



XXXVII IBERIAN LATIN AMERICAN CONGRESS
ON COMPUTATIONAL METHODS IN ENGINEERING
BRASÍLIA - DF - BRAZIL

MODELOS RNA COMO FERRAMENTAS DE PREVISÃO DE AFLUÊNCIAS E DE NÍVEIS DE ÁGUA EM AHE

Nelio Moura de Figueiredo ⁽¹⁾

Claudio José Cavalcante Blanco ⁽²⁾

⁽¹⁾ nelio@ufpa.br, ⁽²⁾ blanco@ufpa.br

⁽¹⁾ Professor da Faculdade de Engenharia Naval do Instituto de Tecnologia da Universidade Federal do Pará, ⁽²⁾ Professor da Faculdade de Engenharia Sanitária e Ambiental do Instituto de Tecnologia da Universidade Federal do Pará

Rua Augusto Côrrea 01, Guamá, Belém, PA, CEP 66.075-110

Resumo. Neste trabalho, modelos baseados em arquiteturas RNA foram utilizados na transformação de chuva em afluências a reservatórios de Aproveitamentos Hidroenergéticos – AHE e na simulação de níveis de água a jusante de barramentos hidrelétricos para a verificação de condições de navegabilidade. Um estudo de caso foi desenvolvido para a bacia do rio Tapajós com dados que serviram de suporte a concepção do AHE de São Luiz do Tapajós. Foram empregadas RNA tipo Multi-Layer Perceptron (MLP) com algoritmo Backpropagation (MLP-BP). No modelo chuva-vazão foram treinadas, validadas e testadas 20 RNA, com 5, 8, 10 e 15 neurônios na camada escondida, com vetor de entrada contendo dados de precipitação, de evapotranspiração e de vazões defasadas. Para o modelo de previsão de níveis de água, foram usadas 4 RNA, com 5, 8, 10 e 15 neurônios. Os modelos chuva-vazão aferiram R^2 de 0,97 e RMSE de 0,08 e os de simulação de níveis de água R^2 de 0,98 e RMSE de 0,09. Com base nos desempenhos aferidos em sua distribuição temporal, constata-se que os modelos são ferramentas de fundamental importância na previsão de afluências e na simulação de níveis de água em AHE.

Palavras-chave: Modelo chuva-vazão, previsão de níveis de água, navegabilidade.

1 INTRODUÇÃO

A transformação de chuva em vazão em bacias hidrográficas é um fenômeno hidrológico que apresenta grande complexidade em sua caracterização, em função da grande variação temporal e espacial de elementos constituintes do ciclo hidrológico. Sob a ótica da modelagem hidrológica e da transformação de chuva em vazão, modelos baseados em Redes Neurais Artificiais (RNA) têm sido utilizados com considerável sucesso na geração de afluências a reservatórios de aproveitamentos hidro energéticos (AHE) e na previsão de níveis de água a jusante de barramentos.

Dados de precipitação, com satisfatórios períodos de observação, apresentam-se com maior disponibilidade temporal e espacial, do que dados de vazão. O emprego de modelos chuva-vazão que buscam reproduzir vazões em bacias hidrográficas, através de processos de otimização não-lineares, tornam-se cada vez mais importantes na previsão de afluências e de defluências residuais em AHE.

Na Amazônia a navegação fluvial é um dos mais importantes meios de transporte de passageiros e de carga, interligando cidades e comunidades ribeirinhas a polos de produção e de comercialização, existentes na vasta malha hidroviária regional. Antagonicamente, a dinâmica econômica e a peculiaridade operacional do transporte fluvial na Amazônia, conjuntamente com informações quantitativas e qualitativas dessa atividade, são pouco conhecidas e sistematizadas. Por força de condições regionais, a vasta malha fluvial amazônica é predominantemente utilizada como via de acesso. Nessa ótica, conhecer a fluvariabilidade dos níveis de água e, conseqüentemente, das profundidades de rios amazônicos é condição primária a uma navegação satisfatória e segura.

Sob a ótica relacional da importância de modelos hidrológicos à geração de energia e à manutenção de condições ambientais, Johnston e Smakhtin (2014) destacaram que a modelagem hidrológica se tornou indispensável na pesquisa e na gestão de recursos hídricos em grandes bacias hidrográficas.

Modelos RNA têm sido amplamente utilizadas e com bom desempenho em muitas áreas da hidrologia e de recursos hídricos (Tingsanchali e Gautam, 2000 e Chen *et al.*, 2006). Sob a ótica da modelagem hidrológica, modelos RNA foram usados com sucesso na previsão de vazões e de níveis de água, conjuntamente com outras técnicas (Demirel *et al.*, 2009, Elshorbagy *et al.*, 2010 e Wu and Chau, 2010). Alok *et al.* (2013) usaram modelos RNA para prever vazões no rio Brahmani, Índia. Hidayat *et al.* (2014) utilizando um modelo RNA na previsão de vazões e de alcance de maré no rio Mahakam, Indonésia, aferiu que RNA podem ser usadas como ferramenta no preenchimento de falhas em séries temporais de vazão.

Dounia *et al.* (2014) aplicaram um modelo estocástico de transformação de chuva em escoamento superficial, baseado em RNA, em uma bacia hidrográfica localizada no nordeste da Argélia. Os resultados aferidos às RNA mostraram-se superiores em relação a resultados obtidos com modelos conceituais. Khan *et al.* (2015) utilizaram modelos RNA para prever vazões e níveis de água na bacia de drenagem do rio Ramganga que faz parte da bacia hidrográfica do rio Ganga, Índia. Os resultados aferidos demonstram que modelos de previsão RNA podem ser amplamente utilizados na previsão de vazões e níveis de água.

