

# ALGORITMO DO GRADIENTE CONJUGADO ESCALONADO EM RNA PARA A PREVISÃO DO CONSUMO HORÁRIO DE ÁGUA EM SISTEMAS DE ABASTECIMENTO

Carla Silva da Silva<sup>1</sup> e Paulo Sérgio Franco Barbosa<sup>2</sup>

**Resumo** – Este trabalho investiga a utilização do algoritmo do gradiente conjugado escalonado em modelo de redes neurais artificiais na previsão da demanda horária de água em sistemas urbanos de abastecimento, tendo como área de estudo a zona da Alça Leste localizada na região metropolitana de São Paulo. Os dados de entrada do modelo de previsão, são referentes à estação Penha. O modelo é testado sazonalmente para as quatro estações do ano. A escolha da técnica de RNA's para o cálculo da demanda horária de água se deu pelo fato de que, em relação às técnicas de séries temporais do tipo Box-Jenkins, as RNA's conseguem calibrar com base em período de observações históricas de menor extensão, alcançando resultados praticamente iguais.

**Abstract** - This work investigates the use of a model of artificial neural networks (ANN) aiming at forecasting the hourly water demand in urban water supply systems. The case study area is located in a branch of the metropolitan area of São Paulo, which is named Alça Leste. The input data are associated to the Penha station. The model is tested for four seasons, winter, spring, summer, autumn. The selected optimization algorithm, introduced by Moller in 1993, is the conjugated gradient method, which is included in the group of the second order algorithms. The choice of the ANN technique to have an estimate of the hourly water demand, is based on the superior advantages when compared to the performance of time series modeling (Box-Jenkins).

**Palavras-Chave** – demanda, redes neurais, abastecimento de água.

---

<sup>1</sup> Doutoranda em Recursos Hídricos, Faculdade de Engenharia Civil, UNICAMP, Rua Dr. Quirino nº:563 apto 84, Bairro Centro, CEP: 13015-080, Campinas, SP – Brasil. Tel: (019)32363260, email: carlass@fec.unicamp.br

<sup>2</sup> Prof. Adjunto, Faculdade de Engenharia Civil, UNICAMP, Caixa Postal 6021, CEP: 13084-971, Campinas, SP – Brasil; email: franco@fec.unicamp.br

## INTRODUÇÃO

A busca por uma maior eficiência no gerenciamento dos recursos hídricos constitui, sem dúvida, um dos temas atuais de importância estratégica no cenário mundial. Hoje tomamos consciência da escassez da água, da necessidade de preservar e bem gerir este elemento vital e finito. De uma forma geral, a previsão é uma afirmação sobre o futuro. Entretanto, ao contrário da “predição” a previsão é condicional sobre o que é esperado para acontecer, caso uma série de hipóteses admitidas venham a se tornar válidas. Portanto, a previsão pode ser entendida como uma projeção ou extrapolação das tendências do passado (BOLAND, 1985).

A previsão de demanda pode ser classificada de várias formas, de acordo com diversos critérios. Quanto à variável a ser prevista, a previsão pode ser classificada como previsão hidrológica, previsão de carga elétrica, previsão de consumos de água e outros. Dependendo da variável prevista, as técnicas utilizadas podem sofrer variações em função das características de cada processo. Quanto ao horizonte de previsão, pode-se classificar a previsão como de longo prazo ou curto prazo. A previsão do longo prazo está associada à definição de parâmetros para planejamento ou projetos de novos sistemas. A previsão de curto prazo está associada aos estudos de efeitos de medidas de racionamento ou às necessidades decisórias da operação em tempo real.

No caso de previsão de longo prazo, necessária para fins de projeto, procura-se geralmente, prever três valores básicos, a demanda média de um dia de consumo normal, a demanda média de um dia de consumo máximo e o pico de consumo de um dia de consumo máximo. Na previsão de curto prazo, procura-se definir o padrão de consumo, isto é, a distribuição dos consumos ao longo do tempo.

A previsão de consumos pode estar ligada a um consumo agregado, como o de uma região, ou de uma cidade ou de um setor abastecido por uma fonte definida ou a consumos individuais, onde se analisam os perfis associados a ligações domésticas, comerciais, industriais, etc.

Os principais fatores associados à definição do consumo são o nível sócio econômico dos consumidores, os tipos de residências, o tipo de usos do solo, as características das instalações hidráulicas individuais, o método de medida de consumo, o preço da água e as condições climáticas.

A operação em tempo real de um sistema de abastecimento de água requer informações atualizadas em diversos pontos da rede de distribuição, visando à decisão sobre as manobras a serem mantidas (ex. *boosters*). O planejamento da operação destes elementos tem como referência a necessidade de atendimento a custo mínimo e com garantia de um padrão mínimo de confiabilidade. Tipicamente, o plano de operação é preparado para um período de 24 horas adiante. Existem diversas razões para a escolha deste horizonte, que são: as demandas apresentarem um pronunciado ciclo diário; a tarifa de energia elétrica, determinante direto dos custos de operação, também apresenta diferenciação horária em muitos sistemas (horo-sazonal); existe sempre uma certa hora do dia em que o estado do sistema (ex. nível dos reservatórios) pode ser estabelecido como meta desejável (ex. reservatório cheio às 6:00 horas), facilitando o planejamento da operação uma vez que tal nível funciona como uma condição de contorno na modelagem.

Embora o horizonte de planejamento usual seja o de 24 horas, pode ser necessário em alguns casos considerar o ciclo semanal diante do maior volume dos reservatórios, com capacidade de regularização semanal.

Esta pesquisa, enfoca um aspecto em especial, de enorme importância na modelagem da operação dos sistemas, a previsão da demanda horária. Em um sentido mais amplo (Mays e Tang, 1992) uma previsão é uma estimativa de um parâmetro ou estado futuro o qual apresenta quatro dimensões: quantidade; qualidade; tempo e espaço. Na escala de discretização horária, com horizonte de 24 horas, um modelo de previsão permite: (a) gerenciar adequadamente os recursos de controle, reservação e bom andamento da rede e do sistema como um todo, permitindo inclusive a redução dos custos devido à operação integrada, espacial e temporalmente, do sistema; (b) garantir maiores chances de efetivo atendimento da demanda, diminuindo os riscos de déficit em pontos de consumo específicos, ou riscos de extravasamento nos reservatórios; (c) identificar as melhores formas de implementar manobras especiais, durante condições de emergência ou manutenção.

As Redes Neurais Artificiais (RNA's) funcionam conceitualmente de forma similar ao cérebro humano, tentando reconhecer regularidades e padrões de dados. São capazes de aprender com a experiência e partir para a generalização baseadas no seu conhecimento prévio. Embora biologicamente inspiradas, as RNA's encontraram aplicações em muitas áreas diferentes. Para esse trabalho, a área de especial interesse é o cálculo da previsão de demanda.

