

# MODELAGEM HIDROLÓGICA UTILIZANDO REDES NEURAS ARTIFICIAIS EM BACIAS URBANAS

Cláudia Cristina Santos  
Instituto Nacional de Pesquisas Espaciais – INPE / MARSP  
Av. dos Astronautas, 1758, Jd. da Granja, São José dos Campos-SP, 12.227-010  
e-mail: [claudiac@met.inpe.br](mailto:claudiac@met.inpe.br)

Augusto José Pereira Filho  
Universidade de São Paulo, São Paulo – USP / IAG / DCA  
Rua do Matão, 1226, São Paulo-SP, 05508-9000  
e-mail: [apereira@model.iag.usp.br](mailto:apereira@model.iag.usp.br)

## ABSTRACT

An artificial neural network (ANN) hydrologic model was developed to forecast floods on a heavily urbanized watershed within the Metropolitan Area of São Paulo (MASP). The Tamanduateí watershed is fustigated with frequent flash floods during the summer season. Recent results have indicated that convective events tend to produce higher rainfall accumulation over the MASP region. Thus, this simple yet conceptually sound model can be used to anticipate flood events. The ANN was trained with streamflow and weather radar derived rainfall accumulation data from several cases. The model was verified with a large number of independent flash floods events.

## 1 - INTRODUÇÃO

O processo de transformação de chuva sobre a bacia em vazão do rio é não linear, porém, representações simplificadas são freqüentemente utilizadas devido à limitação de dados hidrometeorológicos. Geralmente estas representações são feitas através dos modelos chuva-vazão (Singh, 1988). Devido à limitação de dados hidrometeorológicos e da não linearidade da bacia as vezes é difícil a utilização destes modelos. Com os avanços na área de modelagem teórica de sistemas não lineares, desenvolveu-se as *Redes Neurais Artificiais (RNA)* (Haykin, 1994). A RNA é uma estrutura matemática não linear que é capaz de representar arbitrariamente processos complexos não lineares que relacionam entradas e saídas em qualquer sistema. Os modelos de RNA têm sido usados com sucesso para modelar relações envolvendo séries temporais de entrada-saída complexas em várias áreas. Neste trabalho, utiliza-se a técnica de RNA por causa da sua eficiência na modelagem de processos hidrológicos de transformação de chuva-vazão, não requerendo conhecimento explícito dos mesmos. Foram utilizados dados de chuva estimados com radar meteorológico (Braga, 1992) e dados fluviométricos da rede telémetrica da cidade de São Paulo (Braga, 1989) no treinamento de uma rede de três camadas do tipo "feedforward" com algoritmo LLSSIM (Hsu, et al, 1995).

## 2 – DADOS E METODOLOGIA

A bacia hidrográfica do rio Tamanduateí (DAEE, 1988) se localiza na margem esquerda do rio Tietê, na Região Metropolitana de São Paulo (RMSP). Sua área de drenagem é de cerca de 310 km<sup>2</sup> (Fig. 1) e o tempo de concentração foi estimado em 4 horas. Essa bacia tem mais de 80% de área urbana (CTO, 1987).

