

UMA APLICAÇÃO DE REDES DE ELMAN NO TRATAMENTO E PREDIÇÃO DE SÉRIES TEMPORAIS HIDROLÓGICAS

LEONARDO G. TAMPELINI*, CLODIS BOSCARIOLI*, SILVIO C. SAMPAIO*, SARAJANE M. PERES†

* *Centro de Ciências Exatas e Tecnológicas, Universidade Estadual do Oeste do Paraná
Cascavel, Paraná, Brasil*

† *Escola de Artes, Ciências e Humanidades, Universidade de São Paulo
São Paulo, São Paulo, Brasil*

Emails: tampelini@liv.ic.unicamp.br, boscarioli@unioeste.br, ssampaio@unioeste.br,
sarajane@usp.br

Abstract— Brazil has propitious hydrography the construction of large hydroelectric plants, context whereupon the control systems of sophisticated runoff are required, with forecasting of hydrological data, which deals with physical processes of high complexity and variability. The modeling methods for conceptual hydrological series is a costly process and requires involvement of many specialists. An alternative is to apply Artificial Neural Networks in the capture of existing standards in hydrological time series, reducing the intervention of expert and the cost of building the model. This paper presents the implementation of the Elman network modeling hydrological time series (imputation and prediction) for the construction of Rainfall-Runoff models, and certifies its ability to generate reliable predictions of future values of river flows based only on data of rainfall.

Keywords— Artificial Neural Networks, Elman Network, Time Series Prediction, Data Imputation.

Resumo— O Brasil possui hidrografia propícia à construção de grandes hidrelétricas, contexto no qual sistemas de controle de vazão sofisticados são necessários, com previsão de dados hidrológicos, que lida com processos físicos de alta complexidade e variabilidade. A modelagem de séries hidrológicas por métodos conceituais é um processo custoso e exige muita intervenção de especialistas. Uma alternativa é aplicar Redes Neurais Artificiais na captura dos padrões existentes em séries temporais hidrológicas, diminuindo essa intervenção e o custo de construção do modelo. Este artigo apresenta a aplicação da Rede de Elman na modelagem temporal de séries hidrológicas (imputação e previsão) pela construção de modelos Chuva-Vazão, e atesta sua capacidade de gerar prognósticos confiáveis de valores futuros de vazões fluviais com base apenas em dados de precipitação de chuva.

Keywords— Redes Neurais Artificiais, Rede de Elman, Predição de Séries Temporais, Imputação de Dados.

1 Introdução

A escassez e a alta demanda de recursos naturais vêm exigindo tomadas de decisões racionais e eficientes. Neste contexto, o desenvolvimento de ferramentas computacionais capazes de melhorar os processos de tomada de decisão para dimensionar projetos de infra-estrutura, analisar teorias ou compreender fenômenos físicos pode exigir informações desconhecidas no presente é fundamental. Entretanto, muitas dessas informações somente podem ser adquiridas por meio de inferência matemática a partir de dados históricos.

Um conjunto de informações coletadas sequencialmente em algum domínio (tempo, espaço ou frequência) caracteriza uma série temporal (Morettin and Tolo, 1985). Dada a quantidade de séries temporais encontradas na natureza, como na área de hidrografia, e a constante necessidade de informações futuras, modelar e prever séries é essencial ao desenvolvimento científico.

O começo da moderna predição de séries é atribuído a Yule, o qual propôs em 1926 a técnica de modelagem auto-regressiva (Makridakis, 1994). Seguiram-se a ele pesquisadores que propuseram técnicas de predição de séries temporais que consis-

tiam em procurar, em um universo limitado de modelos, aqueles que melhor representassem os processos geradores das séries (Widrow et al., 1994). Com o estudo das RNAs (Redes Neurais Artificiais) e os avanços computacionais, séries temporais mais longas e complexas puderam ser estudadas, permitindo, pela busca adaptativa, extrair relações em grandes conjuntos de dados e inferir o processo gerador da série (Makridakis, 1994).