Algumas características importantes presentes nas RNA's são;

- capacidade de processamento paralelo;
- representação distribuída de conhecimento;
- tolerância a falhas;
- possibilidade de incorporar redundâncias;
- grande capacidade de adaptação;
- flexibilidade no atendimento a critérios de generalização ;
- possibilidade, de incorporação de poderosas ferramentas algébricas facilitando a análise e

interpretação dos resultados.

A eficácia das ferramentas de engenharia, baseadas nos conceitos mais avançados de redes neurais artificiais, se manifesta na forma de dois aspectos básicos: redução drástica da participação do usuário (geralmente não especializado) em seu desenvolvimento e capacidade de determinação automática da complexidade dos problemas a serem tratados.

A previsão de demanda é um assunto sempre presente quando se pretende criar ou expandir um sistema. Existem vários métodos de previsão de demanda de água, porém, métodos que utilizam redes neurais artificiais são escassos na literatura. A potencial vantagem do uso de RNA's para a solução de tal problema e a necessidade de desenvolvimento de algoritmos de previsão de demanda de água em sistemas urbanos de abastecimento, com novas metodologias específicas para problemas de previsão no Brasil, foram as motivações para estudar a performance do uso de RNA's na solução da previsão de demanda horária de água.

## **FUNDAMENTOS DE REDES NEURAIAS ARTIFICIAIS**

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento; já o cérebro de um mamífero pode ter muitos bilhões de neurônios. Cada elemento opera somente sob uma informação local (Nigrini, 1993). Zurada (1992) simplifica a conceituação afirmando que o sistema neural ou RNA's, são sistemas equivalentes ao celulares físicos os quais podem adquirir, armazenar e utilizar conhecimentos experimentais. Em outras palavras, RNA's são unidades de processamento numérico, cuja arquitetura em camada produz um fluxo de informações com ou sem realimentação, possuindo uma estrutura de processamento de sinais com grande poder de adaptação e capacidade de representação de processos não linear.

As Redes Neurais Artificiais (RNA's) funcionam conceitualmente de forma similar ao cérebro humano, tentando reconhecer regularidades e padrões de dados. São capazes de aprender com a experiência e partir para a generalização baseadas no seu conhecimento prévio. Embora biologicamente inspiradas, as RNA's encontraram aplicações em muitas áreas diferentes. Para esse trabalho, a área de especial interesse é o cálculo da previsão de demanda. Algumas características importantes presentes nas RNA's são:

- capacidade de processamento paralelo;
- representação distribuída de conhecimento;
- tolerância a falhas;
- possibilidade de incorporar redundâncias;
- grande capacidade de adaptação;
- flexibilidade no atendimento a critérios de generalização ;
- possibilidade, de incorporação de poderosas ferramentas algébricas facilitando a

análise e interpretação dos resultados.

As RNA's são representadas por unidades interconectadas através de processamentos não lineares estáticos, onde a(s) entrada(s) na rede são vetores e sua respectiva(s) saída(s) são escalares, chamadas de neurônios artificiais. Apresentam grande competitividade com os métodos lineares, quando estes não apresentam bom desempenho nos processos que, particularmente, envolvem aproximação de funções multivariáveis, identificação e controle de sistema dinâmicos. As redes, além de calcular qualquer função computável, estão habilitadas a resolverem problemas de classificação e mapeamento e aproximação de funções.

Várias são as aplicações de redes neurais divulgadas na literatura. Na área aeroespacial está sendo usada em simulação do trajeto de vôos e sistemas de controle de aeronaves; na engenharia automotiva em sistemas de direção automática de automóveis; no sistema bancário em avaliação de aplicações, e se estendendo ao sistema financeiro em previsão do preço corrente. Na eletrônica é bastante utilizada em controle de processos, máquinas de visão, síntese de vozes e modelagem não linear; na área de robótica existem estudos em controle de trajetória e controladores manipulador; na medicina em análise de eletroencefalograma e eletrocardiograma, modelos de próteses e otimização de tempo de transplantes; nas ciências sociais em previsão do custo da violência no trânsito e violência provocada pelos conflitos agrários (Mathworks, 1998).

Na agricultura, por exemplo, Deck et al. (1995) comparam RNA com uma máquina tradicional classificadora por inspeção visual e, Tao et al. (1995) aplicaram RNA's na inspeção visual das cores de tomate e batata para um processo seletivo. Nas ciências econômicas (Tripp e Turdan, 1993) e indústria (Tawel, Marko e Feldkamp, 1998) diversos são os investimentos em busca de novas tecnologias derivadas da aplicação de redes neurais.

Particularmente, na hidrologia e recursos hídricos, as RNA têm sido uma ferramenta muito útil em modelos de previsão de vazão destinados à operação de reservatórios em tempo real; como ferramenta alternativa, na construção de programas especialistas destinados a apoiar as decisões no gerenciamento de recurso hídricos, na previsão de eventos extremos como secas e cheias e, também na previsão de níveis em canais de fuga. O campo de aplicação de redes neurais se estende além das áreas da ciência, para utilização em serviços públicos (segurança, educação, saúde), entretenimento, exploração de óleo e gás e transportes.

## **DADOS DE ENTRADA DO MODELO**

Com base em estudos anteriores (Silva e Barbosa, 2001), usaremos como dados de entrada para o modelo de previsão das demandas horárias, as demandas horárias do respectivo dia da semana anterior e a demanda média do dia anterior ao que se quer prever. Assim teremos 25 neurônios de entrada para cada rede, isto é teremos quatro redes referentes as quatro estações do ano. Devido a região metropolitana de São Paulo apresentar nítida sazonalidade, optou-se pela separação dos dados de entrada do modelo de previsão de demanda em quatro estações; inverno de 21/06/98 a 21/09/98, primavera 22/09/98 a 20/12/98, verão 21/12/98 a 20/03/99 e outubro 21/03/99 a 20/06/99.

## **MODELO PROPOSTO**

As redes neurais artificiais são constituídas de elementos simples operando em paralelo, que armazenam conhecimentos através de experiências de aprendizado, sendo esses elementos inspirados no sistema nervoso biológico. As RNA's são uma tentativa de modelar a capacidade de processamento das informações do sistema nervoso (Haykin, 1994).

Os neurônios da camada de entrada são chamados de neurônios sensoriais, responsáveis pela recepção dos sinais de entrada e sua propagação, sem qualquer modificação para a camada seguinte da rede neural. A camada intermediária é composta por  $n$  neurônios, e a camada de saída é composta por  $r$  neurônios, ambos análogos aos da figura 1, porém a função de ativação nos neurônios da camada de saída é igual à função identidade.