Elsanabary e Gan (2015) desenvolveram um modelo RNA para previsão de vazão mensal na bacia do alto rio Nile Azul na Etiópia. Os resultados do estudo demonstram que é possível desenvolver uma modelo chuva-vazão, utilizando RNA, algoritmo genético e transformada de

Wavelet, para a previsão de vazão mensal com considerável precisão, sendo esses modelos úteis para uma melhor gestão dos recursos hídricos em bacias hidrográficas.

Na Amazônia Figueiredo e Blanco (2014) implementaram modelos estocásticos do tipo ARIMA na previsão, com antecedência de 24 meses, de vazões e de níveis de água médios mensais na bacia do rio Tapajós, PA. O modelo é uma ferramenta que pode ser usada na análise de regimes hidrológicos de bacias hidrográficas e, conseqüentemente, de possíveis impactos e conflitos decorrentes do uso múltiplo da água.

Neste trabalho modelos chuva-vazão e de previsão de níveis de água, baseados em arquiteturas RNA, são conjuntamente utilizados na previsão de afluências em AHE e na simulação da flutuabilidade de níveis de água a jusante de barramentos. Comparativamente a outros modelos e a processos de análise iterativa entre geração de energia e navegabilidade em rios e AHE amazônicos, este estudo contribui ao desenvolvimento de ferramentas de mensuração de afluências e previsão de profundidades à navegação em AHE de bacias hidrográficas na Amazônia. A aferição e desempenho dos modelos é realizada em um estudo de caso no futuro AHE de São Luiz do Tapajós.

2 ÁREA DE ESTUDO

Os modelos de chuva-vazão e de previsão de níveis de água foram aplicados à bacia do rio Tapajós, a qual está inserida na bacia hidrográfica do rio Amazonas, que se constitui na maior bacia hidrográfica do globo terrestre com uma área total de 6.110.000 km², desde suas nascentes nos Andes Peruanos até sua foz no oceano Atlântico. Essa bacia continental estende-se sobre vários países da América do Sul: Brasil (63%), Peru (17%), Bolívia (11%), Colômbia (5,8%), Equador (2,2%), Venezuela (0,7%) e Guiana (0,2%) (ANA, 2013).

A área de estudo compreende a bacia do rio Tapajós que apresenta área de drenagem de 493.200 km² e localiza-se entre as latitudes 2° e 15° Sul e as longitudes 53° e 61° oeste, abrangendo áreas nos estados do Pará, Mato Grosso e uma pequena porção no Amazonas. Seus rios formadores são o Juruena e o Teles Pires, com áreas de drenagem de 191.100 km² e 139.000 km², respectivamente (Fig. 1).

O rio Tapajós, com extensão de 851 km e sendo formado pelos rios Teles Pires e Juruena, junto à divisa dos estados do Pará, Amazonas e Mato Grosso é um dos mais importantes afluentes da margem direita do rio Amazonas. O clima da região é caracterizado pela Zona de Convergência Intertropical. As maiores temperaturas ocorrem entre os meses de setembro a novembro e apresentam valores médios mensais de 28°C. As temperaturas mais baixas, com valores médios de 26°C, geralmente são observadas no mês de fevereiro. A precipitação anual média na bacia está situada entre 1.800 e 2.300 mm (ANA, 2013).

No trecho do baixo curso do rio Tapajós o comportamento sazonal da evaporação indica a ocorrência de taxas relativamente mais elevadas no período de setembro a novembro e mínimas observadas entre os meses de fevereiro a abril. No alto curso, as taxas mais elevadas de evaporação são registradas normalmente no trimestre de julho a setembro, ou seja, dois meses antes do observado nas porções do baixo curso.

