



**Utilização de Redes Neurais Artificiais em Alertas Hidrológicos:
Estudo de Caso na Bacia do Rio Claro em Caraguatatuba, Estado de São Paulo**
Using an Artificial Neural Network for Hydrological
Warnings on the Claro River in Caraguatatuba, São Paulo State

Mauro Ricardo da Silva¹; Leonardo Bacelar Lima Santos²;
Graziela Balda Scofield² & Fabio Dall Cortivo³

¹Agência Nacional do Petróleo. Avenida. Rio Branco 65, 20090-004, Rio de Janeiro, Brasil

²Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden).

Rodovia Presidente Dutra, km 138, 12630-000 São José dos Campos, São Paulo, Brasil

³Instituto Tecnológico de Aeronáutica (ITA),

Praça Marechal Eduardo Gomes, 50, 12228-900, São José dos Campos, São Paulo, Brasil

E-mails: mrdasilva@anp.gov.br; leonardo.santos@cemaden.gov.br;

graziela.scofield@cemaden.gov.br; fabio.dallcortivo@gmail.com

Recebido em: 13/07/2015 Aprovado em: 07/12/2015

DOI: http://dx.doi.org/10.11137/2016_1_23_31

Resumo

A previsão da vazão dos rios de uma bacia hidrográfica com risco de desastres naturais, como inundações e enxurradas, é um recurso fundamental a programas de monitoramento e alerta. Neste trabalho é apresentada uma abordagem baseada em Redes Neurais Artificiais (RNAs) a fim de prever (neuroprevisão) a vazão do rio Claro em Caraguatatuba-SP. Neste estudo, são utilizados dados reais desta bacia hidrográfica, e efetuados o treinamento, teste e validação da rede utilizada. As entradas da RNA são constituídas por n observações passadas de precipitação e $n-1$ observações de vazão. Já a saída da rede é composta pela n -ésima observação de vazão. A escolha do número de entradas (quantidade de observações passadas) foi feita levando em conta as seguintes métricas: o coeficiente de NASH, calculado sobre a série temporal de resposta da rede; e um conjunto de índices relacionados à emissão de alertas quando a vazão estimada ultrapassa uma vazão crítica. A RNA escolhida, com base nas métricas de desempenho utilizadas, apresentou um bom ajuste à série de vazões observadas (NASH = 0,77) e boa capacidade de emissão de alertas (eficiência de 0,91).

Palavras-chave: redes neurais artificiais; alertas hidrológicos; inundações

Abstract

The river flow prediction of a hydrological basin with natural disaster risk, such as floods and flash floods, is an important feature of early warning programs. This work presents an approach based on the Artificial Neural Networks (ANNs) to predict (neuroforecast) the flow of the Claro River in Caraguatatuba-SP. The observed data of this hydrological basin were used to perform the training, test and validation of the neural networks. The ANN inputs are constituted by n past observed precipitation data and $n-1$ observed flow data. However, the output of the ANN is composed by n -*ith* calculated flow data. The choice of the input number (the quantity of past observed data) was made taking into account the following metrics: the NASH coefficient, which is calculated on the temporal data of the network response; and a set of indexes related to the providing an early warning when the estimated flow exceeds a critical flow. Based on performance metrics, the chosen ANN has a good adjustment to the observed flow data (NASH = 0.77) and good ability for providing an early warnings (efficiency of 0.91).

Keywords: artificial neural network; hydrological alerts; floods

1 Introdução

Analisando os dados sobre desastres naturais no Brasil, no período de 1948 a 2004, disponibilizados pelo *Emergency Disasters Data Base*, Kobiyama *et al.* (2007) afirmaram que os desastres naturais que provocam maiores perdas humanas no Brasil são as inundações/enxurradas e os escorregamentos de terra. Em virtude da urbanização acelerada das planícies de inundação e da ausência de planejamento e ordenamento territorial pelos municípios, as inundações têm ocorrido com maior frequência e magnitude em áreas urbanas, causando perdas materiais e humanas. Além disso, o desenvolvimento dos centros urbanos faz com que se tenha uma diminuição da capacidade de infiltração da água no solo, e com isso, há um aumento do volume de escoamento superficial e, conseqüentemente, do pico da vazão das cheias (Vendrame & Lopes, 2005).