Não existe regra definida para estabelecer o número inicial de neurônios a ser utilizado por camada. Existem algumas indicações que auxiliam como primeira tentativa, dentre elas aplicaremos a que indica para a camada de entrada (variáveis independentes) um número de neurônios igual ao número de variáveis de entrada. O número de neurônios da camada escondida deve ser o menor possível, mas como primeira tentativa, treina-se a rede para um número bem alto de neurônios e verifica-se o comportamento do erro, se ele for muito alto, então se deve diminuir até que o erro não se altere significativamente.

Assim como os neurônios, o número de camadas não possui regras estabelecidas e este valor fica em aberto. Como já visto, o treinamento é feito para 3 camadas fixas. A função de ativação utilizada é a tangente hiperbólica do tipo log-sigmoidal.

O modelo de RNA's é simulado através do software MATLAB (*Matrix Laboratory*) for Windows, que é um ambiente computacional para visualização e computação numérica de alta performance. O MATLAB integra análise numérica, processamento de sinais e gráficos, em que o problema e as soluções são expressos tal como são formulados matematicamente, sem a programação tradicional (Mathworks, 1998).

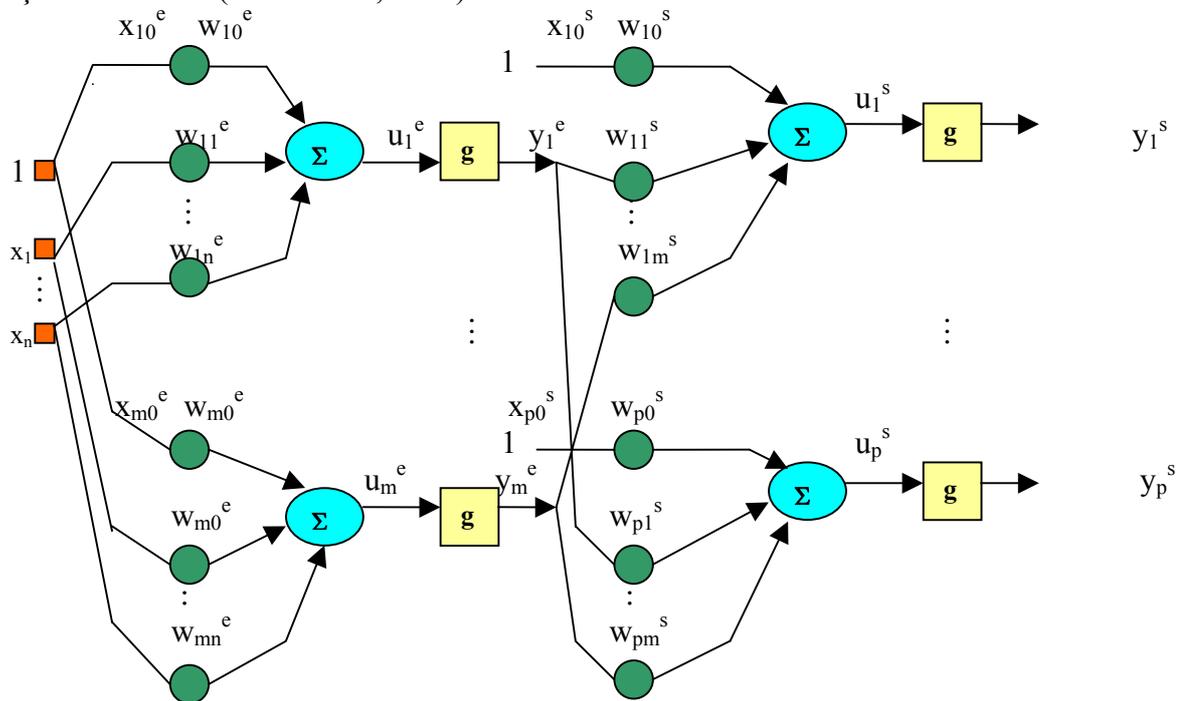


FIGURA 01 – Rede Neural Multicamadas

Onde:

- $n$  é o número de neurônios da camada de entrada;
- $m$  é o número de neurônios da camada intermediária;
- $p$  é o número de pesos (parâmetros ajustáveis).

## METODOLOGIA

Os dados utilizados para a simulação do modelo de RNA's, com topologia constituída por uma camada intermediária e treinamento do tipo supervisionado, foram apenas as demandas conforme já informado anteriormente. A seguir, estão estruturadas todas as informações que constituem a simulação neural:

1 – Conjunto de dados de entrada-saída  $(x_k^1, x_k^2, \dots, x_k^{25}; d_k)_{k=1}^N$

**Estação Inverno:**

$x_k^1, x_k^2, \dots, x_k^{25} = \text{vazões (l/s)}$

$d_k = \text{vazões (l/s)}$

**Estação Primavera:**

$x_k^1, x_k^2, \dots, x_k^{25} = \text{vazões (l/s)}$

$d_k = \text{vazões (l/s)}$

**Estação Verão:**

$x_k^1, x_k^2, \dots, x_k^{25} = \text{vazões (l/s)}$

$d_k = \text{vazões (l/s)}$

**Estação Outono:**

$x_k^1, x_k^2, \dots, x_k^{25} = \text{vazões (l/s)}$

$d_k = \text{vazões (l/s)}$

Os valores de  $N$  (número total de padrões ou exemplos, contidos no conjunto de treinamento) são variáveis de acordo com o período de dados disponíveis. As séries de entrada e saída identificadas foram classificadas como atributos com valores reais por tratarem de variáveis de vazão. Nesse caso, os dados foram normalizados de acordo com o operador que os mapearam no intervalo  $[0, 1]$ .

2 – Função objetivo a ser minimizada: Erro médio quadrático (Mean squared error – MSE).

3 – Função de ativação: é a função tangente hiperbólica do tipo sigmoidal sendo a mesma para todos os neurônios da camada intermediária.

4 – Algoritmo de otimização: algoritmo do gradiente conjugado escalonado (GCE).

5 – Dimensão da RNA:

A rede possui uma camada de entrada, uma camada intermediária e uma camada de saída. A camada de entrada possui 25 neurônios (referentes aos dados de entrada), a camada intermediária possui 10 neurônios (definido com base nos testes realizados) e a camada de saída possui 24 neurônios (referentes as 24 horas de previsão). Nas camadas intermediárias e de saída foram atribuídas entradas adicionais (*Bias*), que foram computadas juntamente com os pesos.

Como o treinamento da rede é realizado por um algoritmo de segunda ordem, ela deve ser submetida a uma reinicialização a cada treinamento referente a cada iteração, considerando-se problemas quadráticos (Silva, 1998), pois em sua maioria esses métodos são deduzidos.

6 – Conjunto inicial de pesos: a inicialização dos pesos é feita por geração aleatória, com distribuição uniforme no intervalo  $[-0.1; 0.1]$ .

