

## Redes Neurais Artificiais Aplicadas à Previsão de Consumo de Água

Alex Vieira Falkenberg<sup>1</sup>, Andrea Sell Dyminski<sup>2</sup>, Eduardo Parente Ribeiro<sup>3</sup>

<sup>1</sup>Mestrando em Métodos Numéricos em Engenharia, CESEC, UFPR.

<sup>2</sup>Dep. Construção Civil, CESEC, UFPR.

<sup>3</sup>Dep. Engenharia Elétrica, UFPR.

E-mails: alexvf@cesec.ufpr.br, andrea@cesec.ufpr.br, edu@eletr.ufpr.br

### Abstract

*Water demand forecasting is extremely necessary to optimize the production costs and losses of drinking water distribution plants. This study introduces a model using artificial neural networks aiming to foresee the water demand in the next 24 hours for the city of Ponta Grossa, Paraná, Brazil.*

### 1. Introdução

Nos últimos anos as companhias de saneamento têm investido largamente na automação de seus sistemas de abastecimento de água, proporcionando dados em tempo real de vazão e pressão das cidades. Visando uma completa otimização dos sistemas, torna-se mister modelar o comportamento do consumo ao longo do dia das zonas de distribuição.

Várias são as vantagens da obtenção de um modelo de previsão de consumo, entre as quais podem ser citadas:

- Identificação imediata de perda física no sistema: Dispondo-se de um modelo confiável de previsão, este acusará em tempo hábil qualquer anormalidade (vazamentos);
- Ganho da qualidade da água através de estoques adequados: Limitando-se a transferir apenas o volume necessário para os reservatórios, evita-se a perda de qualidade da água não consumida em tempo adequado;
- Planejamento da operação das elevatórias da água *in natura* e tratada segundo contratos de energia: Conhecendo-se o consumo nos períodos de pico de energia, pode-se planejar a reserva de água para este período e desligar os equipamentos, evitando-se as multas sobre as tarifas de energia elétrica;
- Planejamento da operação diária da Estação de Tratamento de Água – ETA, de modo a obter os melhores pontos de operação de todos os sistemas que compõem esta planta;
- Estimativa dos “set points” de controle de pressão e vazão ótimos ao longo do dia;
- Logística de produtos químicos da estação de tratamento de água: através de uma previsão de longo tempo de consumo (diária e mensal), tem-se como determinar a logística dos produtos químicos utilizados, evitando-se perdas e atrasos.

O presente trabalho, com a colaboração da Sanepar - Companhia de Saneamento do Paraná, tem como foco de estudo a cidade de Ponta Grossa, localizada a 110 km

a noroeste de Curitiba, com população de aproximadamente 200 mil habitantes. Esta cidade teve seu sistema de abastecimento de água recentemente automatizado, objetivando prever o consumo de determinados bairros nas próximas 24 horas. Embora o volume de dados seja reduzido, compondo um período de apenas três meses, procurou-se modelar a série temporal, representada pelos consumos horários de um bairro de Ponta Grossa, através de redes neurais.

Primeiramente apresenta-se uma arquitetura genérica da topologia do sistema de distribuição de água e os possíveis problemas que possam aparecer na coleta dos dados. A seguir são apresentados vários fatores que contribuem para uma variação do consumo de uma determinada zona de distribuição, a fim de que possam ser definidas as principais entradas da rede neural.

### 1.1. Arquitetura do Sistema de Abastecimento

A topologia de rede de um sistema de abastecimento de água é composta pela camada mais baixa, de CLPs (controladores lógicos programáveis) remotos, que podem estar lendo medidas de vazão locais através de placas de entradas analógicas, ou então recebendo remotamente essas medições via modem ou rádio. Em um nível acima encontram-se os CLPs mestres, que por sua vez também coletam dados dos medidores de vazão locais ou remotos, e recebendo os dados dos CLPs estão as estações SCADA (Supervisory, Control and Data Acquisition), permitindo a visualização e a operação de toda planta.