Segundo Silveira *et al.* (2009), até recentemente a melhoria das previsões meteorológicas e a prestação de ajuda humanitária pós-desastre eram as medidas empregadas para salvar vidas nos casos de movimento de massa e inundação. Após o desastre ocorrido na Região Serrana do Rio de Janeiro, foi criado o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden), em 2011, órgão responsável pelo acompanhamento de eventos meteorológicos deflagradores e de componentes de vulnerabilidade relacionados a desastres naturais. O monitoramento contínuo é feito por meio da construção de cenários de risco e, posteriormente, pela emissão de alertas para o Centro Nacional de Gerenciamento de Riscos e Desastres (CENAD), o qual comunica aos municípios sobre risco iminente. Com isso, a previsão de vazões extremas é fundamental para a emissão de alertas, e, quando emitidos com antecedência suficiente, os órgãos competentes em todo Brasil realizam a retirada da população das áreas de risco. No caso de alertas hidrológicos, é analisado o contexto integrado da susceptibilidade e vulnerabilidade das populações e ambientes, a precipitação pluviométrica e a vazão dos rios da bacia hidrográfica à montante de tais áreas de risco (Santos *et al.*, 2013; Soler *et al.*, 2013). O monitoramento contínuo de bacias hidrográficas brasileiras utilizando dados de vazão e precipitação é uma das metas do Cemaden. Dessa forma, modelos hidrológicos estão sendo calibrados

para várias bacias, assim como outras ferramentas estão sendo desenvolvidas e testadas, como o uso de Redes Neurais Artificiais (RNAs).

As RNAs têm sido usadas com sucesso para modelar relações envolvendo séries temporais de entrada-saída complexas em vários campos da ciência (Vemuri *et al.*, 2008). Segundo Santos & Pereira Filho (2003), as principais vantagens das RNAs na modelagem de bacias hidrográficas são a resolução de sistemas mal definidos ou não claramente compreendidos, e o fato de não requererem conhecimento dos processos físicos envolvidos. Embora as RNAs não substituam os modelos conceituais baseados nas leis físicas, elas podem ser uma alternativa razoável na previsão de vazão de rios quando a dinâmica hidrológica da bacia é pouco conhecida.

O objetivo deste estudo é utilizar RNAs para previsão de vazão com base em dados de precipitação e vazão observados, analisando a melhor combinação dos dados de entrada (tipo e quantidade) com base na série temporal estimada e na emissão de alertas nos casos de altas vazões.

2 Materiais e Métodos

2.1 Área de Estudo

A área de estudo é o município de Caraguatatuba, situado no Litoral Norte do estado de São Paulo, como mostra a Figura 1. Nessa região, a presença da Serra do Mar traz complexidade para o escoamento atmosférico e causa fenômenos como precipitações orográficas, movimento de ar ascendente localizado e forçado, bloqueio das frentes frias ou quentes, entre outros.

Neste trabalho, foram utilizados dados de precipitação da estação de Porto Novo, e dados de vazão diária da estação Fazenda Rio Claro, como mostrado na Tabela 1. O período estudado é de 05/06/1985 a 15/03/1989. A região de estudo foi escolhida devido à alta ocorrência de movimentos de massa e inundações na Bacia do Rio Juqueriquerê, onde o rio Claro é um de seus afluentes, principalmente durante o período chuvoso de dezembro a abril.

