.24
J152	-246802.77	151183.44
J153	-247600.32	151293.87
J169	-246888.66	151109.82
J182	-246833.44	150987.12
J222	-246833.44	151115.95
J224	-246735.29	151097.55
J230	-247956.14	148717.18
J235	-247969.12	148829.60
J240	-246342.65	150698.77
J269	-246215.91	147789.08
J273	-246215.91	147936.37
J274	-246215.91	147665.55
J276	-246040.11	147665.55
J280	-246044.87	147793.83
J285	-246044.87	147936.37
J287	-246866.83	149090.92
J288	-246657.78	149109.93
J289	-246743.30	149238.21
J290	-246586.51	149204.95
J291	-246496.02	149416.56
J292	-246657.78	148791.59
J299	-246596.01	148948.38
J300	-246672.03	149014.90
J301	-247232.22	149649.69
J302	-247066.38	149722.84
J304	-247394.22	149827.36
J306	-247265.94	149903.38
J307	-246942.85	149566.05
J309	-247094.89	149613.56
J317	-247023.62	149361.74
J323	-247170.91	149409.25
R1	-245840.56	147793.83
T3	-246422.40	148459.51
T1	-249114.17	149950.90
T7	-247541.51	149418.76
T6	-247033.12	149124.18
T5	-247570.01	150863.14
T2	-246845.71	148674.23
T4	-246160.35	150738.12

## [VERTICES]

:Link	X-Coord	Y-Coord
-------	---------	---------

## [LABELS]

:X-Coord	Y-Coord	Label & Anchor Node
-245964.09	147727.31	"Source" R1
-246572.25	148116.92	"Pumping Station S1" J285
-249280.46	150121.94	"Tank T1" T1
-247584.27	149585.05	"T7" T7
-246904.84	148601.54	"T2" T2
-251418.52	149865.37	"Tank T3"
-246462.97	148382.99	"T3" T3
-247755.31	150934.40	"T5" T5
-246211.16	150948.66	"T4" T4
-247071.13	149285.72	"T6" T6
-246596.01	149105.18	"S2" J300

-247551.01 149832.12 "S4" J304  
-247318.20 149585.05 "S5" J323  
-246486.73 149328.48 "S3" J291

[BACKDROP]

DIMENSIONS	-249469.32	147238.65	-245209.84	151508.59
UNITS	Meters			
FILE				
OFFSET	0.00	0.00		

[END]

## Anexo 3

### Rotina C++ para geração aleatória dos padrões de treinamento da RNA

Autor: MSc. Eng. Frederico Keizo Odan

```
//-----
#include <time.h>
#include <iostream>
#include <conio.h>
#include <fstream.h>
#include <vcl.h>
#include <stdio.h>
#include <stdlib.h>
#include <typeinfo>
#include <vector>
#include <string.h>

#pragma hdrstop

#include "EPANET2.h"

using std::cout;
using std::endl;

//=====
//declaração de funções
//=====

//-----
//função para gerar números aleatórios reais num intervalo a e b
//-----
float aleatorio_float(float a, float b)
{
    return ((b-a)*((float)rand()/RAND_MAX))+a;
}

//-----
//função para gerar números aleatórios inteiros num intervalo a e b
//-----
int aleatorio_int(int a, int b)
{
    return ((b-a)*((float)rand()/RAND_MAX )+a);
}

//-----
//função para gerar números aleatórios inteiro num intervalo de 0 a b
//-----
int aleatorio_0b(int b)
{
    return (rand() % b );
}

//=====
//Programa Principal
//=====
#pragma argsused

//Abertura do arquivo para impressão de dados
ofstream fout ("Arquivo.txt");
ofstream input ("Input.txt");
ofstream output ("Output.txt");

int main(int argc, char* argv[])
{
    //determinação do nº de casas decimais para a impressão do input e output
```

```

input.precision(4);
output.precision(4);

//declaração de variáveis
int n=1, i,j; //número de entradas a serem simuladas
int nbomba=11; //n° de bombas
int ntank=7; //n° de tanques
int nset=5; //n° de setores de demanda (DMA)
float demandat[]={107.9,67.0,23.5,40.3,33.8}; //demanda total para cada setor (DMA)

float nconjbomba=5; //n° de conjuntos de bombas

//declaração das variáveis de entrada para simulação no EPANET
float **fat_dem; //demanda agregada
int** status_bomba; //status lig/desl da bomba
float **niv_tank; //nível dos tanques
//->matriz dinâmica criada com a expressão"***"

//alocação de memória dinâmica -> definição do tamanho dos vetores/matrizes
fat_dem = new float *[n];
for (i=0;i<n;i++) //alocação de ponteiro dentro de outro ponteiro
    fat_dem[i] = new float[nset];

status_bomba = new int *[n];
for (i=0;i<n;i++)
    status_bomba[i] = new int[nbomba];

niv_tank = new float *[n];
for (i=0;i<n;i++)
    niv_tank[i]= new float[ntank]; //alocação de ponteiro dentro de outro
ponteiro

//Identificação(ID) das bombas e tanques
char ID_bomba[][100] =
{"PU1","PU2","PU3","PU4","PU5","PU6","PU7","PU8","PU9","PU10","PU11"};
char ID_tank[][100] = {"T1","T2","T3","T4","T5","T6","T7"};

//Identificação dos conjuntos de bombas
//criação de matriz de 3 dimensões s/ ponteiros
char
conjbomba_ID[5][3][100]={{"PU1","PU2","PU3"}, {"PU4","PU5"}, {"PU6","PU7"}, {"PU8","PU9"}, {"PU10",
,"PU11"}};

//Identificação(ID) dos nós a serem monitorados (pressão hidrost.)
char ID_nos[][100] = {"J53","J297","J302","J497"};

//Identificação dos tubos a serem monitorados
char ID_tubo[][100]={ "P374","P397","P399","P467"};

//Identificação dos padrões de demanda
char ID_pat[][100]={ "DMA1_pat","DMA2_pat","DMA3_pat","DMA4_pat","DMA5_pat"};

float fat_cons_min[]={0.1,0.1,0.1,0.1,0.1}, fat_cons_max[]={1.1,1.1,1.1,1.1,1.1};
//fatores de consumo mínimo e máximo para cada setor (DMA)
float niv_tank_min[]={0,0,0,0,0}, niv_tank_max[]={6.5,5.9,6.75,4.7,4.5,5.5,5};
//nível máximo e mínimo de cada tanque

//fout << "Impressão dos dados\n\n";
cout << "Inicio da geracao aleatoria de dados" << endl;

//+++++
//Geração aleatória das variáveis de entrada do EPANET
//+++++

//Inicialização do gerador de n° aleatório
randomize();
//impressão do cabeçalho do input
input << "n\t";
for (j=0; j<nbomba;j++){ input << "b" << j+1 << "\t";}