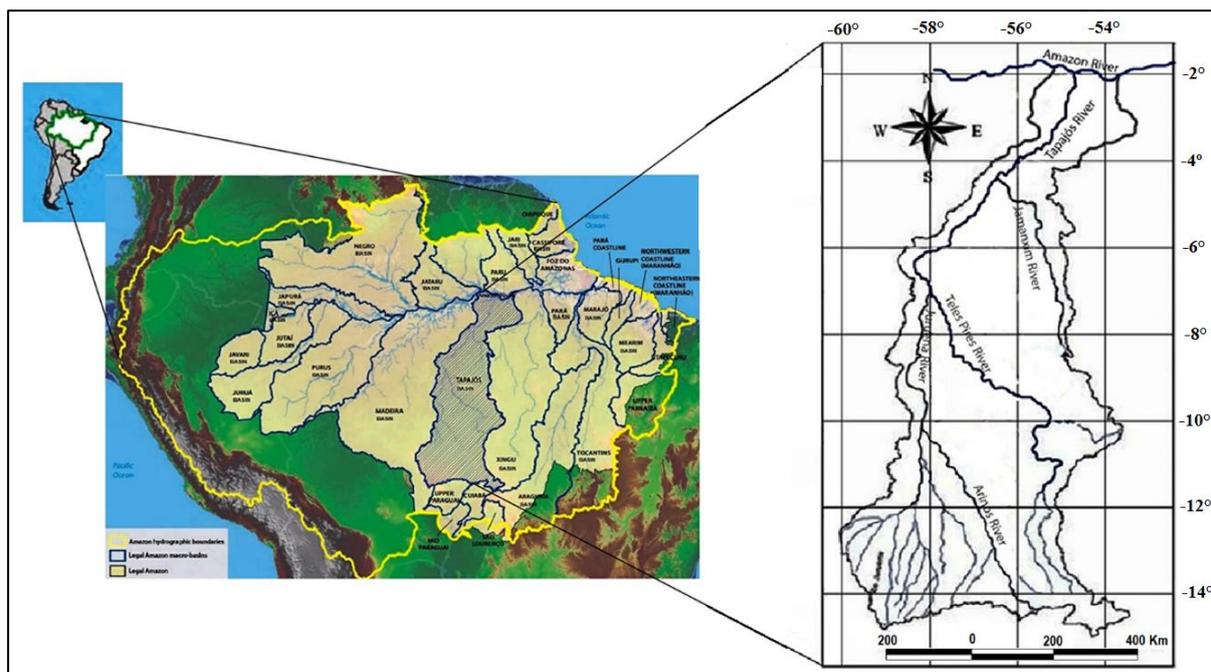


Figura 1: Bacia do rio Tapajós

Fonte: Adaptado de Agência Nacional de Águas – ANA (2002)

3 DADOS UTILIZADOS

A aplicabilidade dos modelos foi verificada com dados hidrológicos que serviram de base a concepção e dimensionamento do futuro AHE de São Luiz do Tapajós. A base de dados utilizada nos modelos foi obtida, da seguinte forma:

- Junto ao Banco de Dados da Agência Nacional de Águas - ANA, constituindo-se de séries históricas de precipitações médias diárias, de níveis de água médios diários e de vazões médias diárias, disponibilizadas através do Sistema de Informações Hidrológicas – Hidro Web no endereço eletrônico <http://hidroweb.ana.gov.br/>; e
- Junto ao Banco de Dados Meteorológicos para Ensino e Pesquisa - BDMEP do Instituto Nacional de Meteorologia (INMET, 2014), constituindo-se de séries históricas de precipitações médias diárias e mensais, que se encontram disponibilizadas no endereço eletrônico <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>.

Os dados de vazão utilizados nos modelos tiveram por base séries mensais em 5 estações fluviométricas e os dados de níveis de água médios mensais foram coletados em 4 estações. O período de análise das séries de vazões e de níveis de água foi de oitenta e um anos (1931 a 2012). Na Tabela 1 constam informações relativas a curso de água, município e coordenadas das estações fluviométricas utilizadas na aquisição dos dados de vazão e na Tabela 2 são mostrados os dados relativos as séries de níveis de água. A Figura 2 mostra a localização das estações fluviométricas utilizadas nos estudos.

Tabela 1: Dados das estações fluviométricas com dados de vazão

Código	Posto	Rio	Município	UF	Coordenadas	
					Latitude	Longitude
17430000	Barra do São Manuel	Tapajós	Borba	AM	-07°20'23"	-58°09'19"
17500000	Fortaleza	Tapajós	Itaituba	PA	-06°02'43"	-57°38'34"
17650002	Acará do Tapajós	Tapajós	Itaituba	PA	-04°53'11"	-56°43'23"
17675000	Jardim do Ouro	Jamanxim	Itaituba	PA	-06°15'27"	-55°46'21"
17710000	Buburé	Tapajós	Itaituba	PA	-04°36'56"	-56°19'30"

Fonte: ANA (2014)

Tabela 2: Dados das estações fluviométricas com dados de níveis de água

Código	Posto	Rio	Município	UF	Coordenadas	
					Latitude	Longitude
17650000	Jatobá	Tapajós	Itaituba	PA	-05°09'09"	-56°51'14"
17650002	Acará do Tapajós	Tapajós	Itaituba	PA	-04°53'11"	-56°43'23"
17710000	Buburé	Tapajós	Itaituba	PA	-04°36'56"	-56°19'30"
17720000	Bela Vista	Tapajós	Itaituba	PA	-04°29'40"	-56°14'07"

Fonte: ANA (2014)