A bacia do rio Juqueriquerê, localizada nos municípios de São Sebastião e Caraguatatuba,

Postos	Código	Nome do Posto	Latitude	Longitude	Período de Observação
Pluviométrico	E2-128	Porto Novo	23°42'	45°27'	1970 – 1997
Fluviométrico	2E-048	Fazenda Rio Claro	23°41'58"	45°29'05"	1980 – 1990

Tabela 1 Postos pluviométricos e fluviométricos e período de dados utilizados.

no litoral do estado de São Paulo, abrange a sub-bacia do Rio Claro, que é o objeto de estudo deste trabalho. Essa bacia possui uma área de drenagem de aproximadamente de 72 km², enquanto que a bacia do rio Juqueriquerê é de 419 km². Segundo Amaral (2010), esta região possui o relevo definido pelos

contornos escarpados da Serra do Mar, denominada de Serra do Juqueriquerê. De acordo com a classificação proposta por Almeida (1964), a bacia do rio Claro pertence à formação geomorfológica da Serrania Costeira, região do litoral norte que drena diretamente para o mar.

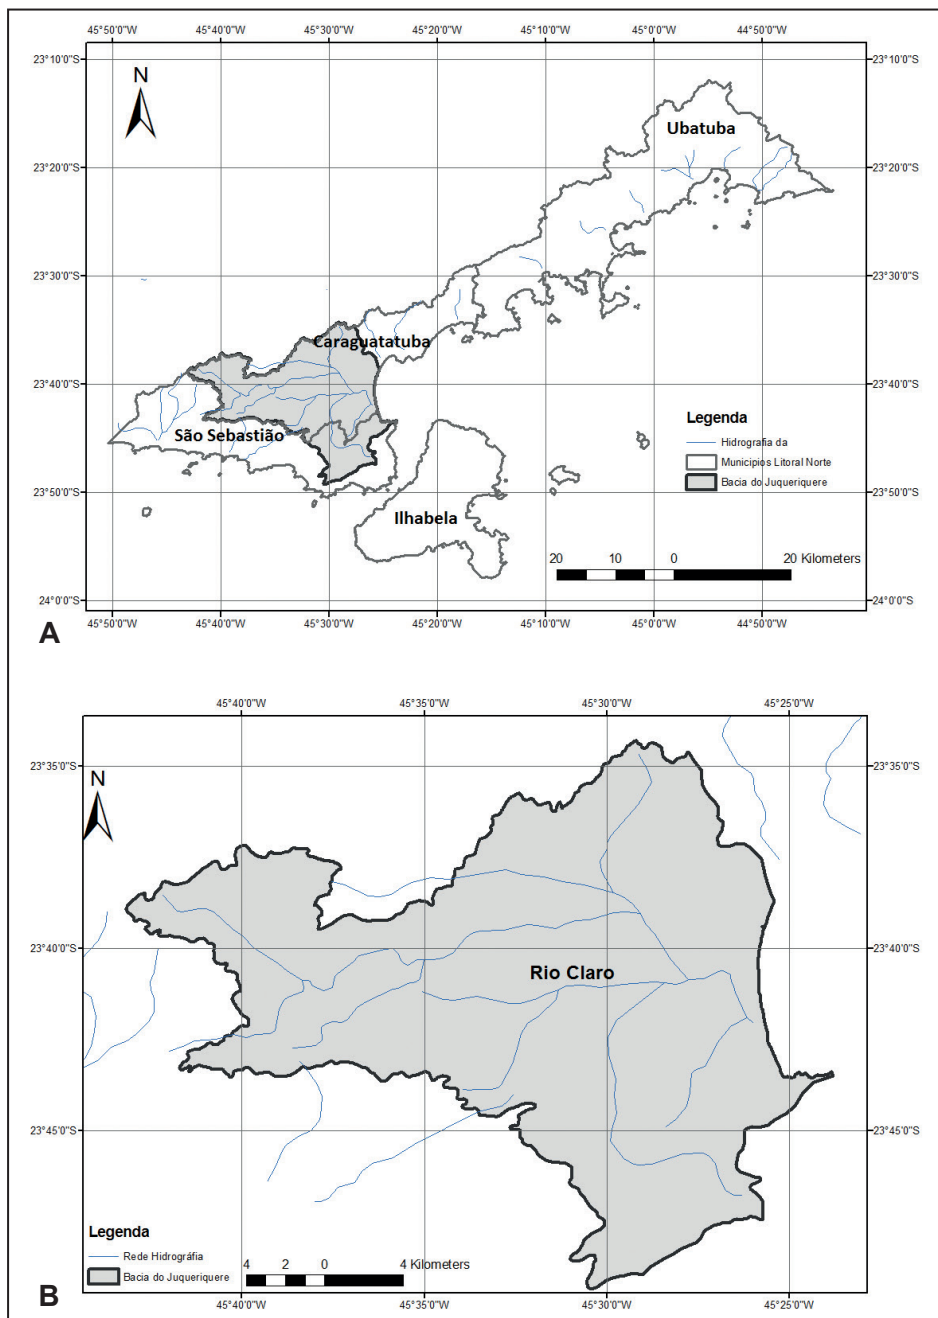


Figura 1 Localização da sub-bacia do Rio Claro no município de Caraguatatuba no Litoral Norte de São Paulo.

A análise dos dados observados de vazão nessa bacia, para o período analisado, mostra que a vazão média foi de 3,78 mm/dia. Ainda é possível observar que os valores de vazão com maior frequência estão localizados em torno de 2,5 mm/dia. O valor crítico da vazão foi definido como a soma da média com dois desvios padrões (2,25 mm/dia). Levando em conta esse valor crítico, houve em torno de 70 episódios (aproximadamente 5% dos dias analisados) com valores superiores a vazão crítica (8,28 mm/dia) para todo o período analisado. O alerta para esses casos é de interesse do Cemaden, CENAD e da Defesa Civil de cada Município, para a realização de uma eventual retirada das pessoas das áreas de risco, de acordo com os demais aspectos do cenário de risco.

2.2 Rede Neural Utilizada