```

```

for (j=0; j<nset;j++) { input << "dem" << j+1 << "\t";}
for (j=0; j<ntank;j++) { input << "res" << j+1 << "\t";}
input << endl;

for (i=0;i<n;i++)
{
//fout << "\n\nConjunto de dados n°" << i;

//geração aleatória do status (lig/desl) das bombas
for (int nb=0; nb < nbomba; nb++)
{
status_bomba[i][nb]=aleatorio_0b(2);
//printf("\nO status da bomba %s eh
%i",ID_bomba[nb],status_bomba[i][nb]);
}

//geração aleatória do fator de demanda
for (j=0;j<nset;j++)
{
fat_dem[i][j] = aleatorio_float(fat_cons_min[j], fat_cons_max[j]);
}
//fout << "\nFator de demanda: " << fat_dem[i];

//geração aleatória dos níveis dos tanques
for (j=0;j<ntank;j++)
{
niv_tank[i][j] = aleatorio_float(niv_tank_min[j], niv_tank_max[j]);
//fout << "\nNível do tanque " << j << ": " << niv_tank[i][j];
}

// esta impressão naum foi realizada, pois pode haver mudanças no status
//devido aos controles impostos ao epaenet
//Impressão das entradas no arquivo Input.txt
input << i+1 << "\t";
for (j=0; j<nbomba;j++)
{
input << status_bomba[i][j] << "\t";
}

for (j=0; j<nset;j++)
{
input << fat_dem[i][j]*demandat[j] << "\t";
}

for (j=0; j<ntank;j++)
{
input << niv_tank[i][j] << "\t";
}
input << endl;
}

//FIM da Geração aleatória das variáveis de entrada do EPANET

//+++++
//Simulação das variáveis de entrada no EPANET
//+++++

//Abertura do Toolkit do EPANET
int errcode;
errcode = ENopen("BWCN.inp","bwcن.rpt","");
//errcode = ENopen("input.inp","atm.rpt","");

//verificação de erros
if (errcode>0)
{
ENclose();
//cout<< "Erro de código = " << errcode << endl;
return(0);
}

```

```

//.....
//Obtenção dos index dos elementos acima
//.....
//index é a ordem que o elemento de determinado ID aparece no arquivo .inp

//obtenção do index das bombas
int* index_bomba;
//char* aux0;

index_bomba = new int[nbomba];
//aux0 = new char[100];
//cout << "Variavel do tipo: " << typeid(aux0).name() << endl;

for (i=0; i<nbomba;i++)
{
    //itoa(ID_bomba[i], aux0, 10);
    ENgetlinkindex(ID_bomba[i], &index_bomba[i]);
    //cout << "index da bomba " << ID_bomba[i] << ": " << index_bomba[i] << endl;
}
//atribuição do index da bomba aos conjuntos de bombas
int **conjbomba_index;
conjbomba_index = new int*[nconjbomba];

for (i=0; i<nconjbomba; i++)
    conjbomba_index[i] = new int[3];

for (i=0; i<nconjbomba;i++)
{
    for (j=0; j<nbomba;j++)
    {
        for (int ij=0; ij<3;ij++)
        {
            if (!strcmp(conjbomba_ID[i][ij],ID_bomba[j]))
            {
                conjbomba_index[i][ij]=index_bomba[j];
                //printf("\nA bomba %s tem index
%i",conjbomba_ID[i][ij],conjbomba_index[i][ij]);
            }
        }
    }
}

//obtenção do index dos tanques
int* index_tank;
index_tank = new int[ntank];

for (i=0; i<ntank;i++)
{
    //itoa(ID_tank[i], aux0, 10);
    ENgetnodeindex(ID_tank[i], &index_tank[i]);
    //cout << "index do tanque " << ID_tank[i] << ": " << index_tank[i] << endl;
}

//Obtenção do index dos nós
int nnos = ARRAYSIZE(ID_nos); //obtenção do tamanho do vetor
int* index_nos;
int aa;
index_nos = new int[nnos];

for (i=0; i<nnos;i++)
{
    //itoa(ID_nos[i], aux0, 10);
    ENgetnodeindex(ID_nos[i], &index_nos[i]);
    //cout << "index do no " << ID_nos[i] << ": " << index_nos[i] << endl;
}

//Obtenção do index dos tubos
int ntubo = ARRAYSIZE(ID_tubo);
int* index_tubo;