7 – Processo iterativo para o treinamento da rede: Método em lote ou batelada;

8 – Foram considerados somente um conjunto de dados par treinamento e outro conjunto de dados para teste, objetivando uma avaliação sistemática do desempenho da rede. A série de vazões é pequena para que se proceda a uma divisão em três conjuntos, treinamento, validação e teste;

9 – Quanto ao particionamento dos dados a serem atribuídos a cada conjunto: atribuiu-se que o conjunto de teste representasse 40% do conjunto de treinamento, conforme a extensão da série;

10 – Critério de parada dos procedimentos de validação cruzada: diante dos diversos critérios existentes, optou-se por aplicar um limite no número de épocas (passos) durante o treinamento e a validação da rede. O limite estabelecido foi verificado pelo valor mínimo do erro da função objetivo alcançada através do gráfico superfície de erro x épocas.

11 – tempo de processamento: O tempo médio de processamento em um computador foi do tipo PC Pentium III com 124 MB de memória RAM, foi de  $3.4e+001$  s.

O método de segunda ordem aplicado é chamado de *Gradiente Conjugado Escalonado – GCE*, desenvolvido por Moller (1993). Tal algoritmo foi utilizado por Von Zuben num programa computacional de treinamento de redes neurais em linguagem MATLAB, denominado *moller.m*. Este algoritmo foi modificado, com o objetivo de atender as necessidades do estudo de previsão de demanda. Baseado no trabalho de Barp (1999), criou-se novas rotinas para composição do programa.

## SIMULAÇÃO DO MODELO EM RNA's

O treinamento e o teste do modelo de RNA's foram executados considerando diversas topologias, variando o número de neurônios na camada intermediária e fixando esta em uma e variando o número de iterações, observando assim as variações dos erros quadráticos. A topologia escolhida para a discussão dos resultados, foi a topologia que tem 10 neurônios na camada intermediária e 1500 iterações para as quatro estações do ano. O motivo de escolher a mesma topologia para as quatro estações do ano, é que o erro quadrático não varia substancialmente para as outras topologias, ficando assim mais fácil as comparações entre as redes. As tabelas a seguir mostram estes testes.

TABELA 01 – Teste das Topologias Estação Penha (Inverno)

It erações	1000		1500		2000		3000		5000	
	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste
N <sup>o</sup> Neurônios	EQF	EQF	EQF	EQF	EQF	EQF	EQF	EQF	EQF	EQF
05	0.9798	2.993	0.8627	4.352	0.8476	3.035	0.7938	4.4770	0.7532	5.0035
10	0.9078	1.715	<b>0.67</b>	<b>2.81</b>	0.6663	3.238	0.6031	2.6367	0.5181	3.2048
20	0.7007	2.100	0.5522	2.908	0.4675	2.3147	0.359	3.1210	0.2377	5.5588
30	0.739	1.866	0.5220	2.344	0.3767	3.5080	0.2641	3.9448	0.1177	4.3037
60	0.7886	1.890	0.5577	2.329	0.4894	2.4283	0.2414	2.9418	0.0323	3.8647
90	0.8412	1.887	0.5895	2.213	0.4758	2.3725	0.2915	2.9540	0.0953	3.8115
100	0.8233	1.881	0.5866	2.093	0.5062	2.2606	0.2558	2.9819	0.0646	3.9454

Tempo de processamento para a topologia de 10 neurônios na camada intermediária e 1500 iterações foi de  $3.45 \times 10^1$  segundos, no período de inverno.

TABELA 02 - Teste das Topologias Estação Penha (Primavera)

It erações	1000		1500		2000		3000		5000	
	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste
N <sup>o</sup> Neurônios	EQF	EQF	EQF	EQF	EQF	EQF	EQF	EQF	EQF	EQF
05	0.4359	2.476	0.4132	3.080	0.388	4.9020	0.3437	2.5786	0.3426	24.55
10	0.3553	2.805	0.3948	2.709	0.2805	2.7662	0.2609	17.347	0.2181	7.4208
20	0.3445	3.127	<b>0.2857</b>	<b>3.525</b>	0.2451	5.1549	0.1771	10.405	0.0979	41.900
30	0.3429	2.880	0.2787	3.813	0.2560	5.4017	0.1623	12.083	0.0659	19.19
60	0.3983	2.396	0.3160	4.054	0.2684	4.6973	0.1906	12.586	0.0726	21.026
90	0.4282	2.657	0.3198	4.881	0.2626	5.9265	0.1971	9.0341	0.0995	19.494
100	0.4706	2.310	0.4157	3.020	0.2545	7.8508	0.1996	7.7427	0.0958	26.092

Tempo de processamento para a topologia de 10 neurônios na camada intermediária e 1500 iterações foi de  $1.09 \times 10^2$  segundos, no período de primavera.

TABELA 03 – Teste das Topologias Estação Penha (Verão)

It erações	1000	1500	2000	3000	5000
---------------	------	------	------	------	------

	<i>Treino</i>	<i>Teste</i>								
<i>Nº</i>	<i>EQF</i>	<i>EQF</i>								
<i>Neurônios</i>										
<b>05</b>	0.2689	0.378	0.2658	0.355	0.2498	0.3467	0.2246	0.3380	0.1890	0.7057
<b>10</b>	0.2288	0.384	<b>0.2196</b>	<b>0.375</b>	0.1900	0.38	0.1612	0.4086	0.1305	0.6830
<b>20</b>	0.2179	0.454	0.1804	0.399	0.1637	0.4011	0.1105	0.4916	0.0744	0.6879
<b>30</b>	0.2476	0.525	0.1738	0.446	0.1472	0.4065	0.1047	0.4774	0.063	0.76
<b>60</b>	0.2628	0.548	0.1964	0.494	0.1383	0.4007	0.1148	0.4884	0.0746	0.7400
<b>90</b>	0.3164	0.603	0.2082	0.427	0.1560	0.4060	0.1111	0.4469	0.0789	0.5779
<b>100</b>	0.3323	0.526	0.2300	0.529	0.1552	0.4431	0.1169	0.5380	0.1183	2.2568

Tempo de processamento para a topologia de 10 neurônios na camada intermediária e 1500 iterações foi de  $3.476 \times 10^1$  segundos, no período de verão.