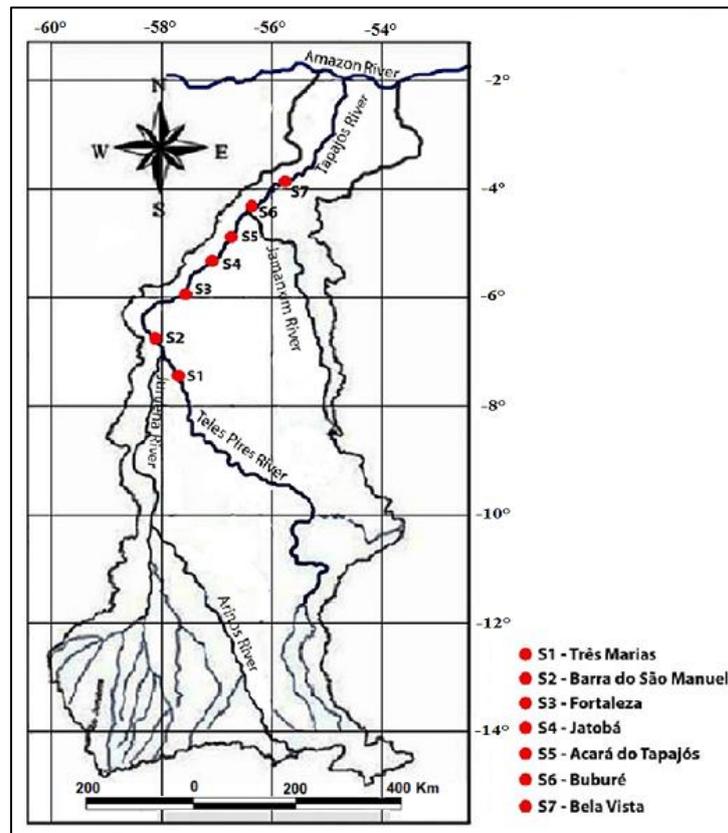


Figura 2: Localização das estações fluviométricas utilizadas nos estudos

Os dados de precipitação utilizados no modelo chuva-vazão, tiveram por base a utilização de séries de precipitações médias mensais, para um período de oitenta e um anos (1931 a 2012), em 3 estações pluviométricas localizadas nas bacias dos rios Tapajós e Jamanxim. Na Tabela 3 são apresentados os principais dados dessas estações.

Tabela 3: Dados das estações pluviométricas utilizadas no estudo

Código	Posto	Município	UF	Coordenadas	
				Latitude	Longitude
01456005	Diamantino	Diamantino	MT	-14°24'21"	-56°26'47"
01260000	Vilhena	Vilhena	RO	-12°44'00"	-60°08'00"
00757000	Alto Tapajós	Itaituba	PA	-07°21'00"	-57°31'00"

Fonte: ANA (2014) e INMET (2014)

O preenchimento de falhas existentes nas séries de dados foi feito com a utilização do método da Ponderação Regional com regressão linear (Eq. 1), conforme descrito por Bertoni e Tucci (2007) e Alves *et al.* (2006). Segundo esses autores e Pruski *et al.* (2004), trata-se de um método que estabelece regressões lineares entre as estações com dados a serem preenchidos Y_m e cada um dos postos vizinhos Y_i .

$$Y_m = \frac{\sum_{i=1}^n Y_i r_{mi}}{\sum_{i=1}^n r_{mi}} \quad (1)$$

Em que, Y_m é a observação da estação base m a ter a falha na série preenchida; n é o número de estações; Y_i é a observação da estação i e r_{mi} é o coeficiente de correlação linear entre os postos m e i .

A consistência dos dados fluviométricos foi feita com a utilização do método de regressão múltipla (Eq. 2).

$$Y_{est} = \beta_1 + \beta_2 Y_m + \beta_3 Y_j \quad (2)$$

Em que, Y_{est} é a observação a ser estimada na estação em análise; Y_m é a observação do posto a montante do posto em análise; Y_j é a observação do posto a jusante do posto em análise e β_1 , β_2 e β_3 são coeficientes de regressão múltipla.

A eficiência da correlação e a confiabilidade da regressão foram verificadas através da confrontação e da análise dos erros entre os valores estimados e os observados.

4 METODOLOGIA

Os modelos RNA permitiram a otimização de afluências e defluências em AHE, em períodos de cheia e de estiagem e de grandes demandas energéticas, com manutenção de condições de navegabilidade em trechos a jusante de barramentos, através de simulações operacionais sustentáveis que minoram conflitos entre usos múltiplos.

A transformação de chuva em vazão e a simulação de níveis de água foi feita através de modelos RNA do tipo *Multi-Layer Perceptron* (MLP) com a utilização do algoritmo *Backpropagation* (MLP-BP). As RNA compuseram-se de três camadas, sendo uma de entrada, uma escondida e uma de saída. Os neurônios da camada intermediária apresentaram funções de transferência do tipo sigmoide e a camada de saída função linear.

Como dentre os algoritmos mais utilizados para executar aprendizados supervisionados, o *Backpropagation* emergiu como o mais largamente usado e mais bem-sucedido algoritmo para treinamento de redes MLP (Haykin, 2005), as aprendizagens das RNA deram-se por retropropagação de erro em dois passos, através de diferentes camadas, sendo:

a) Fluxo da informação da entrada para saída da rede (para frente): nesta fase a ativação dos neurônios escondidos foram propagadas para os neurônios de saída e os erros entre as saídas desejadas e as saídas da rede foram obtidos; e

b) Fluxo da informação da saída em direção dos neurônios escondidos (para trás): nesta fase o erro foi propagado para trás e os pesos, conectando diferentes níveis, são atualizados.

Na Figura 3 é apresentada a arquitetura RNA, tipo MLP, utilizada nos modelos chuva-vazão e de previsão de níveis de água, onde os neurônios da RNA foram dispostos em camadas, a saber:

a) Camada de Entrada, onde os dados de entrada foram recebidos e distribuídos a camadas subsequentes;

b) Camada Escondida, onde os neurônios realizaram o processamento dos dados por meio de regras de propagação e de funções de ativação do tipo sigmoideal; e

c) Camada de Saída, que foi responsável pela resposta da rede e pela geração das variáveis de saída.