```

```

index_tubo = new int[ntubo];

for (i=0; i<ntubo; i++)
{
    ENgetlinkindex(ID_tubo[i], &index_tubo[i]);
    //cout << "index do tubo " << ID_tubo[i] << ": " << index_tubo[i] << endl;
}

//Obtenção dos index dos padrões
int* index_pat;
index_pat = new int[nset];

for (i=0; i<nset; i++)
{
    ENgetpatternindex(ID_pat[i], &index_pat[i]);
}

//FIM da Obtenção dos index dos elementos acima

//Verificação do n° de nós
int nnostot;
ENgetcount(EN_NODECOUNT, &nnostot);
//cout << "\nN° de nos: " << nnostot << endl;

//Obtenção da duração da simulação
long dur;
ENgettimeparam(EN_DURATION, &dur);
//cout << "\nDuracao: " << dur/3600 << endl <<endl;

//definição da duração da simulação em lh
ENsettimeparam(EN_DURATION, 3600); //a duração fornecida deve ser em seg
ENgettimeparam(EN_DURATION, &dur);
//cout << "\nDuracao 2: " << dur/3600 << endl <<endl;

//.....
//Simulação de cada conjunto de entrada
//.....

//impressão do cabeçalho da saída
output << "n" << "\t";
for (j=0;j<nconjbomba;j++)
    output << "Pot" << j+1 << "\t";
for (j=0;j<ntank;j++)
    output << "nres" << j+1 << "\t";
for (j=0;j<nnos;j++)
    output << "pres" << j+1 << "\t";
for (j=0;j<ntubo;j++)
    output << "vaz" << j+1 << "\t";
output << endl;

int aux100=n/10, aux101=1;
for (i=0; i<n;i++)
{
    //Abertura da análise hidráulica sequencial
    ENopenH();

    //cabeçalho da impressão em arquivo
    //fout << "\n\n======" << "\n";
    //fout << "Resultados da simulação n° " << i;
    //fout << "\n======" << "\n";

    //cabeçalho da impressão em tela
    //cout << "\n\n======" << "\n";
    //cout << "Simulação n° " << i << "\n";
    //cout << "======" << "\n\n";

    if (i==aux100*aux101)
    {
        aux101+=1;
    }
}

```



```

        cout << "\nSimulacao " << i;
    }

    // . . . . .
    // Definição dos estados das bombas (ligado/desligado)
    // . . . . .
    float aux3;
    for (int nb=0; nb< nbomba; nb++)
    {
        //ENsetlinkvalue(index_bomba[nb],12,status_bomba[i][nb]);
//velocidade atual
        ENsetlinkvalue(index_bomba[nb],11,status_bomba[i][nb]);
//current status open/closed
        ENsetlinkvalue(index_bomba[nb],4,status_bomba[i][nb]);
//initial status
        //ENsetlinkvalue(index_bomba[nb],5,status_bomba[i][nb]);
//velocidade inicial
        ENgetlinkvalue(index_bomba[nb],11, &aux3);
        //cout << "Bomba " << ID_bomba[nb] << " com estado " << aux3 << endl;
    }
    //FIM da Definição dos estados das bombas (ligado/desligado)

    // . . . . .
    // Definição dos níveis dos tanques
    // . . . . .
    for (int nr=0; nr < ntank; nr++)
    {
        ENsetnodevalue(index_tank[nr], 8, niv_tank[i][nr]);
        ENgetnodevalue(index_tank[nr], 8, &aux3);
        //cout << "tanques " << ID_tank[nr] << " com nivel de " << aux3 <<
endl;
        //cout << " nível gerado " << niv_tank[i][nr] << endl;
    }
    //FIM da Definição dos níveis dos tanques

    // . . . . .
    // Definição do fator de consumo dos nós
    // . . . . .
    int aux4;

    for (int np=0; np < nset; np++)
    {
        float pat[]={fat_dem[i][np]};
        ENsetpattern(index_pat[np], pat, 1);
        ENgetpatternvalue(index_pat[np], 1, &aux3);
        //cout << "Padrão de valor " << aux3 << endl;
    }
    //FIM da definição do fator de consumo

    //Inicialização do sistema hidráulico
    ENinith(0);

    //Realização da simulação hidráulica
    //ENSolveH(); //Simulação hidráulica completa, nao pode usar a simulação
    //seqencial ENopenH -> ENinith -> ENrunH -> ENnextH -> ENcloseH

    long t,tstep;
    do
    {
        ENrunH(&t);
        //cout << "\n\nt: " << t << endl;

        // . . . . .
        //Obtenção de dados de saída
        // . . . . .
        //cout << "\ntstep=" << tstep << "\n";
        if (t==3600)
        {