Para a efetiva representação temporal, uma RNA necessita representar sinais dinâmicos no tempo. Tais redes, chamadas de Redes Neurais Artificiais Recorrentes (RNA-R), utilizam seu sistema de memória para capturar padrões temporais, como tendências e sazonalidade, e possuem pelo menos um laço de realimentação, que podem ser estruturados de diferentes modos, caracterizando redes localmente (realimentação recursiva em cada neurônio) e globalmente recorrentes (realimentação entre diferentes neurônios) (Haykin, 2000).

Desde os primeiros estudos sobre RNA-R realizados por Rumelhart et al. (1986), várias redes foram desenvolvidas, entre elas a Rede de Elman (Elman, 1990), na qual a representação temporal se dá por meio de unidades internas, denominadas unidades de contexto, que realimentam a camada oculta (rede globalmente recorrente), sendo res-

ponsáveis por apenas memorizar as ativações anteriores das unidades intermediárias. A utilização de realimentação na camada escondida permite que todas as amostras já apresentadas à rede influenciem em sua resposta, enfatizando a influência sobre entradas mais recentes (Braga et al., 2007).

RNAs que possuem capacidade de capturar padrões temporais podem ser vistas com alternativas viáveis a modelagem Chuva-Vazão (Jain and Indurthy, 2003), uma vez que necessitam representar tempo de retardo (tempo entre uma chuva e sua respectiva vazão). Elas têm se destacado nas aplicações relacionadas a recursos hídricos oferecendo diversos atrativos em relação aos demais métodos estatísticos e matemáticos, como a aprendizagem por exemplos, independência do problema, processamento distribuído, paralelo e local e implementação realística.

Destacam-se as aplicações de Dawson and Wilby (1998) na comparação de modelos baseados em RNA e modelos convencionais preditivos de vazão; Ballini (2000) na previsão de séries temporais de vazão por meio de RNAs Nebulosas, coletadas nas hidrelétricas de Furnas, Emborcação (bacia do rio Paraná) e Sobradinho (bacia do rio São Francisco); Machado (2005) na modelagem Chuva-Vazão acumulada mensal da bacia hidrográfica do rio Jangada, localizada na divisa do Paraná com Santa Catarina; e Jain and Kumar (2007) na construção de um modelo híbrido (RNA e modelos estatísticos) para previsão de séries fluviométricas do rio Colorado em Lees Ferry.

O presente trabalho apresenta a concepção de um modelo Chuva-Vazão da bacia do rio Piquiri¹ baseado em séries temporais pluviais e fluviais. Tal modelo foi concebido usando Rede de Elman para o pré-processamento (imputação) e na previsão de médio e longo prazo de vazões fluviais. A fim de melhor apresentar a concepção e testes desse modelo, este artigo segue assim estruturado: A Seção 2 descreve os conceitos envolvidos na modelagem Chuva-Vazão; A Seção 3 é dedicada à apresentação do modelo Chuva-Vazão construído e dos resultados obtidos; Por fim, a Seção 4 traz as conclusões desse estudo.

2 Definição do Problema: Modelos Chuva-Vazão

Modelos Chuva-Vazão descrevem, em função da precipitação de chuva, as perdas (vazão) por evaporação, interceptação, infiltração e percolação da água subterrânea e, calculam o escoamento superfi-

cial e o escoamento de base (Tucci, 1998). Por meio desses modelos é possível prever situações que ainda não ocorreram na natureza, suportando aplicações de gerenciamento de recursos hídricos, como em (Linsley and Franzini, 1978).

A distribuição da vazão em função do tempo numa dada seção de um curso d'água é usualmente chamada de hidrograma e é interpretada como a resposta da bacia ou área de drenagem quando estimulada pelas chuvas que caem sobre essa área (Righetto, 1998). Essa resposta geralmente ocorre com uma defasagem no tempo, referida como tempo de retardo da bacia, ou seja, após a ocorrência de chuva Qa seu correspondente efeito sobre a vazão Qb na seção de controle (seção transversal do rio na qual a vazão é aferida), ocorrerá após certo intervalo de tempo Δt .