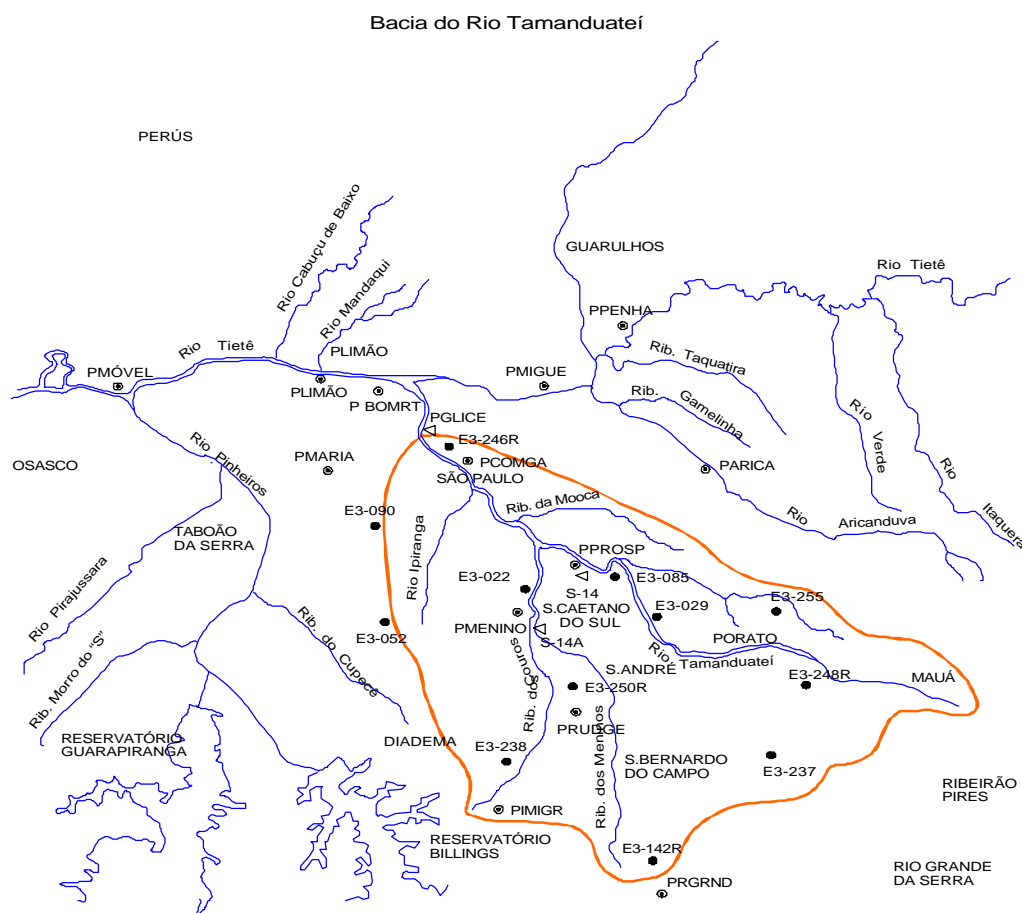


Figura 1: Área de drenagem da bacia do Rio Tamanduateí

Utilizou-se os dados de nível do rio Tamanduateí do posto FGLICE (Fig. 1) da rede telemétrica do Alto Tietê. Os dados foram obtidos em intervalos de 10 minutos. Estes dados foram transformados em vazão por meio de uma curva chave obtida para a bacia.

Os dados de chuva foram obtidos do Radar Meteorológico de São Paulo com resolução temporal de 10 minutos e resolução espacial de 2 km x 2 km. A região em estudo corresponde a aproximadamente 4% da área de abrangência do radar.

Selecionou-se os eventos de cheia ocorridos em 13/05/92, 07/02/92 e 18/11/94 para treinar a RNA, e os ocorridos em 08/02 e 11/12/92, 06/02, 27/05 e 26/10/94 para verificação do modelo.

A rede neural utilizada é do tipo “feed forward” (Haykin, 1994) com três camadas distintas, uma camada de entrada, uma de saída e uma intermediária denominada de camada escondida (Fig. 2). O treinamento foi realizado com o algoritmo LLSSIM de Hsu et al. (1996) que combina a técnica de mínimos quadrados linear com a otimização simplex de inicializações múltiplas e uma função sigmóide para encontrar a solução ótima ou próxima da ótima.

Os elementos de processamento em cada camada são chamados de nós ou unidades. Cada um desses nós é conectado aos nós das camadas vizinhas. Os parâmetros associados com cada uma dessas conexões são chamados pesos. Todas as conexões nodais são feitas apenas em uma direção (Hsu et al., 1995).