```

```

//Obtenção do status das bombas
//cout << "\nApos ENrunH\n";
for (int nb=0; nb< nbomba; nb++)
{
ENgetlinkvalue(index_bomba[nb],11, &aux3);

//cout << "Bomba " << ID_bomba[nb] <<" com estado o/c: " << aux3 <<
endl;

//ENgetlinkvalue(index_bomba[nb],12, &aux3);
//cout << "Bomba " << ID_bomba[nb] <<" com velocidade: " << aux3 <<
endl;

}

//obtenção do consumo das bombas

float aux1, aux6, somapot;
float* cons_bomba; //declaração da variavel p registrar consumo da
bomba

cons_bomba = new float[nconjbomba];

for (int nc=0; nc < nconjbomba; nc++)
{
somapot=0;
for (int nb=0; nb < nbomba; nb++)
{
for (int ns=0; ns < 3; ns++)
{
if (conjbomba_index[nc][ns]==index_bomba[nb])
{
ENgetlinkvalue(index_bomba[nb], 13,
&aux1); //consumo da bomba

somapot=somapot + aux1;
ENgetlinkvalue(index_bomba[nb], 8,
&aux6);
}
}
}

//cout << "vazão da bomba " << ID_bomba[nb] << " : " << aux6
<< endl;

cons_bomba[nc]=somapot;
}

//obtenção do real status da bomba, devido a possíveis mudanças
causadas pelos controles
for (int nb=0; nb < nbomba; nb++)
{
ENgetlinkvalue(index_bomba[nb], 11, &aux3);
//cout << "\nO status orig eh " << status_bomba[i][nb] << " e
o atual eh " << aux3;

if (status_bomba[i][nb] != aux3)
status_bomba[i][nb]=aux3;
}

//fout << "\nConsumo das bombas: " << cons_bomba;

//obtenção do nível dos tanques
float aux2;
float* niv_tank_f;
niv_tank_f = new float [ntank];
//fout << "\n\nNível dos tanquess";
for (int nr=0; nr < ntank; nr++)
{
ENgetnodevalue(index_tank[nr], 0, &aux1); //elevação
ENgetnodevalue(index_tank[nr], 10, &aux2); //pressão
hidrostática

niv_tank_f [nr] = aux2-aux1; //nível do tanque
//fout << "\nNível do tanques " << ID_tank[nr] << ": " <<
niv_tank_f [nr];

//cout << "\nNível do tanque : " << ID_tank[nr] << ": " <<
niv_tank_f[nr];

}

//obtenção da pressão hidrostática dos nós selecionados

```

```

//fout << "\n\nPressao hidrostatica dos nos";
float * pres_nos;
pres_nos = new float [nnos];
for (int nn=0; nn < nnos; nn++)
    {
        ENgetnodevalue(index_nos[nn], 11, &pres_nos[nn]);
        //fout << "\nPressao hidrost. do nó " << ID_nos[nn] << ": " <<
pres_nos[nn];
    }

//Obtenção da vazão dos tubos selecionados
float* vaz_tubo;
vaz_tubo = new float[ntubo];
for (int nt=0; nt < ntubo; nt++)
    {
        ENgetlinkvalue(index_tubo[nt],8, &vaz_tubo[nt]);
        //cout << "\nVazao no tubo " << ID_tubo[nt] << ": " <<
vaz_tubo[nt];
    }

//Impressão dos resultados para Output.txt
output << i+1 << "\t";
for (j=0;j<nconjbomba;j++)
    output << cons_bomba[j] << "\t";
for (j=0;j<ntank;j++)
    output << niv_tank_f[j] << "\t";
for (j=0;j<nnos;j++)
    output << pres_nos[j] << "\t";
for (j=0;j<ntubo;j++)
    output << vaz_tubo[j] << "\t";
output << endl;

//FIM da Obtenção de dados de saída
}

ENnextH(&tstep);

//cout << "tstep: " << tstep << endl;

//ENsaveH();
//ENreport();

}while (tstep>0);

ENsaveinpfile("bwcinp.inp");
ENreport();

//FIM das Simulações de cada conjunto de entrada
ENcloseH();
}

ENclose();
//FIM das simulação das variáveis de entrada no EPANET

//impressão do input devido a mudanças no status da bomba causadas por controles do
EPANET
input << endl;
for (i=0; i < n; i++)
    {
        input << i+1 << "\t";
        for (j=0; j<nbomba;j++)
            {
                input << status_bomba[i][j] << "\t";
            }

        for (j=0; j<nset;j++)
            {
                input << fat_dem[i][j]*demandat[j] << "\t";
            }
    }

```

```
        }
    for (j=0; j<ntank;j++)
    {
        input << niv_tank[i][j] << "\t";
    }
    input << endl;
}

cout << "Fim da geração aleatória de dados" << endl;

getch();

//desalocação de memória dinâmica
delete [] status_bomba;
delete [] fat_dem;
delete [] niv_tank; //desalocação de memoria de matriz!
}
//-----
```