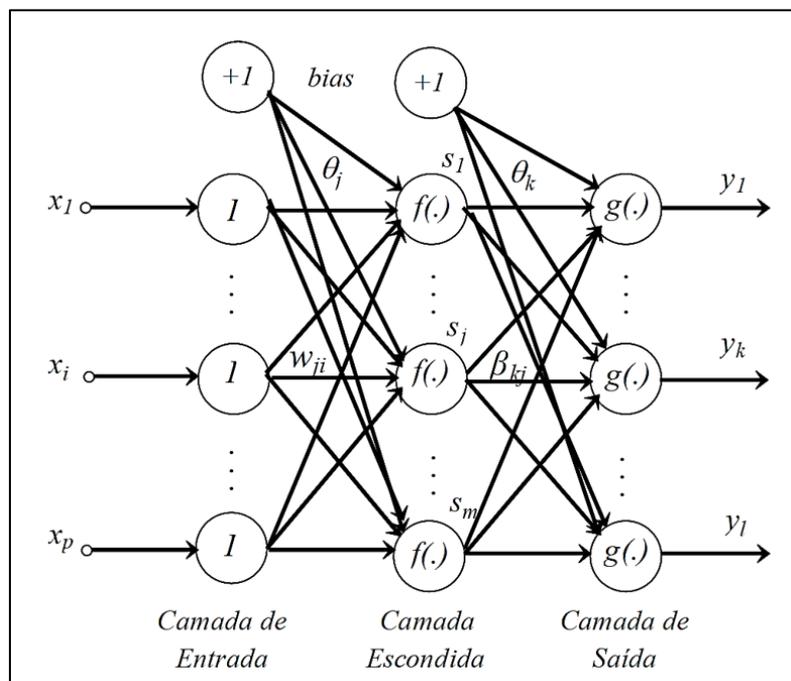


Figura 3: Rede Perceptron Multicamadas – MLP utilizada no modelo chuva-vazão

Fonte: Adaptado de Haykin (2005)

Para a escolha da melhor arquitetura RNA foram criados, em função das características das variáveis do vetor de entrada, cinco diferentes grupos de modelos. Esses grupos de modelos expressaram relações entre dados do vetor de entrada e do vetor de saída. As variáveis adotadas para o vetor de entrada tiveram como critério de escolha a adoção de princípios comumente empregados em modelagens hidrológicas. As vazões foram geradas a partir de dados de precipitação e de evaporação.

Na Figura 4 é mostrada a arquitetura das RNA que compuseram cada um dos grupos de modelos referenciados na Tabela 4. Com base na arquitetura da Figura 4, n_1 é o número de variáveis do vetor de entrada; n_2 é o número de neurônios na camada escondida; n_3 é o número de neurônios na camada de saída e n_4 é o número de variáveis do vetor de saída

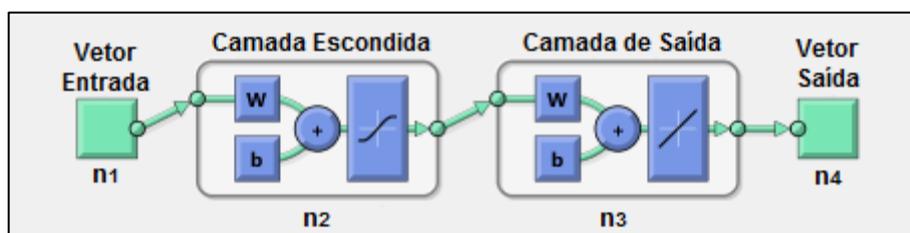


Figura 4: Arquitetura das RNA

Foram treinadas 20 RNA mediante a aplicação do algoritmo de otimização de *Levenberg-Maquardt*, que é uma variação do algoritmo *Backpropagation* e uma boa técnica de aproximação de relações não lineares. Durante o processo de treinamento das RNA, seus pesos e vieses foram ajustados até que o algoritmo de treinamento alcançasse algum critério de parada.

Tendo por base as características das variáveis do vetor de entrada de cada um dos grupos de modelo, na Tabela 4 é apresentada, em função da variação do número de neurônios na camada escondida n_2 , a topologia de cada uma das 20 RNA que foram treinadas e validadas, tendo como critério de parada um *Mean Square Error* (MSE) máximo de 0,004 e um *Regression Coefficient* (R^2) mínimo de 0,92.

Tabela 4:: Características das arquiteturas das RNA dos modelos chuva-vazão

Modelo	n_1	n_2	n_3	n_4
MCV1-5N	3	5	1	1
MCV1-8N	3	8	1	1
MCV1-10N	3	10	1	1
MCV1-15N	3	15	1	1
MCV2-5N	4	5	1	1
MCV2-8N	4	8	1	1
MCV2-10N	4	10	1	1
MCV2-15N	4	15	1	1
MCV3-5N	5	5	1	1
MCV3-8N	5	8	1	1
MCV3-10N	5	10	1	1
MCV3-15N	5	15	1	1
MCV4-5N	5	5	1	1
MCV4-8N	5	8	1	1
MCV4-10N	5	10	1	1
MCV4-15N	5	15	1	1
MCV5-5N	6	5	1	1
MCV5-8N	6	8	1	1
MCV5-10N	6	10	1	1
MCV5-15N	6	15	1	1

No modelo chuva-vazão foram treinadas, validadas e testadas 20 RNA, com 5, 8, 10 e 15 neurônios na camada escondida. A estrutura do vetor de entrada de cada grupo de modelos contou com dados de precipitação de postos pluviométricos ($P_i(t), P_j(t), P_k(t)$); com o somatório das precipitações nesses postos ($P_i(t) + P_j(t) + P_k(t)$); com a evapotranspiração média mensal nos postos i, j e k ($EV_m(t)$); e com vazões defasadas no posto i ($Q_i(t - 1)$). A variável do vetor de saída do modelo foi sempre uma vazão ($Q_s(t)$), que compõe afluências a um dado reservatório.