TABELA 04 – Teste das Topologias Estação Penha (Outono)

<i>Iterações</i>	<b>1000</b>		<b>1500</b>		<b>2000</b>		<b>3000</b>		<b>5000</b>	
	<i>Treino</i>	<i>Teste</i>								
<i>Nº</i>	<i>EQF</i>	<i>EQF</i>								
<i>Neurônios</i>										
<b>05</b>	1.3359	2.093	1.2773	2.828	1.0771	4.8195	1.0807	8.6702	0.9945	24.837
<b>10</b>	1.1659	2.528	<b>0.9428</b>	<b>2.921</b>	0.8334	3.0944	0.8222	3.4493	0.6955	7.7584
<b>20</b>	0.8697	2.775	0.6448	3.401	0.5724	3.9479	0.4064	6.3496	0.2833	7.1776
<b>30</b>	0.9337	2.584	0.639	3.626	0.4658	3.6824	0.2645	4.7043	0.12	5.071
<b>60</b>	0.8172	2.684	0.655	2.768	0.4569	3.7322	0.2387	3.7264	0.0196	5.9778
<b>90</b>	0.8246	2.631	0.6484	3.139	0.5352	3.370	0.2846	6.0642	0.0164	5.0663
<b>100</b>	0.8582	2.665	0.6234	3.50	0.4901	3.5009	0.2653	4.6356	0.0272	5.3213

Tempo de processamento para a topologia de 10 neurônios na camada intermediária e 1500 iterações foi de  $3.389 \times 10^1$  segundos, no período de outono.

As figuras a seguir mostram o resultado da previsão para as quatro estações do ano, sendo um gráfico de treinamento que mostra os valores reais usados para o treino versus os resultados encontrados (calibrados treino), e o gráfico de teste que mostra os valores reais usados para o teste versus os resultados encontrados (reais teste). Para melhor visualização os resultados plotados são a média das vazões diárias.

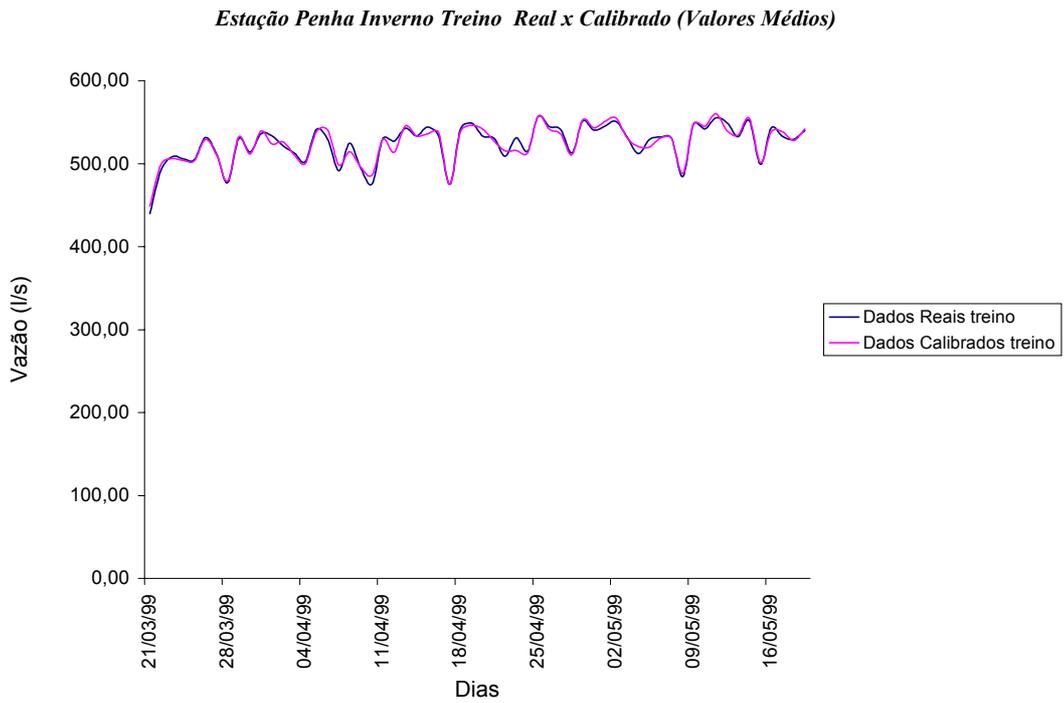


FIGURA 02 – Resultado do Treinamento para a Estação de Inverno

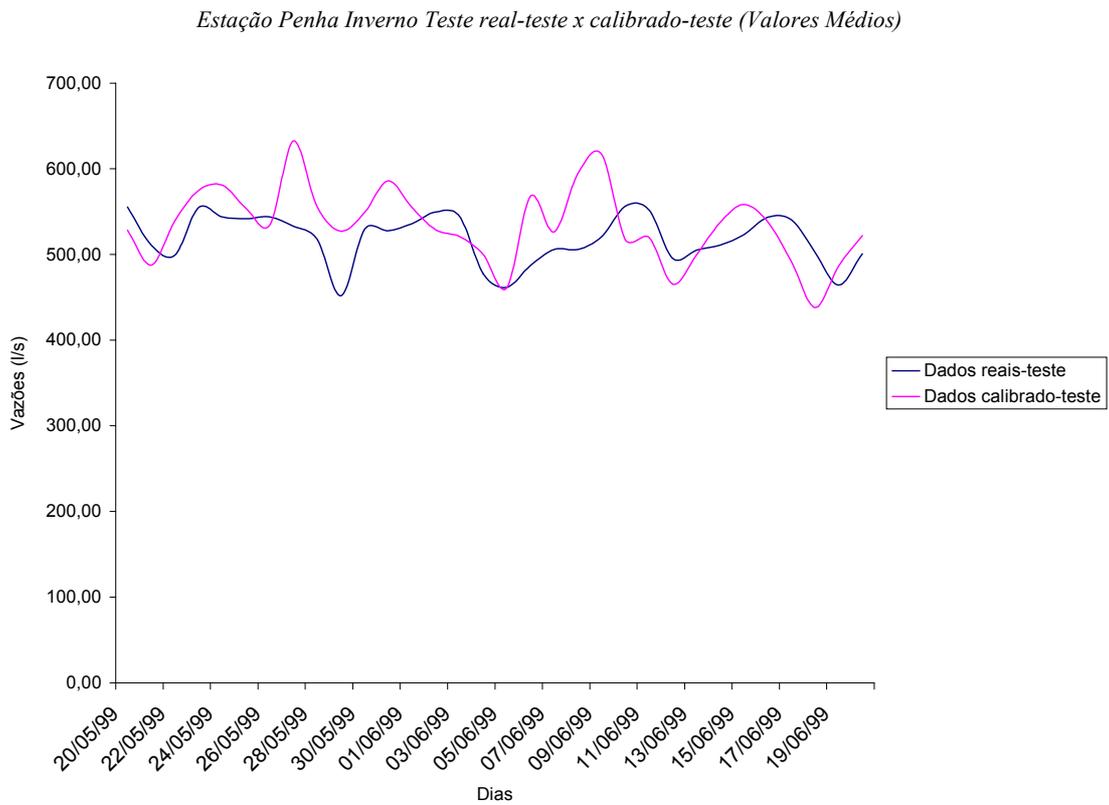


FIGURA 03 – Resultado do Teste para a Estação de Inverno

Estação Penha Primavera Treino Real x Calibrado (Dados Médios)