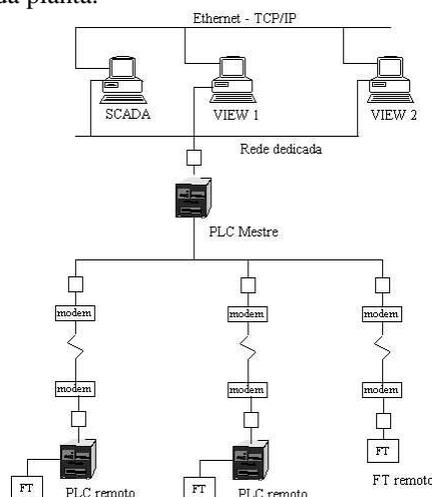


Figura 1 – Topologia de rede genérica de um sistema de supervisão e controle de distribuição de água.

Diversas são as causas que podem propiciar a incoerência de uma leitura, dentre as mais comuns podem ser citadas:

- Falha do sensor de vazão;
- Falha de comunicação em algum ponto da rede;
- Falta de energia prolongada;
- Falhas de equipamentos envolvidos;
- Vazamentos;
- Manutenção da rede hidráulica;
- Etc.

A fim de que os dados de treinamento da rede neural sejam corretos, é necessária uma filtragem dos mesmos [1], conjugando os sinais de falha de comunicação e falhas de sensor com os de leitura totalizada do volume de consumo. Da mesma forma, devem ser verificadas as datas onde ocorreram vazamentos e manutenções da rede hidráulica, a fim de que os dados coletados nestas ocasiões sejam ignorados.

Portanto, ao se planejar um sistema de supervisão com treinamento automático da rede neural, todas as possíveis falhas citadas acima devem ser consideradas para validar os novos dados de treinamento.

## 1.2. Principais Fatores de Consumo

Estudos sobre comportamento do consumo de água em cidades comprovam sua característica dinâmica, multivariável e não linear, com fatores que influenciam de forma diferente em cada país, cidade e zonas de distribuição [2].

Dentre os fatores que caracterizariam um certo tipo de comportamento em diferentes cidades, podem ser citados:

- Localização Geográfica: Cidades litorâneas apresentam uma curva de consumo diferente de cidades localizadas em regiões serranas;
- Turismo: Cidades turísticas incorporam forte sazonalidade em certas épocas do ano.

Dentre os fatores que caracterizam um certo tipo de comportamento em diferentes bairros, podem ser citados:

- Tipo do bairro: residencial, comercial, industrial ou misto;
- Aspectos sócios econômicos: bairros de classe alta têm comportamento diferenciado dos bairros de classe baixa, por exemplo, o fato de pessoas de classe alta viajarem nos fins de semana.

Dentre os fatores comuns, podem ser identificados:

- Condições do tempo: o consumo cai vertiginosamente com a presença de chuva;
- Estação do ano;
- Dias da semana e feriados: existem comportamentos variados de consumo às segundas-feiras em relação aos domingos, sábados e resto da semana.

Algumas regras de consumo são evidenciadas ao analisar o comportamento de uma população, por exemplo:

- Após 2 ou 3 dias de chuvas consecutivos, a presença de sol causa um alto consumo de água, visto que muitas pessoas aproveitam a oportunidade para lavarem suas roupas, carros e calçadas;
- No verão, depois de um dia quente e seco, muitas pessoas regam seus jardins ao observar o aspecto das plantas;

Outros fatores comportamentais também interferem no consumo e variam em cada país, por exemplo, no Brasil, pelo fato da água ter um custo relativamente pequeno, é comum pessoas desperdiçarem em diversos atos do dia a dia, como no banho, ao escovar os dentes, ao fazer a barba, etc.

## 2. Metodologia aplicada

O objetivo do trabalho é de prever o consumo de uma determinada zona de distribuição nas próximas 24 horas. Para estudo foi escolhido o bairro Uvaranas da cidade de Ponta Grossa, com consumo médio diário em torno de 14000 m<sup>3</sup>. Encontrava-se disponível um banco de dados de três meses contendo as leituras das vazões totalizadas coletadas a cada 5 minutos.