No modelo chuva-vazão, em função da disponibilidade e da qualidade dos dados pluviométricos, para a composição das variáveis dos vetores de entrada dos modelos MCV1 a MCV5, foram utilizados, para as fases de treino, de validação e de teste das RNA, dados de precipitação do posto pluviométrico Alto Tapajós para a variável $P_i(t)$; do posto Diamantino para a variável $P_j(t)$; e do posto Vilhena para $P_k(t)$. As evaporações líquidas ($EV_m(t)$) utilizadas nos modelos foram obtidas com base no Sistema de Cálculo da Evaporação Líquida – SisEvapo.

Para a previsão de níveis de água a mesma metodologia RNA empregada aos modelos chuva-vazão, foi utilizada na previsão de níveis de água. Foram treinadas, validadas e testadas 4 RNA, com 5, 8, 10 e 15 neurônios na camada escondida. Para esses modelos os vetores de entradas das RNA compuseram-se de séries de níveis de água médios mensais, defasadas ou não, em cada estação fluviométrica.

Sob a ótica de condições de navegabilidade, tendo como dados de entrada séries históricas de níveis de água, o modelo RNA permitiu a previsão de níveis de água a jusante de AHE e, conseqüentemente, da variação de calado e da capacidade de carga de embarcações em trecho de rios localizados a jusante de barramentos. O modelo permitiu, ainda, com base na previsão de níveis de água, a análise de condições de navegabilidade a partir dos níveis de água de referência previamente definidos.

Na calibração e na validação dos modelos RNA, foi utilizada uma função objetivo que teve como coeficientes de desempenho o coeficiente de determinação ou de *Nash e Sutcliffe* (R^2) e a Raiz do Erro Relativo Quadrático Médio (RMSE – *Root Mean Square Error*), expressos pelas Equações 3 e 4, respectivamente.

$$R^2 = 1 - \frac{\sum_{t=1}^n (Q_t - \hat{Q}_t)^2}{\sum_{t=1}^n (Q_t - \bar{Q})^2} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n \left(\frac{Q_t - \hat{Q}_t}{Q_t} \right)^2}{n}} \quad (4)$$

Em que, n é o número de vazões observadas, Q_t é a vazão observação no mês t , \hat{Q}_t é a vazão simulada pelas RNA no mês t e \bar{Q} é a média das n vazões observadas.

A operacionalização da metodologia RNA foi feita com a utilização de algoritmos e funções implementados no software MATLAB® - 2014b, que é uma linguagem de alto nível e um ambiente interativo para computação e programação, desenvolvida pela *MathWorks*.

5 RESULTADOS E DISCUSSÃO

O modelo chuva-vazão desenvolvido, baseado em programação RNA, foi utilizado na previsão de vazões afluentes a reservatórios de AHE, utilizando como entrada dados combinados de chuva, de evapotranspiração e de vazão, obtidos em postos pluviométricos e fluviométricos de interesse, existentes em área de influência direta de AHE.

Apresenta-se para a estação fluviométrica de Buburé a aplicação do modelo chuva-vazão, que consistiu em modelar arquiteturas RNA distintas para que essas fossem avaliadas entre si, de forma a subsidiar a seleção de um modelo que apresentasse previsões com melhores desempenhos. Em cada simulação, o treinamento da RNA foi repetido, com base nos critérios de parada previamente definidos, a fim de otimizar os critérios de desempenhos adotados almejados a cada RNA.

Para cada bloco de modelos da Tabela 4, MCV1 a MCV5, caracterizados pelo tipo e características das variáveis do vetor de entrada, foram treinadas, validadas e testadas 4 RNA, com 5, 8, 10 e 15 neurônios na camada escondida. As RNA do modelo MCV5 apresentaram melhores desempenhos. Dentre as RNA treinadas com 5, 8, 10 e 15 neurônios, a RNA com 10 neurônios em sua camada escondida apresentou melhor desempenho, com R^2 na fase de treino de 0,97842, na fase de validação de 0,96988 e na fase de teste de 0,96144.

Após a verificação do desempenho de cada uma das 20 RNA foi verificado que o modelo com 10 neurônios na camada escondida e vetor de entrada com dados de precipitação; de evapotranspiração e de vazão defasada (MCV5-10N) apresentou melhor desempenho. O desempenho dos modelos na calibração, para os quais foram oferecidos 24 padrões de teste (janeiro de 2010 a dezembro de 2011) em todos os RNA, foi aferido através do coeficiente de Nash e Sutcliffe R^2 (Eq. 3) e da raiz do erro relativo quadrático médio RMSE (Eq. 4). O modelo MCV5-10N, que apresentou melhor desempenho, aferiu R^2 de 0,97309 e RMSE de 0,08136.

Na Figura 5 são mostrados os hidrogramas das vazões observadas e simuladas pelo modelo MCV5-10N, para um período de 24 meses compreendido entre janeiro de 2010 a dezembro de 2011. Observa-se que o modelo apresentou desempenho satisfatório na geração de vazões afluentes a partir de dados de chuva para o período de estiagem. No período de cheia, observam-se pequenas dispersões de amplitude e de fase, por conta de gradientes variacionais de afluências no período de cheia. Tais gradientes são resultantes da não linearidade inerente a modelagem de fenômenos chuva-vazão.