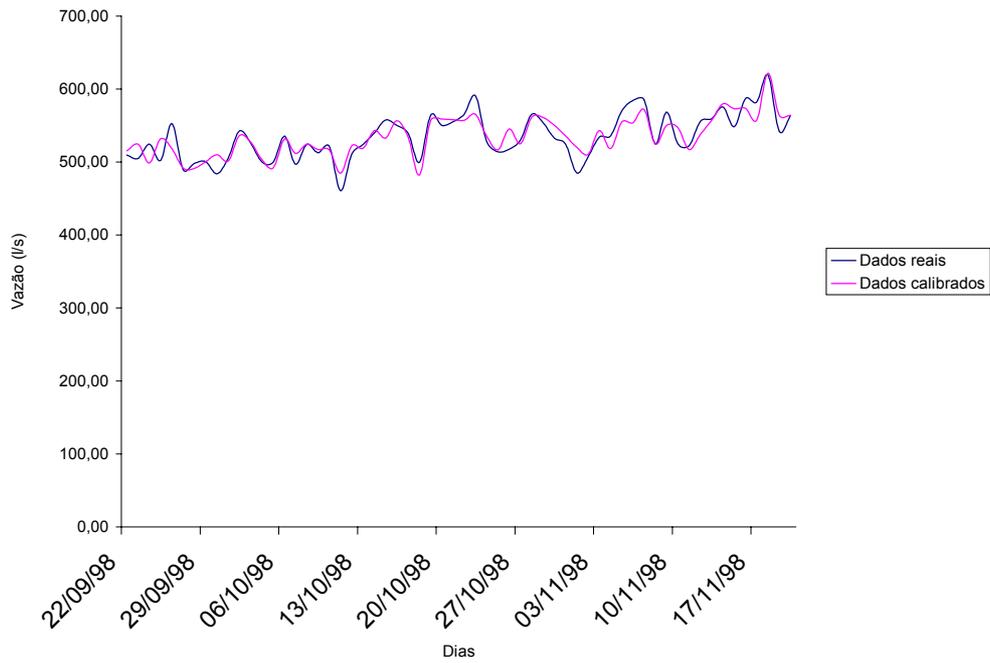


FIGURA 04 – Resultado do Treinamento para a Estação da Primavera

Estação Penha Primavera Teste Real-Teste x Calibrado-Teste (Dados Médios)