Primeiramente os dados foram coletados do banco de dados e filtrados a fim de que tenham coerência e que não prejudiquem o treinamento da rede, escolhendo-se a primeira leitura válida de cada hora. Os dados cuja diferença do tempo de coleta entre duas amostras seguidas fossem 5 minutos maiores ou menores que uma hora foram descartados.

Devido à dificuldade de dispor de informações de temperatura e umidade previstas, resolveu-se não utilizá-las no modelo.

Os primeiros testes, tomando como exemplo estudos anteriores [1,3 e 4], foram feitos objetivando prever o consumo da hora seguinte. A fim de definir a melhor combinação de entradas para a rede, foram testadas quatro combinações, variando-se as funções de ativação e o número de neurônios na camada escondida entre um e cinco neurônios.

Testes com funções de ativação:

- Linear / linear;
- Tangente hiperbólica / linear com normalização entre -1 e +1 dos dados de entrada;
- Tangente hiperbólica / tangente hiperbólica com normalização entre -1 e +1 dos dados de entrada;
- Tangente hiperbólica / linear com normalização do desvio padrão dos dados de entrada;
- Tangente hiperbólica / linear com normalização do desvio padrão dos dados de entrada e análise dos componentes principais com significância de 2%.

Todas as redes são do tipo *feedforward* com algoritmo de treinamento *backpropagation* Levenberg-Marquardt.

O lote total de dados foi dividido de tal forma que os primeiros 85% foram destinados para treinamento e os 15% restante para teste.

Para avaliação dos resultados foram utilizados o erro médio quadrático (MSE – Eq. 1) para o conjunto de treinamento, e para o conjunto de teste, a medida de erro

percentual médio (Eq. 2), a porcentagem dos resultados com erro menor que 5%, a porcentagem dos resultados com erro menor que 10%, e o coeficiente de correlação entre os resultados simulados e os valores reais:

$$MSE = \frac{1}{n} \sum_{i=1}^n (e_i)^2 \quad (1)$$

$$\mathcal{E}_{\% \text{ médio}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{t_i} \right| \times 100\% \quad (2)$$

onde  $e_i$  representa o erro, ou a diferença entre o valor real e o resultado da rede, e  $t_i$  representa o *target*, ou valor real de consumo.

### 3. Resultados

Foram treinadas e testadas quatro arquiteturas de redes com diferentes combinações de entradas, assim denominadas de “rede A” a “rede D”. Para cada combinação foram feitas diferentes normalizações das entradas e utilizadas diferentes funções de ativação.

Em algumas redes foi utilizada a técnica de análise dos componentes principais, que tem por finalidade reduzir o número de variáveis originais do problema (entradas), geralmente altamente correlacionadas entre si, através de combinações lineares não correlacionadas das mesmas. Embora seja necessário todo o conjunto das novas variáveis, este pode ser reduzido desconsiderando-se as variáveis menos significantes, que muito pouco contribuem para o todo. Os resultados são apresentados a seguir, onde encontram-se citados os parâmetros utilizados como entradas, saídas e a arquitetura utilizada (número de entradas – neurônios na camada escondida – número de saídas).

#### Rede A:

Entradas:

- Os 7 dias da semana representando entradas individuais binárias;
- Consumo das últimas 24 horas.

Saída:

- Consumo da próxima hora.

Arquitetura:

- 31-5-1, para as quatro primeiras redes;
- 10-5-1 para a rede com análise dos componentes principais (ACP).

Tabela 1: resultados obtidos com a rede A

Funções ativação	Norm	MSE (trein)	$\rho$ (teste)	Erro %	% Erro < 5%	% Erro < 10%
Linear / linear	-	1588	0.8756	10.89	42.38	65.71
Tangh / linear	(-1,+1)	0.00318424	0.8562	12.26	41.90	62.38
Tangh / tangh	(-1,+1)	0.00184876	0.8828	12.23	44.29	68.10
Tangh / linear	Desvio padrão	0.0118001	0.8397	15.35	50.00	69.05
Tangh / linear	Desvio padrão + ACP (2%)	0.106769	0.9381	16.03	27.14	46.67

#### Rede B:

Entradas:

- Os 7 dias da semana representando entradas individuais binárias;
- As 24 horas do dia representando entradas individuais binárias;
- Consumo das 3 últimas horas.