Redes Neurais Artificiais (RNAs) são sistemas computacionais que apresentam a capacidade de aprender a partir do ambiente no qual estão inseridas (Haykin, 1999). Dessa forma, as RNAs podem ser utilizadas a fim de fazer o mapeamento de um conjunto de variáveis de entrada (padrões de entrada), que representam o ambiente, a um conjunto de variáveis de saída (padrões de saída). O conhecimento adquirido durante esse processo de mapeamento (treinamento) fica armazenado e disponível nas conexões sinápticas da rede e é usado em situações futuras. Tais situações são caracterizadas por padrões de entrada, que apresentam alguma semelhança com os padrões iniciais, no entanto não estiveram presentes no ambiente inicial, no qual as redes foram inseridas. Dessa forma, a RNA é capaz de extrair informações desses novos padrões baseando-se no conhecimento adquirido e armazenado na sua memória durante o processo de treinamento (Cortivo *et al.*, 2012).

Uma RNA é constituída por vários neurônios artificiais e o conceito do neurônio artificial foi inspirado no funcionamento do neurônio biológico e introduzido por McCulloch & Pitts (1943). O modelo de neurônio artificial é representado matematicamente por

$$v_j = \sum_{i=1}^n x_i w_{ij} + b_j \quad (1)$$

em que x_i é cada uma das entradas que são aplicadas a esse neurônio, w_{ij} são os pesos sinápticos, e é onde fica armazenado o conhecimento adquirido durante o processo de treinamento, b_j representa um nível de viés, v_j é o potencial de ação e n é o número de conexões de entrada do neurônio. O sinal y_j que é disparado para o neurônio seguinte é definido por

$$y_j = \phi(v_j) \quad (2)$$

em que $\phi(\cdot)$ é chamada de função de ativação. A Figura 2 traz a ilustração de uma RNA do tipo Perceptron de Múltiplas Camadas (PMC). Nessa figura, os pesos sinápticos são representados pelas setas que ligam os neurônios.