A Figura 1 demonstra o tempo de retardo de uma bacia hipotética, que não depende apenas da intensidade e distribuição espacial da precipitação, mas também de características físicas da bacia, como área, conformação topográfica e geográfica, tipos de solo e usos empreendidos em sua superfície (Tucci, 1998).

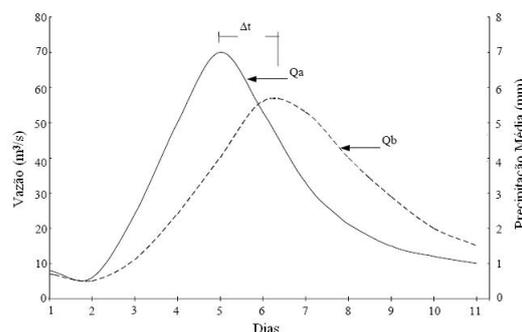


Figura 1: Representação gráfica do tempo de retardo de uma bacia hidrográfica. Fonte: Adaptado Tucci (1998): Qa representa a precipitação média acumulada; Qb representa a vazão resultante. Após a ocorrência de um montante de chuva (ponto máximo de Qa), sua resultante em vazão (ponto máximo da curva Qb), só ocorre após um atraso temporal, neste caso pouco mais de um dia ($\Delta = 1,3$).

3 Experimentos e Resultados

Esta seção se destina a relatar os procedimentos experimentais executados, com destaque à etapa de imputação de dados e aos resultados obtidos.

3.1 Conjunto de Dados

Os dados utilizados na construção do modelo Chuva-Vazão são provenientes de postos plu-

¹ Bacia hidrográfica de grande porte (24.731 Km^2 de área de drenagem.) localizada na região oeste do Estado do Paraná/Brasil.

viométricos e fluviométricos da bacia do rio Piquiri, monitorados pela SUDERHSA (2008). Trata-se de 102 séries históricas de precipitação de chuva (1956 a 2008) e uma série de vazão (1971 a 2003), todas com uma frequência diária. Dada a disponibilidade de uma única série de vazão, esta foi considerada como referência de corte às demais séries hidrológicas², restringindo-as em 22 séries.

Para o treinamento supervisionado das redes, as 22 séries de precipitação foram utilizadas como entrada e a série de vazão como valor esperado (saída). Porém, a série de vazão disponibilizada possui 3 períodos de dados ausentes: 04/01/1982 a 31/01/1982; 01/05/2002 a 31/05/2002; e 1/12/2002 a 31/12/2002. Considerado apenas o período sem falhas, a série se restringe a um período de 18 anos (1983 a 2001). Para aumentar a extensão dessa série³, as falhas encontradas foram imputadas por um modelo hidrológico neural distribuído⁴, tal que os dados de precipitação e vazão foram utilizados para treinar uma Rede de Elman e estimar dados de vazão.

3.2 Experimentos

O conjunto de dados (de séries) utilizados no experimento foram divididos em três sub-conjuntos sequenciais: a) *de Validação*, os primeiros 15% dos dados de cada série; b) *de Treinamento*, os próximos 70% dos dados de cada série; c) *de Teste*, os 15% restantes de cada série.

Devido à existência de vários picos na série de vazão, e para evitar que futuros valores de vazões extrapolem um limiar imposto por uma normalização, a série de vazão não foi normalizada. Por esse motivo, uma função do tipo linear positiva foi adotada como função de ativação dos neurônios de saída, representando os dados entre $[0, +\infty]$. O processo de normalização escolhido para os dados de entrada foi a transformação linear, reescalando-os para uma amplitude variando em $[-1, 1]$. Desse modo, para melhor representação interna nas RNAs, optou-se em utilizar na camada de entrada e nas camadas ocultas uma função de ativação tangente hiperbólica.

Para o treinamento das redes (imputação e predição), diferentes conjuntos de parâmetros foram testados, e os melhores resultados foram

²É importante notar que para a modelagem Chuva-Vazão com suporte de RNA (treinamento supervisionado) é necessário que todas as séries temporais utilizadas contenham o mesmo período de coleta de dados.