## Anexo 4

### Rotina Scilab para treinamento da RNA

```
//Script em linguagem Scilab para realizar o treinamento da rede neural
//objetivando capturar o funcionamento/conhecimento de redes de abastecimento de agua
//via redes neurais artificiais - RNA, utilizando o Toolbox
//de redes neurais ANN 0.4.2.3 baseado no trabalho de Ryurick M Hristev,
//intitulado "Matrix Techniques in ANN", e atualizado por Alan Cornet.
//
//Versao 2 ->pode receber varias arquiteturas para a rede neural que
//serao simuladas em serie

//Mestrando: Eng. Fernando H. Lourencetti

//Desenvolvimento: MSc. Eng. Frederico Keizo Odan

//Orientadora: Profª. Titular Drª. Luisa Fernanda Ribeiro Reis

//limpeza das variaveis e arquivos em aberto

clear;

//dasabilitando a paginacao da tela. O usuario opta por
//permitir ou nao a impressao na tela caso o limite da pagina seja
//atingido
lines(0);

printf('\nInicio do programa\n');

//tempo inicial
clock;ti=ans;

//1) Leitura de dados de entrada (input)
//Nota: os dados estarao dispostos em forma sequencial, isto e, cada linha representa
//uma leitura do sistema. Em cada coluna temos as variaveis que compoem o sistema, em arquivo excel (.xls)
//para mais detalhes ler as instrucoes em "Manual para utilizacao do SF-RNA2"

//1.a) especificacao do local dos arquivos

//criar um diretorio em c: com o nome Comportamento
//diret=string('c:/Comportamento');
diret=string('C:\Comportamento');
chdir(diret);
```

```
//criacao do sub-diretorio que ira conter as saidas do programa dentro da pasta c:/comportamento
createdir('saida');
createdir('saida_simulada');

chdir('saida_simulada');
if MSDOS then unix('del *.txt'); end
//chdir('c:/Comportamento');
chdir(diret);

printf('Leitura dos arquivos e processamento dos dados\n');
//1.b)Leitura do arquivo em Excel

//abertura do arquivo
[fd1,SST,Sheetnames,Sheetpos] = xls_open('C:\SimScilab\Input BWCN1.xls');

//leitura da aba do excel com os parametros basicos: Parbas nome de variavel atribuida pelo programador
[Parbas,TextInd1] = xls_read(fd1,Sheetpos(1));

//leitura da aba do excel com os dados de entrada. Input nome de variavel atribuida pelo programador
[NPInput,TextInd1] = xls_read(fd1,Sheetpos(2));

//leitura da aba do excel com os dados de saida. Output nome de variavel atribuida pelo programador
[NPOutput,TextInd1] = xls_read(fd1,Sheetpos(3));

//leitura da planilha excel com os parametros basicos. Separacao dos dados (linha e coluna) necessarios da aba Parbas
// proporcao entre dados para treino e teste (divididos em 50% treinamento; 25% em validacao cruzada
//e 25% em teste/verificacao

//50% para treinamento
ntreino_50 = Parbas(2);
//25% para validacao cruzada
ntreino_25v = Parbas(2,2);
//25% para teste e verificacao
ntreino_25t = Parbas(2,3);
//erro admissivel a ser propagado no treinamento(entre 0 e 0.1)
erro = Parbas(4);
//parametro de treinamento(step para procura do peso)
peso = Parbas(6);
//numero da iteracao ou ciclos de treinamento (T)
iteracao = Parbas(8);
```

```

//numero total de camadas da rede neural
camadas = Parbas(10);

//nuemro maximo de neuronios da camada intermediaria
neuronint = Parbas(12,1:2);

//numero de neuronios nas camadas de entrada e saida [ x x x ... x]
neurentsai = Parbas(14,1:2);

//Utilizar ciclo de treino com erro min (0 – não / 1 – sim)
ciclomin = Parbas(16);

//Padronizacao - obter os valores maximos e minimos das matrizes de entrada e saida.
a=0.1; b=0.9;
for I=2:neurentsai(1)+1
    minInput(I)=min(NPInput(:,I));
    maxInput(I)=max(NPInput(:,I));
    Input(:,I)=a+(b-a)*(NPInput(:,I)-minInput(I))/(maxInput(I)-minInput(I));
end
for I=2:neurentsai(2)+1
    minOutput(I)=min(NPOutput(:,I));
    maxOutput(I)=max(NPOutput(:,I));
    Output(:,I)=a+(b-a)*(NPOutput(:,I)-minOutput(I))/(maxOutput(I)-minOutput(I));
end

//Divisao dos conjuntos de treino, validacao cruzada e teste (entradas e saidas)
//Necessita saber o tamanho da matriz de entrada e saida. Comando "size"
//a) primeiramente entradas - armazenada na variavel Input
//numero "2" significa leitura a partir da 2ª linha, sendo 1 a variavel "tamanho" 1 e os ":" ler todas as colunas

//ENTRADAS

tamanho=size(Input);

aux1=ntreino_50*tamanho(1);
aux2=ntreino_25v*tamanho(1);
aux3=ntreino_25t*tamanho(1);

//50% para treino entrada
Inputtreino_50=Input(2:aux1,2:$)';

//25% para validacao cruzada
Inputteste_25v=Input(aux1+1:aux2+aux1,2:$)';