Figura 2 Representação gráfica de uma rede neural artificial do tipo perceptron de múltiplas camadas.

Neste trabalho foram utilizadas três arquiteturas de RNAs contendo 5 neurônios na camada oculta e um único neurônio na camada de saída. Nos neurônios da camada oculta foi utilizada a função tangente hiperbólica e no neurônio da camada de saída a função linear. O treinamento das redes foi feito pelo método de Levenberg-Marquardt, e a função de aprendizagem foi baseada no gradiente descendente. O critério de parada para o treinamento se deu pelo número de interações (épocas) ou pelo valor mínimo do erro quadrático médio.

A diferença entre cada uma das redes está no número de neurônios na camada de entrada. A escolha do número de neurônios nesta camada teve como base diferentes composições de medidas, tais como:

- a) apenas dados de precipitação;
- b) apenas dados de vazão;
- c) dados de precipitação e vazão combinados. Nesse caso cada dia será chamado

de par, pois será composto por uma medida de precipitação e uma de vazão.

As amostras foram divididas em três partes a fim de compor os conjuntos de treinamento, teste e validação. O conjunto de treinamento foi composto por 70% das amostras, enquanto que os conjuntos de teste e validação foram compostos pelos 30% restantes, sendo 15% em cada conjunto.

As entradas das RNAs foram compostas pelas medidas de precipitação e vazão observadas pareadas dia a dia. A vazão do n -ésimo par foi considerada a saída da rede, isto é, a RNA visa prever a vazão do último dia. Para cada diferente configuração de dados de entrada, redes foram criadas variando o número de medidas (neurônios na camada de entrada) de 2 a 30 pares de precipitação e vazão.

Em virtude da sensibilidade associada à escolha dos valores iniciais para os pesos, cada uma das configurações (RNAs) foi treinada 50 vezes. Em cada um desses treinamentos foram consideradas diferentes escolhas para os pesos sinápticos. Ao final, foram escolhidos os conjuntos de pesos que geraram os melhores valores para as métricas de desempenho consideradas, e que são descritas na seção seguinte.

2.3 Métricas de Desempenho

Para avaliar o desempenho da previsão feita pela RNA, várias medidas foram empregadas.

a) Acurácia (A) refere-se à proporção de previsões corretas, sem levar em consideração o que é positivo (dar alerta) e negativo (não dar alerta), e é dada por

$$A = \frac{(VP + VN)}{(VP + VN + FP + FN)} \quad (3)$$

em que VP (verdadeiro positivo) significa os valores positivos que o sistema julgou como acertos. VN (verdadeiro negativo) são os valores negativos que o sistema julgou como negativos e são considerados como acerto. FP (falso positivo) significa erro, pois são os valores negativos que o sistema julgou como positivos. FN (falso negativo) são os erros já que são os valores positivos que o sistema julgou negativos.

b) Sensibilidade (S) é a proporção de verdadeiros positivos, relativa à capacidade do sistema prever corretamente a condição, e é dada por

$$S = \frac{VP}{(VP + FN)} \quad (4)$$

c) Especificidade (E) é a proporção de verdadeiros negativos, relativa à capacidade do sistema em prever corretamente a ausência da condição para casos que realmente não a possui, e é dada por

$$E = \frac{VN}{(VN + FP)}; \quad (5)$$

d) Eficiência (EFF) é a média aritmética entre S e E, e é dada por

$$EFF = \frac{(S + E)}{2}; \quad (6)$$

e) Preditividade Negativa (PN) é a proporção de verdadeiros negativos em relação a todas as previsões negativas, e é dada por

$$PN = \frac{VN}{(VN + FN)}; \quad (7)$$

f) Preditividade Positiva (PP) é a proporção de verdadeiros positivos em relação a todas as previsões positivas, e é dada por

$$PP = \frac{VP}{(VP + FP)}; \quad (8)$$

g) Raiz do Erro Quadrático Médio (REQM) mede a amplitude do erro. O valor zero indica uma previsão perfeita e esse valor aumenta conforme aumenta a diferença entre os valores de previsão e observado. O REQM é expresso por

$$REQM = \sqrt{\frac{1}{n} \sum (P - O)^2}; \quad (9)$$

em que O representa a vazão observada e P a vazão estimada.