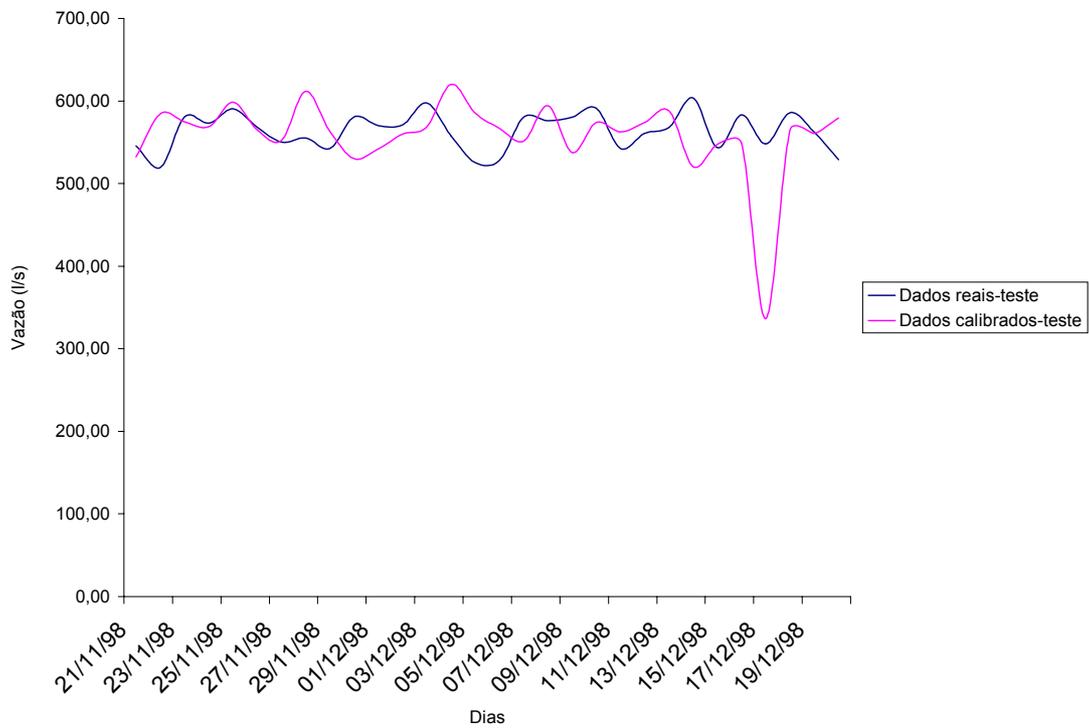


FIGURA 05 – Resultado do Teste para a Estação de Primavera

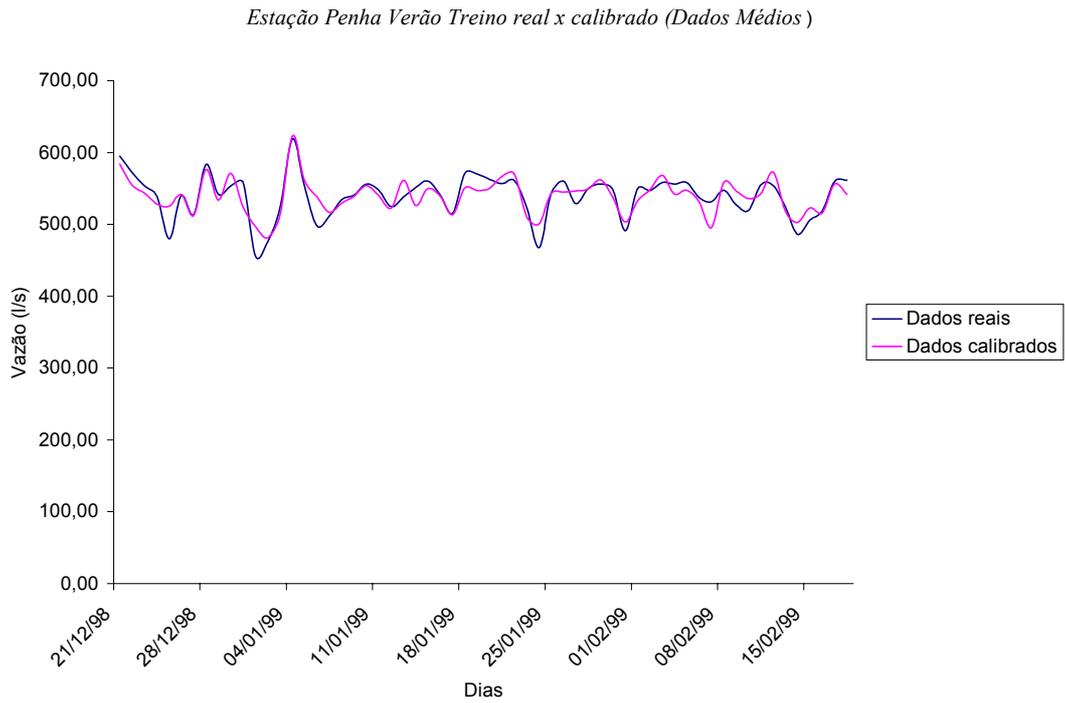


FIGURA 06 – Resultado do Treinamento para a Estação de Verão

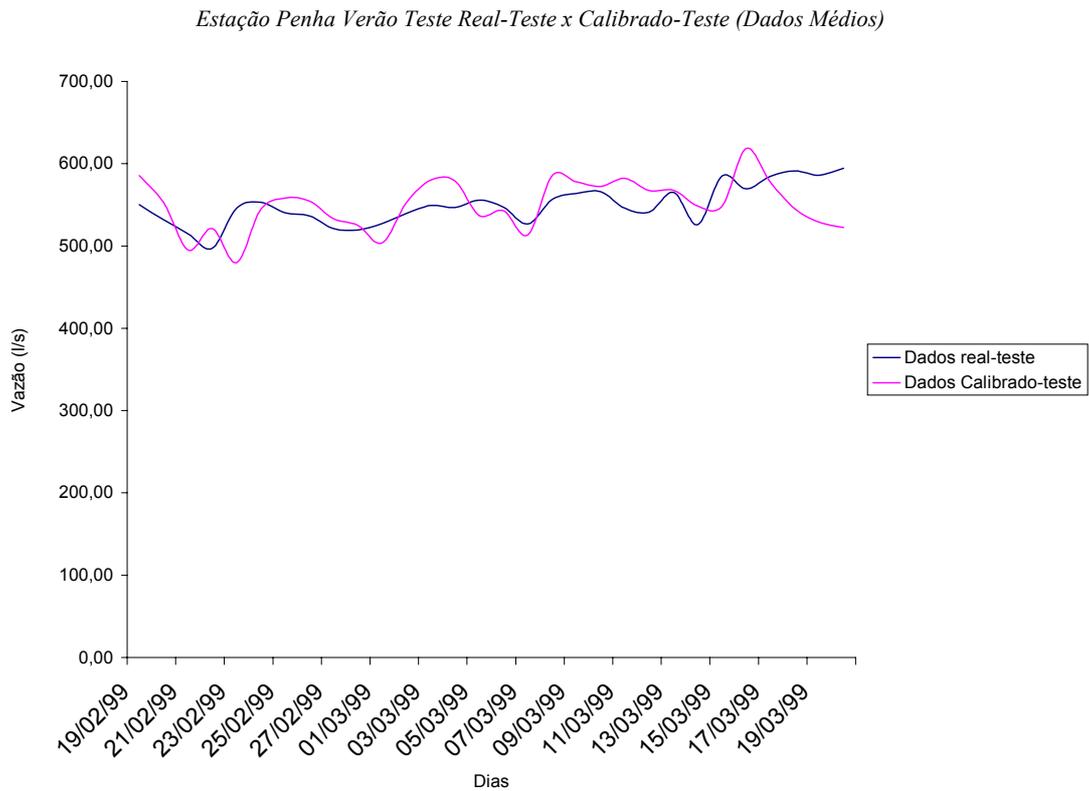


FIGURA 07 – Resultado do Teste para a Estação de Verão

Estação Penha Outono Treinamento Real x Calibrado (Dados Médios)

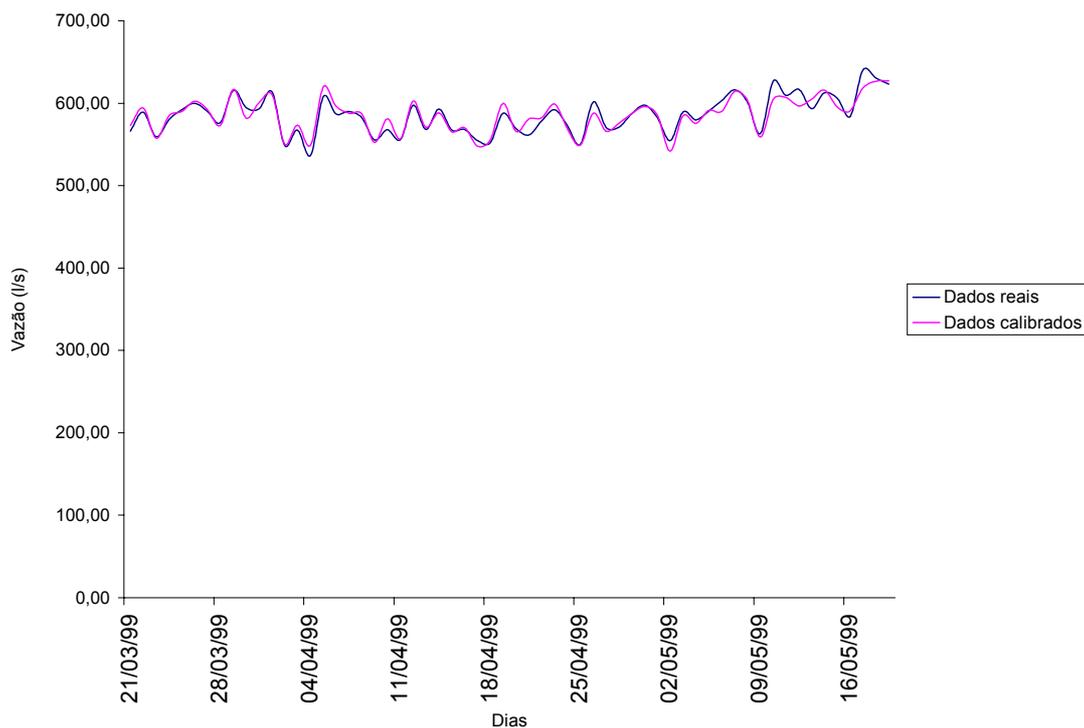


FIGURA 08 – Resultado do Treinamento para a Estação de Outono

Estação Penha Outono Teste Real-Teste x Calibrado-Teste (Dados Médios)