Saída:

- Consumo da próxima hora.

Arquitetura:

- 34-5-1, para as quatro primeiras redes;
- 29-5-1 para a rede com análise dos componentes principais.

Tabela 2: resultados obtidos com a rede B.

Funções ativação	Norm	MSE (trein)	$\rho$ (teste)	Erro %	% Erro < 5%	% Erro < 10%
Linear / linear	-	1254	0.9119	7.08	64.09	87.64
Tangh / linear	(-1,+1)	0.00206297	0.8985	7.02	64.48	88.03
Tangh / tangh	(-1,+1)	0.00295726	0.9206	6.26	70.66	89.96
Tangh / linear	Desvio padrão	0.00980605	0.9283	6.28	69.11	89.19
Tangh / linear	Desvio padrão + ACP (2%)	0.0166980	0.9278	6.10	71.04	91.51

#### Rede C:

Entradas:

- Os 7 dias da semana representando entradas individuais binárias;
- As 24 horas do dia representando entradas individuais binárias;
- Consumo das 2 últimas horas.

Saída:

- Consumo da próxima hora.

Arquitetura:

- 33-5-1, para as quatro primeiras redes;
- 29-5-1 para a rede com análise dos componentes principais.

Tabela 3: resultados obtidos com a rede C

Funções ativação	Norm	MSE (trein)	$\rho$ (teste)	Erro %	% Erro < 5%	% Erro < 10%
Linear / linear	-	1260.29	0.9105	7.11	64.86	86.87
Tangh / linear	(-1,+1)	0.00189119	0.9294	6.28	67.95	90.35
Tangh / tangh	(-1,+1)	0.0015307	0.9364	5.74	73.75	88.80
Tangh / linear	Desvio padrão	0.0142054	0.9381	6.38	67.95	88.80
Tangh / linear	Desvio padrão + ACP (2%)	0.0143354	0.9294	6.45	69.11	89.19

Rede D:

Entradas:

- Os 7 dias da semana representando entradas individuais binárias;
- As 24 horas do dia representando entradas individuais binárias;
- Consumo da última hora.

Saída:

- Consumo da próxima hora.

Arquitetura:

- 32-5-1, para as quatro primeiras redes;
- 29-5-1 para a rede com análise dos componentes principais.

Tabela 4: resultados obtidos com a rede D

Funções ativação	Norm	MSE (trein)	$\rho$ (teste)	Erro %	% Erro < 5%	% Erro < 10%
Linear / linear	-	1334.03	0.9207	6.46	68.50	88.98
Tangh / linear	(-1,+1)	0.00214875	0.9348	5.51	75.20	91.73
Tangh / tangh	(-1,+1)	0.00205539	0.9327	5.74	69.29	91.73
Tangh / linear	Desvio padrão	0.0147648	0.9273	6.00	69.69	90.16
Tangh / linear	Desvio padrão + ACP (2%)	0.01428812	0.9310	5.65	71.65	91.73

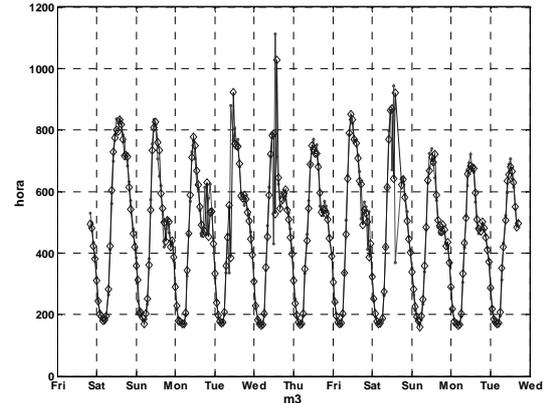


Figura 2 – Previsão horária de Uvaranas utilizando a rede D. (ponto – real / círculo – previsto).

Para prever as 24 horas seguintes optou-se por utilizar a técnica “multi-step”, ou seja, a saída da rede neural será uma realimentação da próxima previsão.