```

```
//25% para teste entrada
Inputteste_25t=Input(aux2+aux1+1:$.2:$);

//SAIDAS
//50% para treino saida
Outputtreino_50=Output(2:aux1,2:$);

//25% para validacao cruzada saida
Outputteste_25v=Output(aux1+1:aux2+aux1,2:$);

//25% para teste saida
Outputteste_25t=Output(aux2+aux1+1:$.2:$);

//Impressao dos vetores e matrizes de entrada e saida

fd2=mopen('saida/Verif.txt','wt');

//PARTE A: Entradas

//Imprime conjunto de entrada de treino - 50%

mfprintf(fd2,\n\n=====\\n');
mfprintf(fd2,||Inputtreino_50||\\n');
mfprintf(fd2,'=====\\n');
for I=1:tamanho(1)*ntreino_50-1
    mfprintf(fd2,%d\\t',I);
    for J=1:neurensai(1)
        mfprintf(fd2,%6.4f\\t',Inputtreino_50(J,I));
    end
mfprintf(fd2,\\n');
end

//Imprime conjunto de validacao - entrada (25%)

mfprintf(fd2,\n\n=====\\n');
mfprintf(fd2,||Inputteste_v_25||\\n');
mfprintf(fd2,'=====\\n');
for I=1:tamanho(1)*(5-ntreino_25v)
    mfprintf(fd2,%d\\t',I);
    for J=1:neurensai(1)
        mfprintf(fd2,%6.4f\\t',Inputteste_25v(J,I));
    end
```



```
mfprintf(fd2, '\n');
end

//Imprime conjunto de teste - entrada (25%)

mfprintf(fd2, '\n\n===== \n');
mfprintf(fd2, '|Inputteste_t_25| \n');
mfprintf(fd2, '===== \n');
for I=1:tamanho(1)*(.5-ntreino_25t)
    mfprintf(fd2, '%d\t', I);
    for J=1:neurentsai(1)
        mfprintf(fd2, '%6.4f\t', Inputteste_25t(J, I));
    end
mfprintf(fd2, '\n');
end

//PARTE B: Saidas

///Imprime conjunto de saida de treino - 50%

mfprintf(fd2, '\n\n===== \n');
mfprintf(fd2, '|Outputtreino_50| \n');
mfprintf(fd2, '===== \n');
for I=1:tamanho(1)*ntreino_50-1
    mfprintf(fd2, '%d\t', I);
    for J=1:neurentsai(2)
        mfprintf(fd2, '%6.4f\t', Outputtreino_50(J, I));
    end
mfprintf(fd2, '\n');
end

//Imprime conjunto de validacao - saida (25%)

mfprintf(fd2, '\n\n===== \n');
mfprintf(fd2, '|Outputteste_v_25| \n');
mfprintf(fd2, '===== \n');
for I=1:tamanho(1)*(.5-ntreino_25v)
    mfprintf(fd2, '%d\t', I);
    for J=1:neurentsai(2)
```

```
        mfprintf(fd2,%6.4f\t',Outputteste_25v(J,I));
    end
    mfprintf(fd2,\n');
end

//Imprime conjunto de teste - saida (25%)

mfprintf(fd2,\n\n=====\\n');
mfprintf(fd2,||Outputteste_25||\\n');
mfprintf(fd2,'=====\\n');
for I=1:tamanho(1)*(.5-ntreino_25t)
    mfprintf(fd2,%d\t',I);
    for J=1:neurentsai(2)
        mfprintf(fd2,%6.4f\t',Outputteste_25t(J,I));
    end
    mfprintf(fd2,\n');
end

fclose(fd2);

//2) REDE NEURAL ARTIFICIAL (RNA)

//Geracao da semente aleatoria
rand('seed',0);

//parametro de treinamento (learning parameters)
lp=[peso erro];

//inicializacao dos tempos de processamento para o treinamento
t1=list();
t2=list();

// loop para variar os neuronios na camada intermediaria

fd3=mopen('saida/Resultados.txt','wt');

//Criacao de uma lista contendo elementos de treino (entrada e saida) e teste (entrada e saida)
//atribuindo nomes a lista
//nome 1: Linputtreino_50
//nome 2: Loutputtreino_50
//nome 3: Linputteste_25v
//nome 4: Linputteste_25t
```

---

```

//nome 5: Loutputteste_25v
//nome 6: Loutputteste_25t
    Loutputtreino_50=list();
    Loutputteste_25v=list();
    Loutputteste_25t=list();

fd4=mopen('saida\RMSE.txt','wt');
mfprintf(fd4,I \t Tempo \t Erro treino \t Erro validação\t Erro teste\n');
for n=neuronint(1):neuronint(2)
//Treinamento da rede neural
//Imprime os resultados em tela pulando 1 linha
printf('\n=====n');
printf('||Treinamento da arquitetura %i ||\n',n);
printf('=====n');

//armazenamento dos dados de validacao cruzada
save('dadosvc.bak',Inputteste_25v,Outputteste_25v,n, ciclomin)

// definicao da arquitetura da RNA
N=[neurentsai(1),n,neurentsai(2)];

// Inicializacao dos pesos
W=ann_FF_init(N);
clock;t1(n)=ans;

//Introducao da matriz de treino
W=ann_FF_Std_online(Inputtreino_50,Outputtreino_50,N,W,lp,iteracao);
Outputsimulado_25v=ann_FF_run(Inputteste_25v,N,W);
Outputsimulado_25t=ann_FF_run(Inputteste_25t,N,W);
clock;t2(n)=ans;
tempo=etime(t2(n),t1(n));
printf('tempo de simulacao: %5.0f seg = %5.2f min\n ',tempo,tempo/60);

//Execucao da rede neural dado um determinado input
Outsimultreino_50 = ann_FF_run(Inputtreino_50,N,W);
Outsimulteste_25v = ann_FF_run(Inputteste_25v,N,W);
Outsimulteste_25t = ann_FF_run(Inputteste_25t,N,W);

//Calculo do RMSE - erro no treino e no teste (Root Mean Square Error - Raiz Quadrada do Erro Medio)
errotreino_50=(sum((Outsimultreino_50-Outputtreino_50).^2)/(ntreino_50*tamanho(1))/(neurentsai(2)))^0.5;
errovalidacao_25v=((sum((Outsimulteste_25v-Outputteste_25v).^2)/((.5-ntreino_25v)*tamanho(1))/neurentsai(2)))^0.5;
erroteste_25t=((sum((Outsimulteste_25t-Outputteste_25t).^2)/((.5-ntreino_25t)*tamanho(1))/neurentsai(2)))^0.5;
printf('\n\nErro Treino = %6.4f,errotreino_50);