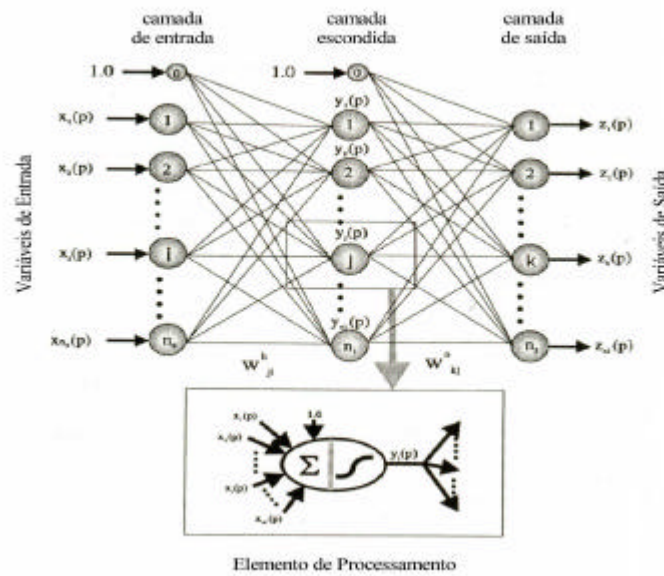


Figura 2: Rede Neural Artificial *feedforward* típica de três camadas (Fonte: Hsu et al.,1995).

Cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária (escondida) e constrói o padrão de resposta. As camadas intermediárias funcionam como extratoras de características. Seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema.

A arquitetura de um nó típico é também mostrado na Fig. 2. Cada nó  $j$  recebe um sinal de entrada de cada um dos nós  $i$  da camada anterior. Cada sinal de entrada ( $x_i$ ) tem associado a ele um peso ( $w_{ji}$ ). Faz-se então uma média ponderada entre os sinais de entrada e os pesos das conexões. O sinal de entrada (input) efetivo ( $S_j$ ) para o nó  $j$  é a somatória ponderada de todos os sinais de entrada. O resultado disto é aplicado à uma função de ativação ou função de transferência. O modelo matemático de processamento é dado por :

$$S_j = \sum_{i=0}^{n_0} w_{ji} \cdot x_i \quad (1)$$

O sinal de saída (output) do nó é produzido por meio da passagem do sinal de entrada efetivo,  $S_j$ , por meio de uma função de ativação não linear, denominada de função de transferência ou função limiar. A função de ativação *sigmóide* é muito utilizada nas RNAs. A função sigmoideal é caracterizada por seu formato S alongado, contínua, monotonamente crescente e limitada por duas assíntotas horizontais. Um neurônio  $j$  é definido pela função logística:

$$y_j = f(S_j) = \frac{1}{[1 + \exp(-S_j)]} \quad (2)$$

onde,

$$\begin{aligned} -\infty < S_j < +\infty \\ 0 < y_j < 1 \end{aligned}$$

Criou-se um banco de dados de 48 séries de entradas e saídas. Os dados de chuva e vazão foram normalizados entre 0 e 1, e 0.1 e 0.9, respectivamente, para evitar a saturação do sinal de saída, muito comum em aplicações da RNA (Gupta, et al., 1997).

Os dados de chuva disponíveis foram estimados a partir das medições de refletividade do radar. A chuva acumulada foi estimada em intervalos de 30 minutos sobre oito isócronas se afastando radialmente da jusante (Fig. 3). Desta forma, reduziu-se os dados de entrada para intervalos de 30 minutos com 8 valores de precipitação e uma de vazão (correspondente ao intervalo de tempo anterior). Como saída utilizou-se a vazão medida no intervalo de tempo atual.


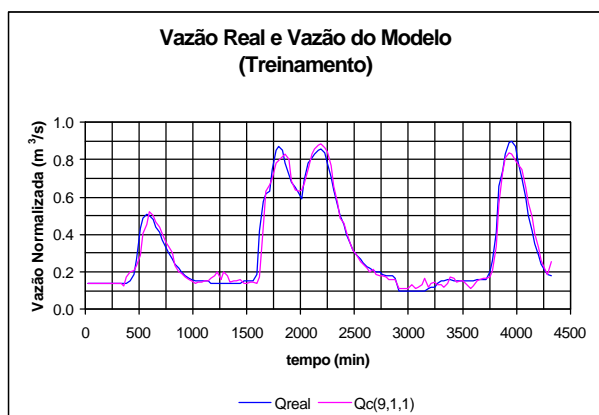


Figura 3: Bacia do Tamanduateí em quadrículas de 2 km x 2 km correspondente às coordenadas dos dados de radar meteorológico. Cores indicam as isócronas.