Foram testadas as previsões das 24 horas a partir das horas 5:00 (figura 3), 11:00 (figura 4), 18:00 (figura 5) e 22:00 (figura 6) por se tratarem de horários estratégicos para a operação do sistema. Utilizou-se um vetor pertencente ao lote de teste, ou seja, que não tenha participado do treinamento da rede.

Comparando-se os resultados, escolheu-se, portanto, a rede para a qual obteve-se o menor valor de erro, ou seja, a que utiliza o consumo da hora passada, as entradas binárias referentes aos sete dias da semana e as entradas binárias referentes às 24 horas, denominada “rede D”, com funções de ativação linear e tangente hiperbólica.

Além da análise dos erros, outro critério importante para a escolha do modelo mais adequado foi a necessidade da previsão não arriscar picos descendentes, já que para o propósito em questão, é preferível que, em caso de erro, o valor de consumo previsto seja maior que o valor real, como pode ser observado na figura 2, representando a simulação da rede D (azul) comparada aos dados reais de consumo (vermelho). Deve-se observar que os picos de baixa do consumo foram provocados por operações anormais da rede hidráulica, em períodos de teste e implantação do sistema de automação.

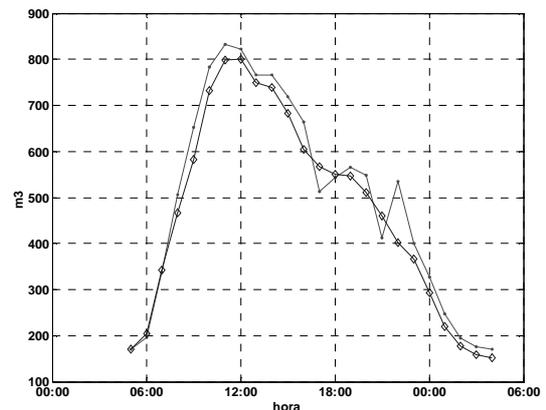


Figura 3 – Previsão das próximas 24 horas a partir das 5:00 de Uvaranas. (ponto – real / círculo – previsto).  
Erro percentual médio: 7.32 % / coeficiente de correlação: 0.9869

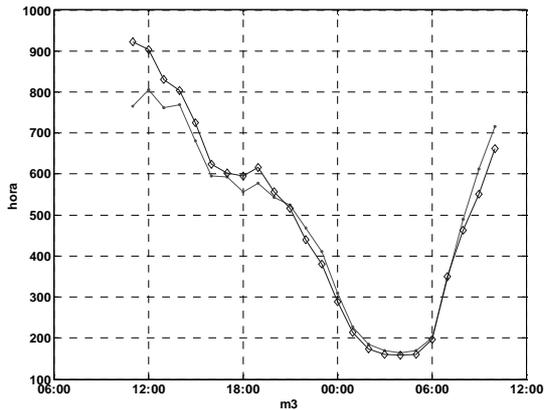


Figura 4 – Previsão das próximas 24 horas a partir das 11:00 de Uvaranas.(ponto – real / círculo – previsto).  
 Erro percentual médio: 6.27 % / coeficiente de correlação: 0.9856.

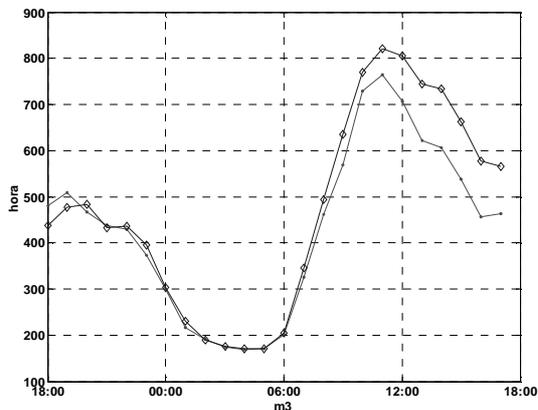


Figura 5 – Previsão das próximas 24 horas a partir das 18:00 de Uvaranas.(ponto – real / círculo – previsto).  
 Erro percentual médio: 8.53 % / coeficiente de correlação: 0.9796.