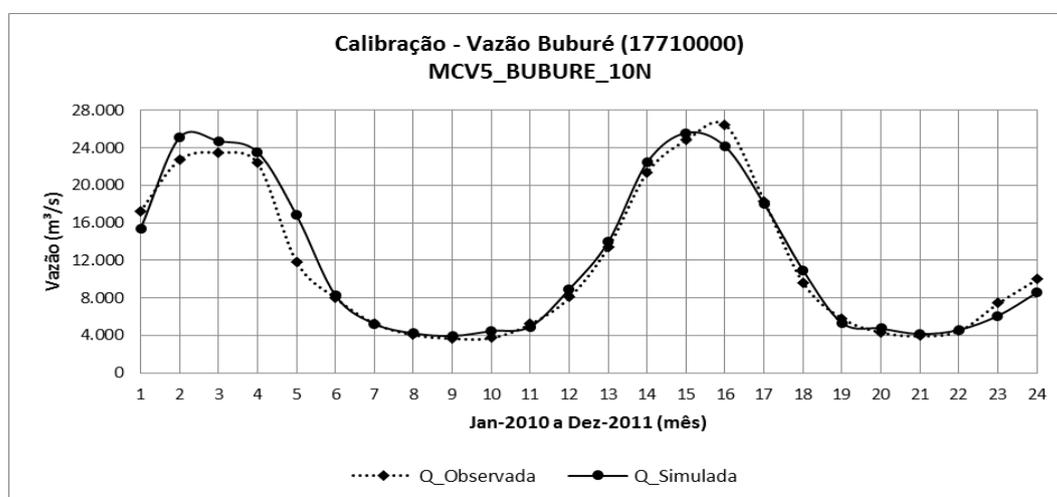


Figura 5: Previsão de vazão em Buburé com o modelo MCV5_BUBURE_10N

Para a previsão de níveis de água a jusante de AHE, um modelo RNA com 15 neurônios na camada escondida (MPNA-15N) apresentou melhor desempenho dentre os demais. Para o posto fluviométrico de Bela Vista, esse modelo apresentou um R^2 de 0,98242 e RMSE de 0,09341. Na Figura 6 são mostrados os hidrogramas dos níveis de água observados e simulados pelo modelo MPNA-15N para a estação Bela Vista. Na Figura 6 observa-se o melhor desempenho das RNA na simulação dos níveis de água. Esse melhor desempenho pode ser explicado pelos menores gradientes observados para os níveis de água e por uma relação causa efeito menos não linear.

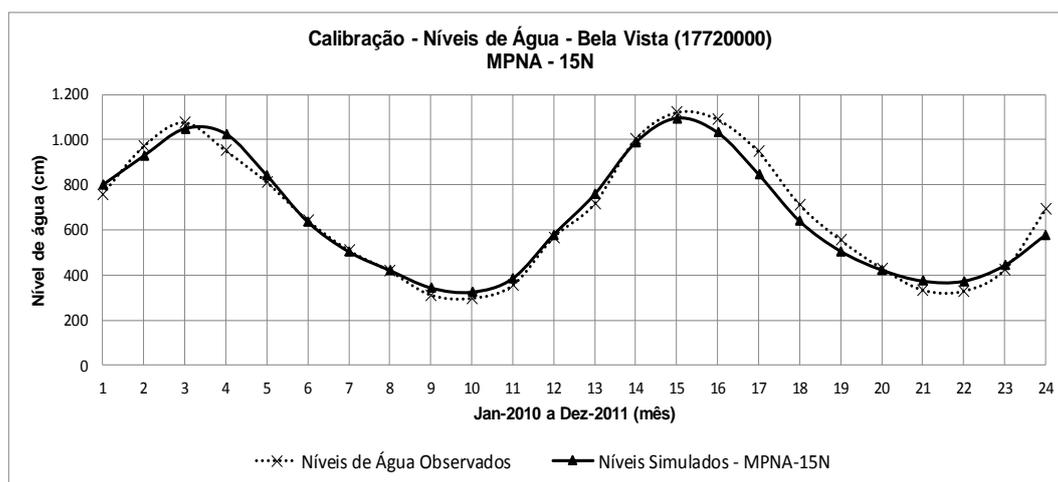


Figura 6: Previsão de nível de água em Bela Vista

6 CONCLUSÕES

As aplicações dos modelos RNA como ferramentas de transformação de chuva em afluências a reservatórios de AHE e de previsão de níveis de água a jusante de barramentos hidrelétricos, evidenciaram que esses modelos apresentaram desempenhos bem satisfatórios. Tendo como universo de análise a aplicação das RNA a todas as estações fluviométricas referenciadas, observou-se que o modelo chuva-vazão para a estação Buburé apresentou melhor desempenho, aferindo R^2 de 0,97 e RMSE de 0,08 e que o modelo de simulação de níveis de água teve melhor performance para a estação Bela Vista, apresentando R^2 de 0,98 e RMSE de 0,09.

Com base nos resultados aferidos e na distribuição temporal do desempenho dos modelos estudados, os quais evidenciaram comportamento próximo dos valores observados, com melhores desempenhos em períodos de estiagem, constata-se que os modelos desenvolvidos são ferramentas de fundamental importância na previsão de afluências a reservatórios e na simulação de vazão e níveis de água em trechos de rios localizados a jusante de barramentos hidrelétricos.