h) NASH: O coeficiente Nash-Shutcliffe (Nash & Shutcliffe, 1970) é construído pela comparação dos dados observados com os resultados da simulação de vazão, sendo expresso por

$$NASH = 1 - \frac{\sum (O - P)^2}{\sum (O - \bar{P})^2}, \quad (10)$$

com \bar{P} representando a vazão estimada média.

3 Resultados e Discussão

A Figura 3 apresenta os valores máximo e médio (com barra de um desvio padrão) do coeficiente NASH em função do número de dias de

medidas consideradas na camada de entrada para o caso (a) – apenas dados de precipitação. É possível observar que até um intervalo de 4 dias na camada de entrada, o desvio padrão associado à média do NASH é relativamente pequeno e o valor da média e do máximo de NASH são crescentes. Após tal valor ótimo de dados na camada de entrada (4 dias, NASH máximo de 0,38) aparece uma tendência de leve decaimento dos valores médio e máximo e aumento da amplitude do desvio padrão associado ao valor médio.




Figura 3 Caso (a) - considerando apenas dados de precipitação - valores do coeficiente NASH máximo (círculos vermelhos) e médio (quadrados negros) com barra de um desvio padrão (traços cinza) em função do número de dias de medidas na camada de entrada.

A Figura 4 apresenta valores máximos e médios (com barra de um desvio padrão) do coeficiente NASH em função do número de medidas consideradas na camada de entrada para o caso (b) – apenas dados de vazão. Na fase inicial, até 10 dias na camada de entrada, é possível, novamente, observar que o desvio padrão associado à média do NASH é relativamente pequeno e o valor da média e do máximo de NASH são levemente crescentes. Após tal valor ótimo de dados na camada de entrada surge uma tendência de leve decaimento dos valores médio e máximo e aumento da amplitude do desvio padrão associado ao valor médio.

O valor ótimo de dados na camada de entrada no caso b (10 dias) é maior do que no caso a (4 dias). Essa diferença pode estar relacionada aos diferentes comportamentos das próprias grandezas: a precipitação com maior amplitude de variações do que a vazão; dessa forma para captar as variações na




Figura 4 Caso (b) - considerando apenas dados de vazão - valores do coeficiente NASH máximo (círculos vermelhos) e médio (quadrados negros) com barra de um desvio padrão (traços cinza) em função do número de dias de medida na camada de entrada.

precipitação pode ser suficiente um menor número de observações do que o necessário para captar no caso das vazões. Já o valor do NASH máximo para o caso b (0,68) é maior do que o encontrado no caso a (0,38). Isso pode estar associado ao fato de que a variável de entrada e de saída são a mesma grandeza física, a vazão.

A Figura 5 apresenta valores máximo e médio (com barra de um desvio padrão) do coeficiente NASH, em função do número de dias de medidas na camada de entrada, para o caso (c) – dados de precipitação e vazão. É possível observar que até 9 pares de dados de entrada há uma tendência de crescimento do NASH máximo e de manutenção do NASH médio. Após tal valor tanto o valor máximo quanto o médio do NASH decaem lentamente. O cenário com dados de precipitação e vazão se mostrou o mais indicado para a previsão da vazão. Considerando 9 pares de medidas na camada de entrada (9 medidas diárias de precipitação e 8 de vazão – vide a seção 2.2), foi obtido o maior NASH, igual a 0,72, para essa primeira fase de avaliações.

Foi também analisado o comportamento de dispersão referente à vazão estimada em função da vazão observada para o caso (c). Foi obtido um REQM de 1,09 mm/dia. Para a RNA de NASH máximo no caso (a) e no caso (b), os valores encontrados são de 1,50 e 1,28, respectivamente.