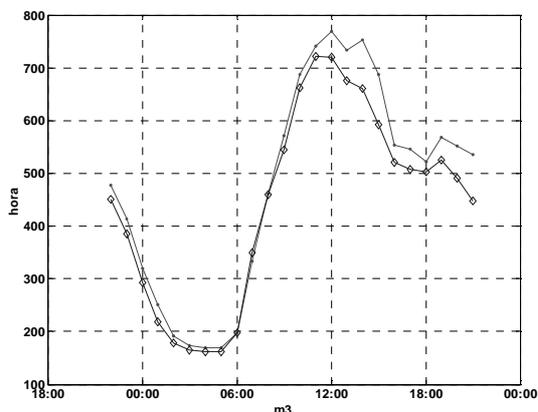


Figura 6 – Previsão das próximas 24 horas a partir das 22:00 de Uvaranas.(ponto – real / círculo – previsto).  
 Erro percentual médio: 6.84 % / coeficiente de correlação: 0.9927

#### 4. Conclusões

Os resultados podem ser considerados bastante satisfatórios, levando-se em conta que a base de dados utilizada para treinar a rede é pequena, além de que o conjunto de dados reflete várias anormalidades decorrentes de testes realizados neste período relacionados ao projeto de automação do sistema de abastecimento de água.

O ideal seria, portanto, dispor de dados de alguns anos para que as informações da estação do ano e/ou do mês possam ser inseridas no modelo.

Com o estudo das causas que interferem na dinâmica do consumo ao longo do tempo, pode-se tentar identificar regras de consumo da região em estudo e incorporá-las à rede neural.

Com relação à previsão do consumo nas próximas 24 horas, observa-se que o consumo previsto no período noturno apresenta-se com erros muito pequenos, e desta forma, uma diferença significativa entre um valor de consumo previsto e o real seria suficiente para gerar um alarme indicando a presença de um possível vazamento na rede hidráulica.

A previsão das 24 horas a partir das 11:00, apresentando um erro percentual médio de 6.27%, atende à necessidade de uma estimativa de produção de água para o restante do dia, assim como a necessidade de reserva para o período de pico de energia, visto que o erro, sendo positivo, não acarreta em problemas de falta de abastecimento.

A previsão a partir das 18:00 apresentou um erro percentual médio de 8.53 %, bastante aceitável, e informa com boa precisão a tendência do consumo no período noturno, possibilitando um planejamento, se necessário for, para recuperar a reserva para o dia seguinte.

O erro sempre aumenta conforme o número de horas adiante da hora inicial, visto que na previsão “multi-step” o erro é cumulativo.

Estudos ainda estão sendo realizados com a finalidade de melhorar a previsão, principalmente com relação à faixa entre 11:00 e 18:00, onde ocorrem maiores irregularidades.

Visto que as cidades apresentam um comportamento dinâmico ao longo dos anos, a rede deveria ser treinada periodicamente para adaptar-se às mudanças do meio.

#### 5. Agradecimentos

À Sanepar, em especial à USCO, pelas informações e disponibilidade dos dados.

#### Referências

[1] Narate Lertpalangsuntia, Christine W. Chana, Ralph Mason, Paitoon Tontiwachwuthikul, “A toolset for construction of hybrid intelligent forecasting systems: application for water demand prediction”, *Artificial Intelligence in Engineering* vol.13 pag. 21-42,1999

- [2] A. An, N. Shan, C. Chan, N. Cercone, and W. Ziarko, "Discovering rules for water demand prediction: An enhanced rough-set approach," *Engineering Applications of Artificial Intelligence*, vol. 9, pp. 645-653, 1996.
- [3] G. Florent, B. Bernardt, G. Denis, "Drinking Water Demand Using an hourly timestep", National School for Water and Environmental Engineering –Strasbourg, France. The Fifth International Conference on Neural Information Processing, 1998.
- [4] Harold L. Stark, Stephen J. Stanley, Ian D. Buchanan, "Water Demand Forecasting Using Artificial Neural Networks," Department of Civil and Environmental Engineering – University of Alberta, Alberta, Canada.