Destarte, a adoção de modelos estocásticos tipo RNA como processo de previsão de vazão e de níveis de água em muito contribuiu na consecução de estudos hidroviários, uma vez que esses modelos, aliados a análises probabilísticas e a levantamentos topobatimétricos que caracterizem o relevo do fundo, são ferramentas que permitem a prospecção de condições de navegabilidade e o dimensionamento de obras de infraestrutura hidroviárias necessárias a tornar uma via navegável.

7 REFERÊNCIAS

- Agência Nacional de Águas – ANA, 2002. A Evolução da Gestão dos Recursos Hídricos no Brasil / The Evolution of Water Resources Management in Brazil. Brasília: ANA.
- Agência Nacional de Águas – ANA, 2014. Conjuntura dos recursos hídricos no Brasil (2013). Agência Nacional de Águas. Brasília: ANA, 2013. 432 p.: II. ISBN 978-85-882100-15-8.
- Agência Nacional de Águas – ANA. Sistema de Informações Hidrológicas – HidroWeb (2014). Disponível em: <http://hidroweb.ana.gov.br/HidroWeb.asp?TocItem=1070&TipoReg=7&MostraCon=false&CriaArq=false&TipoArq=1&SerieHist=false>. Acessado em outubro de 2014.
- Alok, A., Patra K.C., and Das S.K., 2013. Prediction of Discharge with Elman and Cascade Neural Networks. *Research Journal of Recent Sciences*, Vol. 2, 279-284.
- Alves, A.; Kobiyama, M. Silva, R. V. Checchia, T., 2006. Análise de dados hidrológicos na região de município de Alfredo Wagner/SC. In: *Simpósio de Recursos Hídricos do Sul, I, 2006*, Curitiba. Anais, Porto Alegre, Associação Brasileira de Recursos Hídricos;
- Bertoni, J. C., Tucci, C. E. M., 2007. Precipitação. In: Tucci, C. E. M. *Hidrologia: Ciência e Aplicação*. Porto Alegre: UFRGS, 2007. P. 177-241.
- CHEN, W., and CHAU, K. W., 2006. Intelligent manipulation and calibration of parameters for hydrological models. *International Journal of Environment and Pollution*, 28(3-4), 432-447. [doi:10.1504/IJEP.2006.011221].
- Demirel, M.C., Venancio, A., Kahya, E., 2009. Flow forecast by SWAT model and ANN in Pracana basin, Portugal. *Adv. Eng. Softw.* 40, 467–473;
- Dounia, M.; Sabri, D.; Yassine, D., 2014. Rainfall- Rain off Modeling Using Artificial Neural Network, *APCBEE Procedia* 10 251 – 256, ICESD 2014: February 19-21, Singapore.
- Elsanabary, M. and Gan, T., 2015. Weekly Streamflow Forecasting Using a Statistical Disaggregation Model for the Upper Blue Nile Basin, Ethiopia. *Journal of Hydrologic Engineering*, Vol. 20, May, 04014064.
- Elshorbagy, A., Corzo, G., Srinivasulu, S., and Solomatine, D. P., 2010. Experimental investigation of the predictive capabilities of data driven modeling techniques in hydrology – Part 2: Application, *Hydrol. Earth Syst. Sci.*, 14, 1943–1961, doi:10.5194/hess-14-1.
- Figueiredo, N. M., Blanco, C. J. C., 2014. Simulação de Vazões e Níveis de Água | Médios Mensais para o Rio Tapajós Usando Modelos ARIMA; RBRH – *Revista Brasileira de Recursos Hídricos* V. 19 n° 3 – Jul/Set, 111-126.
- Haykin, S., 2005. *Neural Networks: A Comprehensive Foundation*, 9th Ed. Upper Saddle River, NJ, USA: Prentice Hall PTR.
- Hidayat, H., 2014. Prediction of discharge in a tidal river using artificial neural networks. *Journal of Hydrologic Engineering*, 19 (8).

Instituto Nacional de Meteorologia – INMET, 2014. Banco de Dados Meteorológicos para Ensino e Pesquisa – BDMEP (2014). Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acessado em outubro de 2014.

Johnston, R., Smakhtin, V., 2014. Hydrological Modeling of Large River Basins: How Much is Enough, *Water Resources Management*, 2014, 2695-2730, DOI: 10.1007/s11269-014-0637-8.

Khan, M. Y. A., Hasan, F., Panwar, S. And Chakrapani, G. J., 2015. Neural network model for discharge and water level prediction for Ramganga river catchment of Ganga Basin, India, *Hydrological Sciences Journal*, 08/2015; DOI: 10.1080 / 02626667.2015.1083650.

Pruski, F. F.; Pereira, S. B., Novaes, L. F.; Silva, D. D.; Ramos, M. M., 2004. Precipitação média anual e vazão específica média de longa duração, na Bacia do São Francisco. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 8, n. 2/3, p. 247-253.

Tingsanchali, T., Gautam, M. R., 2000. Application of tank, NAM, ARMA and neural network to flood forecasting. *Hydrol. Process.* 14, 2473–2487.

Wu, C.L.; Chau, K.W., 2010. Data-driven models for monthly streamflow time series prediction, *Engineering Applications of Artificial Intelligence*, Volume 23, Issue 8, December 2010, Pages 1350-1367, ISSN 0952-1976, 10.1016 /j. engappai.2010.04.003.