Uma vez decidido pelo uso concomitante de precipitação e de vazão, foi preciso selecionar qual




Figura 5 Caso (c) - considerando dados de precipitação e vazão - valores do coeficiente NASH máximo (círculos vermelhos) e médio (quadrados negros) com barra de desvio padrão em função do número de dias de medidas na camada de entrada.

a RNA a ser utilizada, buscando, para diferentes pesos iniciais na etapa do treinamento, uma RNA que atendesse aos seguintes critérios: NASH maior ou igual ao máximo encontrado no teste variando os dados de entrada (0,72), e com no máximo um alerta falso positivo e um falso negativo, ou seja, o interesse é encontrar uma RNA tanto com alto NASH quanto com boas métricas de desempenho no apoio à decisão para emissão de alertas. As métricas de desempenho, calculadas com base nos dados de validação, são sumarizadas na Tabela 2.

Métrica	A	S	E	EFF	PN	PP	REQM (mm/dia)	NASH
Valores	0,99	0,83	1	0,91	1	0,83	1,09	0,77

Tabela 2 Qualidade das estimativas feitas pela RNA escolhida levando em conta as métricas de desempenho.

Foi investigado o valor estimado de vazão para três dias aleatoriamente escolhidos dentro do conjunto de validação, apresentando a vazão acima do valor crítico: dias 6/6/1986, 25/01/1987 e 28/02/1988. Na Tabela 3 estão os valores estimados considerando a RNA escolhida. Nota-se que as vazões observadas e estimadas para os dias 6/6/1986 e 8/02/1988 são aproximadamente iguais, enquanto que ocorreu subestimativa da vazão estimada para o dia 25/01/1987, em torno de 38 %. Com relação à precipitação dos dias analisados, verificou-se 0 mm para os dias 6/6/1986 e 28/02/1988 e de 60 mm para 25/01/1987. Vale salientar que não ocorreu chuva nos dias anteriores ao dia 25/01/1987.

	6/6/1986	25/01/1987	28/02/1988
Vazão observada (mm/dia)	2,60	19,98	6,55
Vazão estimada (mm/dia)	2,58	7,77	6,54

Tabela 3 Resultados das vazões previstas para os dias 6/6/1986, 25/01/1987 e 28/02/1988, considerando a RNA escolhida.

Na Figura 6a, está apresentado o hidrograma do Rio Claro utilizando a RNA escolhida. As Figuras 6b e 6c trazem um destaque para momentos específicos do período de análise: no inverno, quando a vazão dos rios da região costuma ser menor, e no verão, quando as vazões alcançam altos valores devido às intensas precipitações. Em ambos os casos a vazão estimada pela RNA acompanha muito bem a vazão observada.

4 Conclusões e Perspectivas

Neste trabalho foi apresentada uma abordagem baseada em Redes Neurais Artificiais (RNAs) a fim de prever (neuroprevisão) a vazão de um rio. O estudo de caso foi feito considerando o rio Claro, em Caraguatatuba-SP.

Embora o treinamento de uma RNA seja um processo dispendioso, os resultados obtidos mostram que a técnica é promissora para esse tipo de previsão. Além disso, esses sistemas não necessitam de um modelo matemático, que muitas vezes é complexo, para representar o problema.

Os resultados obtidos com a RNA que utiliza simultaneamente dados de entrada de precipitação e de vazão foram os melhores (NASH de 0,77) – o que aponta para a necessidade de promover o monitoramento contínuo de ambas as variáveis. Sob esse aspecto, atualmente o Cemaden trabalha na ampliação da malha nacional de pluviômetros e estações hidrológicas via projetos como Pluviômetros Automáticos e Pluviômetros nas Comunidades, o que colaborará com a obtenção de precipitação e vazão em diversos rios brasileiros.