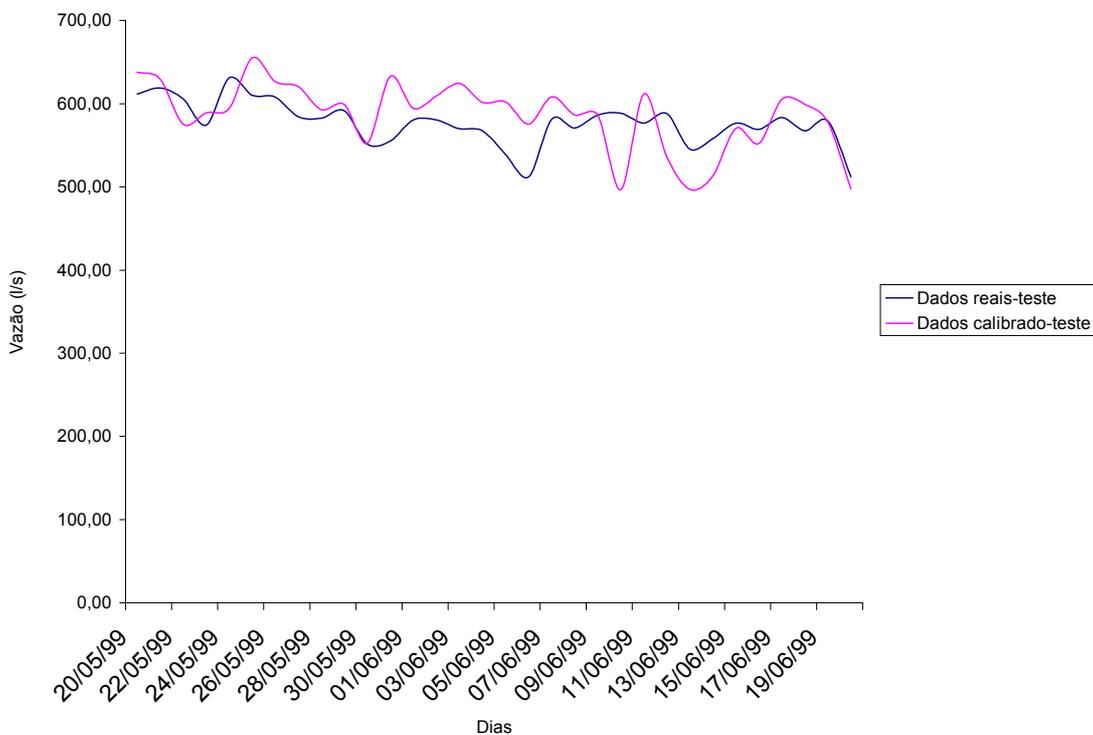


FIGURA 09 – Resultado do Teste para a Estação de Outono

## CONCLUSÃO

Uma das dificuldades na previsão de vazões é a presença da sazonalidade devido aos períodos seco e úmidos do ano, por isso optou-se em dividir os dados em quatro estações do ano.

Os modelos e séries temporais baseados na metodologia de Box & Jenkins, necessitam de uma laboriosa formulação estatística para tratar a não-estacionaridade, identificar e estimar os dados de vazões aos modelos de séries temporais, sendo que os resultados, principalmente para a previsão vários passos à frente, nem sempre são satisfatórios.

Pesquisas por abordagens alternativas, capazes de superar tais dificuldades têm sido intensas. Uma das atuais tendências é a aplicação de modelos de redes neurais para previsão de vazões, visando mostrar a eficiência desta metodologia quando comparada com os resultados dos modelos de séries temporais.

O principal objetivo deste trabalho concentrou-se na previsão da demanda horária, usando um modelo de redes neurais multicamadas, com topologia do tipo três camadas, com algoritmo de treinamento utilizando o método do gradiente conjugado escalonado, escolhido em razão da grande capacidade de generalização e velocidade de processamento e também em razão do reduzido valor do resíduo das diferenças entre valores observados de demanda e os calculados pela RNA's.

Similarmente a outros métodos de previsão, a técnica de redes neurais exige uma série histórica completa, como dados de entrada para o treinamento. Neste caso, quando o banco de dados possuir intervalos de falhas é necessário utilizar métodos estatísticos adequados de preenchimento de falha que aproximem a tendência temporal da variável.

A escolha de dez neurônios na camada intermediária e 1500 iterações foi baseada em testes realizados com a rede, como a variação do erro quadrático foi pequena quando se variava o número de neurônios e iterações, foi fixada esta topologia para facilitar a comparação das redes.

Observou-se que o erro quadrático final para o treinamento é aceitável, já o erro quadrático final para o teste apresenta valores maiores porém ainda pequenos, esta variação pode ter ocorrido devido os dados de teste não estarem representando de maneira adequada os dados de treinamento, já que não houve eventos críticos neste período.

Os melhores resultados foram para as estações da primavera e verão, período onde ocorre maior intensidade de chuva na região metropolitana.

## AGRADECIMENTOS

Esta pesquisa conta com o apoio financeiro da Fundação de Amparo à Pesquisa do Estado de São Paulo - FAPESP, na forma de bolsa de doutorado a pesquisadora Carla Silva da Silva.

## REFÊRENCIAS BIBLIOGRÁFICAS

BARP, A. R. B., **Modelagem chuva-vazão em bacias hidrográficas com suporte em redes neurais artificiais**. Tese de doutorado. Faculdade de Engenharia Civil da Universidade Estadual de Campinas. Campinas FEC, 1999.

BOLAND, J. J., **Forecasting water use: A tutorial**. Computer Applications in water Resouces. edited by H. C. Torno, Buffalo, Nova York, p. 907-916, 1985.

DECK, S. et al., **Comparison of a neural network and traditional classifier for machine vision inspection**. Applied Engineering in Agriculture, vol. 11, N. 2, p. 319-326, 1995.

HAYKIN, S., **Neural network – A comprehensive foudantions**. New York: McMillan College Company, 1994

MATHWORKS, **Neural Network Toolbox User's Guide** – For use with MATLAB v.3. Mass: The Mathworks, Inc. 1998.

- MAYS, L. W. e TANG, Y. K., **Hydrosystems Engineering & Management**, McGraw-Hill, 1992.
- MOLLER, M. F., **A scaled conjugate gradient algorithm for fast supervised learning**. Neural Network. Vol. 6, p.525-533, 1993.
- NIGRINI, A., **Neural networks for pattern recognition**. Cambridge, MA: The MIT Press, 1993.
- SILVA, C. S. e BARBOSA, P. S. F., **Previsão da demanda horária de água em sistemas urbanos de abastecimento**. XIV Simpósio Brasileiro de Recursos Hídricos, Aracaju-SE, 2001.
- TAO, Y. et al., **Machine vision for color inspection of potatoes and apples**. Transactions of the American Society of Agricultural Engineers, vol. 38, N.5, p. 1555-1561, 1995.
- TAWEL, R., MARKO, K., e FELDKAMP, L., **Custom VLSI ASIC for automotive applications with recurrent networks**. 1998. URL: <http://www.jpl.nasa.gov/releases/98/ijcnn98.pdf> .
- TRIPPI, R. R. e TUBAN, E., **Neural networks in finance and investing**. Chicago: Probus, 1993.
- ZURADA, J. M., **Introduction to artificial neural systems**. Boston: Plus Publishing Company, 1992.