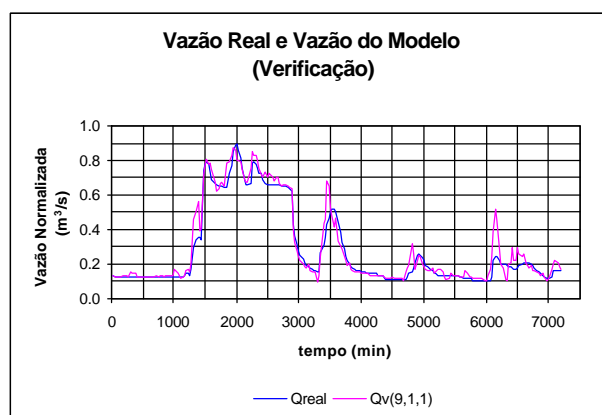
### 3 - RESULTADOS

A performance da RNA foi testada para vários cenários. Inicialmente, utilizou-se a precipitação como dado de entrada e a vazão como dado de saída. O treinamento indicou que o erro entre a vazão estimada e observada decresceu com aumento do número de camadas escondidas. Entretanto, a verificação do treinamento com dados independentes indicou que a erro entre a vazão estimada e observada cresceu com o número de camadas escondidas.

Em seguida, utilizou-se a vazão observada no intervalo imediatamente anterior como dado de entrada. Reduziu-se significativamente a diferença entre a vazão estimada e a vazão observada. A inclusão da "memória da bacia" na verificação do treinamento também resultou em uma boa correlação entre as vazões observadas e estimadas. A Fig. 4 mostra as vazões observadas e estimadas no treinamento e na verificação. A Fig. 5 mostra o diagrama de espalhamento e reta de regressão linear entre as vazões observadas e estimadas.

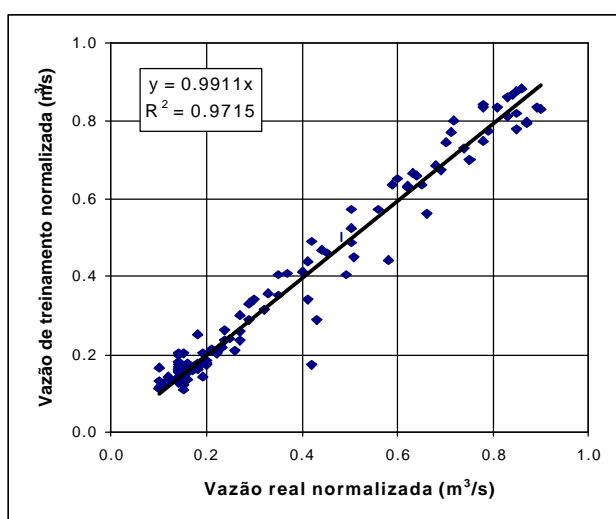


(a)

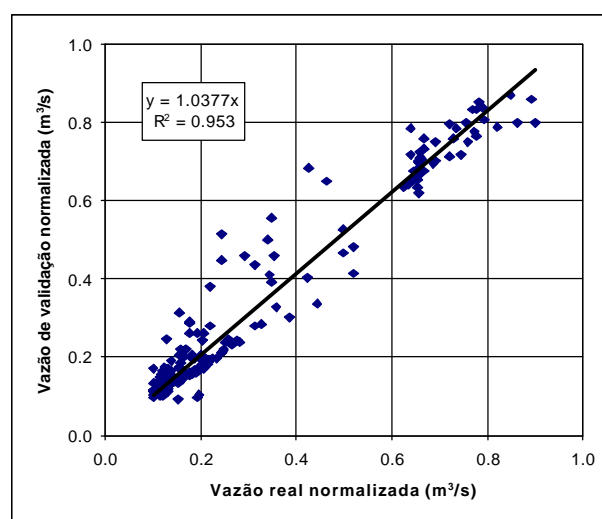


(b)

Fig. 4: Vazões normalizadas observadas (curva azul) e estimadas (curva vermelha) no treinamento (a) e verificação (b) da RNA. Esta indicado o número de camadas de entrada (9), escondida (1) e saída (1) da RNA.