Dentre as perspectivas do trabalho estão:

- a) o uso de dados com resolução temporal mais fina (por exemplo, horária);




Figura 6 Hidrogramas do Rio Claro, Caraguatatuba, SP para o período de (a) 5 de junho de 1986 a 15 de março de 1989, (b) 10 de janeiro de 1986 a 31 de janeiro de 1987 e (c) 5 de maio de 1987 a 20 de junho de 1987.

b) o uso não apenas de dados observacionais *in situ*, mas também de resultados de radares meteorológicos e de modelos de previsão numérica do tempo;

c) a estimativa não apenas da vazão mas da quantidade de água armazenada no solo, tendo em vista alertas de movimento de massa, segunda classe de desastres que gera maiores perdas humanas no país (Kobiyama et al., 2007).

5 Referências

Amaral, J.F. 2010. *Análise do Transporte de sedimentos na Bacia do Rio Claro. Trabalho de Graduação.* Divisão

de Engenharia Civil-Aeronáutica, São Paulo. Instituto Tecnológico de Aeronáutica. Trabalho de Conclusão de Curso, 95 p.

Almeida, F.F.M. 1964. Os fundamentos geológicos do relevo paulista. *Boletim do Instituto de Geografia e Geologia*, 41: 169-263.

Cortivo, F.D.; Chalhoub, E.S & Campos Velho, H.F. 2012. Estimativa do Perfil da Concentração de Clorofila em Águas Naturais Através de um Perceptron de Múltiplas Camadas. *Tendências em Matemática Aplicada e Computacional*, 13: 233-246.

Haykin, S. 1999. *Neural Networks: A Comprehensive Foundation*, 2ª ed. Canada, Prentice-Hall, 823 p.

Kobiyama, M.; Checchia, T.; Silva, R.V.; Schroder, P.H. & Mota, A.A. 2007. Ensino de hidrologia para prevenção de desastres naturais como projeto de extensão universitária no Estado de Santa Catarina, Brasil. *In: SIMPÓSIO*

- BRASILEIRO DE RECURSOS HÍDRICOS, 17.
- McCulloch, W. S. & Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4): 115-133.
- Nash, J., & Sutcliffe, J.V. 1970. River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology*, 10(3): 282-290.
- Santos, C.C. & Pereira Filho, A.J. 2003. Modelagem Hidrológica Urbana Por Meio de Redes Neurais Artificiais: uma Aplicação para a Bacia Do Rio Tamanduateí Em São Paulo, SP. *Revista Brasileira de Meteorologia*, 18(2): 149-159.
- Santos, L.B.L.; Jorge, A.A.S.; Zolino, M.M. ; Silveira A.C.; Rodrigues J. & Linhares, C.A. 2013. Caracterização de bacias hidrográficas por uma abordagem diretamente baseada em operações via bancos de dados geográficos. *In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS*, 20.
- Silveira W.N.; Kobiyama, M.; Goerl, R.F. & Brandenburg, B. 2009. Curitiba: *História de Inundações em Joinville 1851 - 2008*. Curitiba, Organic Trading, 153p.
- Soler, L.S.; Gregorio, L.T.; Leal, P.; Londe, L.; Soriano, E.; Cardoso, J.; Coutinho, M.; Santos, L.B.L. & Saito, S. 2013. Challenges and perspectives of innovative digital ecosystems designed to monitor and warn natural disasters in Brazil. *In: INTERNATIONAL CONFERENCE ON MANAGEMENT OF EMERGENT DIGITAL ECOSYSTEMS*, 5.
- Vemuri, A.T.; Polycarpou, M.M., & Diakourtis, S.A. 1998. Neural network based fault detection in robotic manipulators. *IEEE Transactions on Robotics and Automation*, 14(2): 342-348.
- Vendrame, I.F. & Lopes, W.A.B. 2005. Análise do crescimento urbano e seus efeitos na mudança da dinâmica do escoamento superficial da Bacia do Pararangaba. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 12.