³Righetto (1998) recomenda utilizar períodos iguais ou maiores que 20 anos para capturar o comportamento de uma série hidrológica.

⁴Modelos distribuídos são aqueles em que os parâmetros de alimentação variam também segundo o espaço geográfico (Morettin and Toloi, 1985).

obtidos a partir de: **Inicialização de pesos aleatória** para minimizar o problema de mínimos locais causados pela inicialização, cada rede foi inicializada e treinada três vezes; **Ajuste dinâmico de Momentum**, com taxa de 0.1 no intervalo de $[0.001, 1e10]$; **Taxa de aprendizagem**, definida de acordo com o algoritmo de aprendizado *Levenberg-Marquardt* (Ardrib, 2003); **Avaliação do desempenho**, segundo aferição do Erro Médio Quadrático; **Critério de parada do treinamento** em 600 épocas ou crescimento progressivo do erro do conjunto de validação (validação cruzada) por 10 épocas consecutivas (evitar a perda da generalização) ou ainda, alcance de uma taxa de erro igual a zero; **Número de neurônios**⁵ na camada oculta igual a 35.

3.3 Resultados de Pré-Processamento

Após o ajuste dos parâmetros e a execução do treinamento, as Redes de Elman apresentaram resultados coerentes com o comportamento hidrológico da bacia. A imputação dos dados ausentes produziram resultados próximos ao comportamento do hidrograma, não sub-dimensionado seus valores de pico⁶, e reproduzindo o tempo de retardo da bacia.

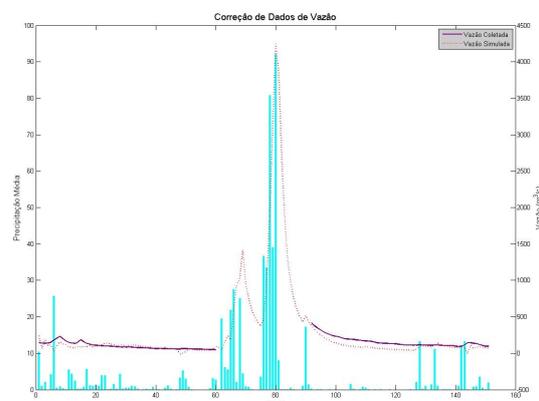


Figura 2: Interpolação para as falhas do mês de maio de 2002. Eixos: Precipitação Média X Dias X Vazão (m^3/s).

Apesar da localização das falhas ser em pequenos períodos, as do mês de maio de 2002 são um ponto crítico, caracterizado pela alta incidência chuva. Na Figura 2, as barras verticais representam a precipitação acumulada na área de estudo, a linha contínua representa a descontinuidade da coleta da vazão e a linha pontilhada demonstra a interpolação produzida pelas Redes de Elman após

⁵ Redes com mais camadas e com mais neurônios não foram consideradas devido à complexidade computacional do processo de treinamento.

⁶ Dados de vazões fluviais são utilizados no dimensionamento de obras hidráulicas, sendo essencial que as vazões de pico não sejam sub-dimensionados (Barbosa, 2006).

treinamento. Analisando essa figura percebe-se a resposta devidamente atrasada da vazão após um período de chuva.

Considerando os pequenos períodos com falhas e diante dos bons resultados produzidos pela Rede de Elman, estes foram tidos como adequados para suportar a interpolação dos dados ausentes, resultando na ampliação do período da série temporal de 18 para 32 anos.

3.4 Resultados de Predição

Para a tarefa de predição, Redes de Elman foram treinadas com as séries pré-processadas. O tempo de treinamento das redes foram aproximadamente de 180 horas⁷. Este tempo é devido a longa duração de cada época de treinamento, onde é necessário apresentar à rede 22 séries temporais, cada uma com um período de 27 anos de dados diários, dos quais 5 anos pertencem ao conjunto de validação e 22 anos ao conjunto de treinamento.