(a)



(b)

Figura 5: Diagrama de espalhamento entre vazões observadas e estimadas pela RNA para o treinamento (a) e verificação (b). Estão indicadas as retas de regressão linear e os coeficientes de variação.

Finalmente, utilizou a chuva acumulada com resolução de 2 km x 2 km conjuntamente com a vazão imediatamente anterior como dados de entrada, ou seja, setenta e oito dados de entrada (vazão e chuva) e uma dado saída (vazão). Houve uma redução do erro no treinamento. Porém, este melhor ajuste reduziu os pesos dados à chuva e aumento o peso dado à vazão. Portanto, o aumento da resolução dos dados de chuva prejudicou o treinamento devido à maior variabilidade dos dados de chuva e respectivos erros. Ainda, a diferença entre a vazão estimada e observada no treinamento decresceu com o aumento de camadas escondidas, porém as diferenças aumentaram na verificação.

#### 4 – CONCLUSÃO

Os resultados sugerem um melhor desempenho da RNA com menor número de camadas escondidas e menor número de dados de entrada de chuva devido à maior variabilidade dos erros. Além disso, o aumento de camadas escondidas aumenta o tempo de processamento. Os resultados deste estudo com dados de chuva e vazão de alta resolução espaço-temporal são aparentemente superiores aos obtidos com séries de chuvas pontuais e vazão em outras bacias. Indicam também a viabilidade da modelagem do processo de transformação chuva-vazão por meio da RNA. Esta metodologia permite um treinamento contínuo da rede com a vantagem de melhor representar processos hidrológicos não lineares.

## 5 - AGRACEDIMENTOS

Os autores agradecem à Fundação Centro Tecnológico de Hidráulica pelo fornecimento dos dados de chuva e vazão e ao Dr. Kuo-lin Hsu pelo fornecimento do algoritmo LLSSIM e suporte técnico.

## REFERÊNCIAS

- Braga Jr., B.P.F. **Rede telemétrica do Alto Tietê**. Revista Águas e Energia Elétrica, Departamento de Águas e Energia Elétrica, nº 15, 1989.
- Braga Jr., B.P.F; Barros, M.T.L. **O Sistema de alerta a inundações da cidade de São Paulo**. Telemetria e Sensoriamento Remoto com Aplicações em Hidrologia e Meteorologia, Curitiba, FINEP, 1992.
- CTO – Centro Técnico Operacional **Estudo hidráulico e hidrológico da bacia do rio Tamanduateí**. Relatório Técnico , junho de 1997.
- Departamento de Águas e Energia Elétrica **Canalização do Tamanduateí**. Revista Águas e Energia Elétrica, nº 12, pp. 30-41, 1988.
- Gupta, H. V., Hsu, K., Sorooshian, S., **Superior training of artificial neural networks using weight-space partitioning**, (1997): *Proced. IEEE (ICNN'97)*, vol. 3, 1919-1923.
- Haykin, S., 1994: **Neural network a -comprehensive foundation**, Prentice - Hall Internacional, Inc., N.J
- Hsu, K., Gupta, H. V., and Sorooshian, S., (1995): **Artificial neural network modeling of the rainfall-runoff process**, *Water Resour. Res.*, vol. 31, no. 10, pp. 2517-2530.
- Hsu, K.; Gupta, H. V.; Sorooshian, S., **A Superior training strategy for three-layer feedforward artificial neural networks** Technique Report, HWR nº 96-030, Department Hydrologic and Water Resources, University of Arizona, 1996.
- Singh, V.P., (1988): **Hydrologic systems-rainfall-runoff modeling**, vol I, Prentice-Hall, Inc., Englewood Cliffs, N.J.