```

```

printf('\nErro Validação = %6.4f',errovalidacao_25v);
printf('\nErro Teste = %6.4f\n',erroteste_25t);
//Despadronizacao ou desnormalizacao

for I=1:neurentsai(2)

    xteste_25v(:,I)=(Outsimulteste_25v(I,:)-a)/(b-a)*(maxOutput(I+1)-minOutput(I+1))+minOutput(I+1);
    xteste_25t(:,I)=(Outsimulteste_25t(I,:)-a)/(b-a)*(maxOutput(I+1)-minOutput(I+1))+minOutput(I+1);
    xtreino_50(:,I)=(Outsimultreino_50(I,:)-a)/(b-a)*(maxOutput(I+1)-minOutput(I+1))+minOutput(I+1);

    end

//Armazenamento dos resultados (listas)

    Loutptreino_50(n)=xtreino_50;
    Loutpteste_25v(n)=xteste_25v;
    Loutpteste_25t(n)=xteste_25t;

//Impressao dos vetores e matrizes de entrada e saida 'wt' se o arquivo ja existir, sobrescreve. Se nao existir, cria novo.

//criacao de uma string com a arquitetura da rede neural
ss=[];
ss='[';
ss=ss+string(neurentsai(1))+'-';
for i=1:camadas-2
ss=ss+string(n)+'-';
end
ss=ss+string(neurentsai($))+']';
//armazenamento dos dados
save('saida/arquitetura RNA'+ss+'.bak',N,W,lp,iteracao);

chdir('saida_simulada');
if MSDOS then unix('del *.txt'); end
write('treino'+ss+'.txt',xtreino_50,(20(f10.1)));
write('validacao cruzada'+ss+'.txt',xteste_25v,(20(f10.1)));
write('teste'+ss+'.txt',xteste_25t,(20(f10.1)));
chdir(diret);

//impressao dados relativos ao RMSE

mfprintf(fd4, '%i \t %5.2f \t %6.4f \t %6.4f \t %6.4f \n',n,tempo/60,errotreino_50,errovalidacao_25v,erroteste_25t);

```

```
end
```

```
save('saida/dados  
do treinamento.bak',Inputtreino_50,Outputtreino_50,Inputteste_25v,Inputteste_25t,Outputteste_25v,Outputteste_25t);
```

```
save('saida/resultados simulados.bak',Loutputtreino_50,Loutputteste_25v,Loutputteste_25t);
```

```
fclose(fd1);
```

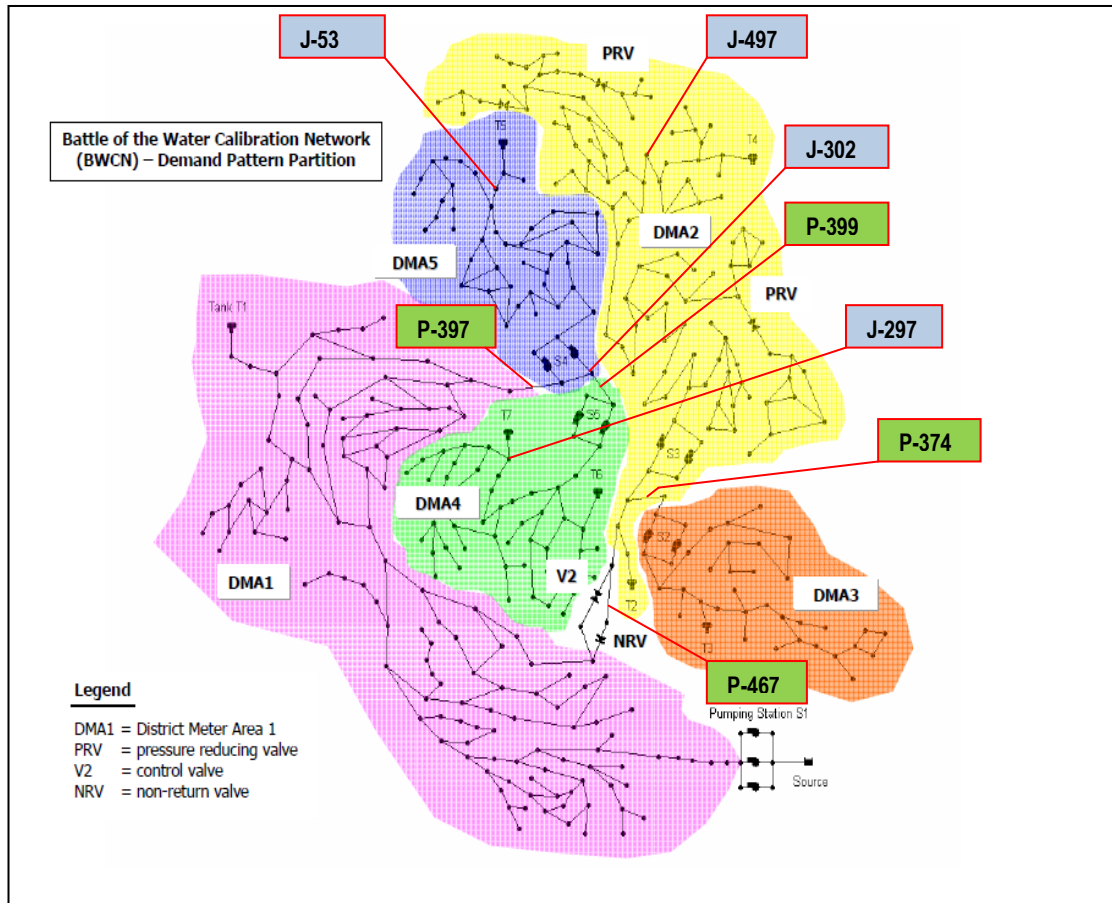
```
beep();
```

```
beep();
```

```
beep();
```

## Anexo 5 – rede WDSA

### Divisão dos DMAs e pontos de monitoramento de pressão e vazão.



## Anexo 6

Tela do arquivo Excel utilizado para ajuste dos parâmetros básicos de treinamento da RNA

	A	B	C	D	E	F	G	H
1	Proporção entre dados para treino e teste (utilizado 1)							
2	0,5	0,25	0,25					
3	Erro admissível a ser propagado no treinamento (entre 0 e 0.1)							
4	0,4							
5	Parâmetro de treinamento (step para procura do peso)							
6	0,1							
7	Nº de iterações							
8	5000							
9	Nº total de camadas da rede neural							
10	3							
11	Intervalo de neurônios da camada intermediária							
12	60	60						
13	Nº de neurônios nas camadas de entrada e saída [ x x x ... x]							
14	5	7						
15	Utilizará ciclo de treino com erro min (0 - não / 1 - sim)							
16	1							
17								
18								
19								
20								
21								
22								
23								
24								
25								
26								
27								
28								
29								
30								

Par Básico   Entrada   Saída

## Anexo 7

Tela do arquivo Excel utilizado para armazenar os padrões de treinamento (entradas) da RNA

	A	B	C	D	E	F	G
	Simulação	nº de bombas ativas	Consumo total	Nivel reserv 65	Nivel reserv 165	Nivel reserv 265	
1	nº						
2	0	0	1367,84	39,5459	77,987	82,8272	
3	1	2	969,268	47,7767	84,6492	27,2408	
4	2	2	1418,75	99,0814	88,9981	70,3024	
5	3	3	1343,23	35,0139	60,9485	22,306	
6	4	2	1449,64	20,7343	86,1507	54,7868	
7	5	3	1382,18	96,8139	94,0703	89,3826	
8	6	3	932,528	29,4748	70,8274	80,8069	
9	7	2	1138,75	68,4286	84,2647	65,8834	
10	8	1	1907,19	82,8761	71,0685	63,7715	
11	9	0	1789,78	48,6465	99,5025	40,3668	
12	10	3	805,465	70,6626	83,8465	91,0825	
13	11	2	1700,55	53,2487	35,9813	69,4357	
14	12	0	1913,42	25,1289	85,8486	56,4013	
15	13	3	1012,15	94,9889	90,9452	85,7356	
16	14	1	1983,05	72,6341	93,5118	76,8426	
17	15	3	1895,32	34,7728	49,971	77,8588	
18	16	0	1941,3	92,9746	76,1376	92,9075	
19	17	2	1980,88	66,7165	90,6674	97,7264	
20	18	0	1205,84	32,8013	53,4959	99,7131	
21	19	0	988,578	36,5673	48,2192	79,6381	
22	20	0	1285,63	76,1467	40,9253	49,6719	
23	21	3	1884,79	43,4217	67,9464	20,9784	
24	22	2	984,231	71,4774	63,2954	27,3324	
25	23	0	792,09	28,1167	71,16	83,4803	
26	24	3	2013,82	55,092	41,319	30,43	
27	25	1	846,468	91,0306	62,1113	58,1317	
28	26	0	1592,92	75,5455	51,0269	73,1162	



## Anexo 8

Tela do arquivo Excel utilizado para armazenar os padrões de treinamento (saídas) da RNA

	A	B	C	D	E	F	G	H
	Simulação	Cons. das	Niv. Reserv.	Niv. Reserv.	Niv. Reserv.	Pres. No	Pres. No	Pres. No
1	nº	bombas	65	165	265	55	90	170
2	0	0	49,2891	73,0492	74,2716	64,5408	61,4835	71,3777
3	1	1047,44	53,9643	69,2321	41,8792	50,7997	57,8012	57,5235
4	2	506,981	92,153	84,042	80,2015	83,526	85,5698	82,3374
5	3	1584,58	42,4128	50,0725	34,5896	41,6291	46,4823	43,7284
6	4	1076,4	34,233	71,9333	59,9995	57,056	57,5443	64,1991
7	5	667,752	92,7179	90,6459	93,6749	92,6515	92,0629	91,3026
8	6	1181,98	43,802	72,3143	72,2929	68,5533	67,6989	71,9768
9	7	764,391	73,045	75,3982	73,1066	73,7379	74,2283	74,0973
10	8	442,542	76,4786	69,1832	70,0141	70,786	71,1399	69,3695
11	9	0	51,4237	80,2788	51,9063	52,8309	53,9716	61,7087
12	10	827,717	78,6815	86,2591	84,5453	84,3023	84,0866	85,1796
13	11	1106,51	56,981	47,5618	58,2436	57,4974	56,188	51,7311
14	12	0	34,5906	70,1246	57,4175	49,0749	47,5711	59,2925
15	13	663,043	91,1902	88,7491	90,7701	90,6435	90,4605	89,406
16	14	375,338	76,9618	82,8726	80,7945	79,2219	78,8735	80,756
17	15	1391,17	45,4801	57,9974	65,5794	61,2666	57,7399	59,7055
18	16	0	87,3624	83,827	85,5079	84,7682	84,3254	83,8735
19	17	597,148	75,7297	88,7084	89,8333	84,851	83,7325	87,9249
20	18	0	41,7225	58,585	82,3967	62,9877	54,4938	63,7054
21	19	0	43,2927	52,726	65,6955	54,8555	50,2069	55,3909
22	20	0	65,618	48,4024	49,1988	51,4286	52,2569	48,8533
23	21	1500,73	48,82	55,4481	34,7363	43,4455	50,4465	46,2861
24	22	960,488	67,7063	57,1244	41,6858	53,2732	59,7572	52,058
25	23	0	39,5131	68,2893	72,783	61,2159	57,0893	68,0973
26	24	1533,89	53,6518	40,8096	38,7318	44,1931	46,7892	39,9693
27	25	405,826	82,2306	64,8569	64,8064	69,623	71,4496	65,3821
28	26	0	69,1812	60,782	65,3582	64,8139	63,9962	62,031