Concluída esta etapa, o conjunto de teste foi apresentado às redes e suas respostas (predições) foram obtidas. Essas respostas demonstram a capacidade das redes utilizadas em prever valores com um horizonte máximo de 5 anos, horizonte pré-determinado pelo tamanho do conjunto de testes. Um resumo do desempenho das redes é apresentado na Tabela 1, onde os melhores resultados estão destacados em negrito.

Avaliando apenas o EMQ não é possível visualizar os bons resultados obtidos pelas RNAs, um dos motivos é grande variação da vazão. Nos meses de maio e outubro as vazões observadas chegam a 9.6 vezes a vazão média (máxima de $4759m^3/s$), contribuindo no aumento do EQM. Porém, ao analisar a representação gráfica da previsão e dos valores esperados é possível observar a captura do comportamento da série pela RNA.

Tabela 1: Desempenho das Redes de *Elman*.

Rede de Elman - Erro Médio Quadrático			Arquitetura
Desempenho			
Erro Validação	Erro Treinamento	Erro Teste	Nº Escondida
1.8360e05	1.7981e05	1.809e05	20
8.4216e04	9.1523e04	8.5534e04	25
6.9810e03	7.4739e03	6.2198e03	30
1.3327e03	1.3204e03	1.2313e03	35

A Rede de Elman de melhor resultado teve as melhores representações nos fluxos máximos de vazões, contudo, a maior frequência de erros ocorreu nas vazões médias. A ocorrência desses erros pode ter sido causada pelo alto número de combinações possíveis das entradas que culminam em

⁷ Os testes foram executados utilizando o sistema operacional Windows XP, um processador Pentium IV 3000MHz e 1024MB de memória RAM.

um valor médio, dificultando o processo de generalização temporal da rede. Os resultados mostram a diferença acumulada de 0,0162% dos volumes observados em relação aos previstos.

Considerando a não linearidade da série de vazão estudada e analisando a Figura 3, observa-se a proximidade dos dados previstos (linha pontilhada) com os dados coletados (linha contínua), principalmente com relação a períodos extremos de vazão, qualificando o modelo para uso em simulações de grandes períodos de vazões.

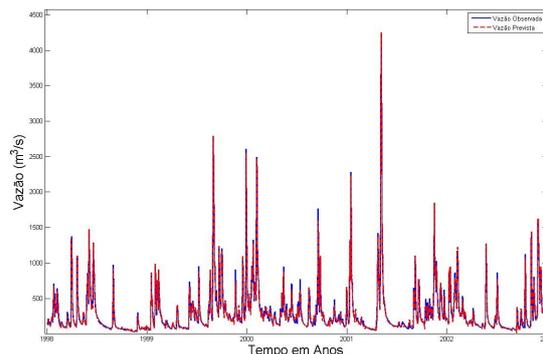


Figura 3: Melhor resultado das Redes de Elman para a predição de 5 anos de vazões (1998 a 2003).

Existe uma aparente sobreposição da vazão observada (linha contínua) e da prevista (linha pontilhada)(Figura 3), mas ao ampliar a imagem é possível observar erros nas predições de menor vazão (Figura 4). Do ponto de vista do especialista, estas divergências estão dentro da normalidade pois, no modelo construído, que abrange uma grande área de drenagem, muitas séries pluviométricas são necessárias para representar o comportamento da bacia, as quais podem possuir inconsistências causadas por erros na coleta, mudanças nas condições de observação ou devido a algum agente físico real. E, considerando o fluxo médio anual da bacia ($524 m^3/s$), o erro médio foi pequeno, tendo uma variação de $24,141 m^3/s$.

Apesar da utilização de 24 séries pluviométricas, essas podem não ter sido suficientes para a captura das respostas mais sensíveis da bacia hidrográfica. Desse modo, aumentar o número de séries, de preferência de postos de coletas próximos ao fluxo de vazão principal (rio Piquiri), pode ser uma alternativa para melhorar os resultados, mas exige maiores recursos computacionais.

4 Conclusões

Os resultados obtidos pelas Redes de Elman foram promissores, promovendo prognósticos confiáveis para períodos longos (5 anos), evidenciando alta capacidade de generalização temporal, colocando-

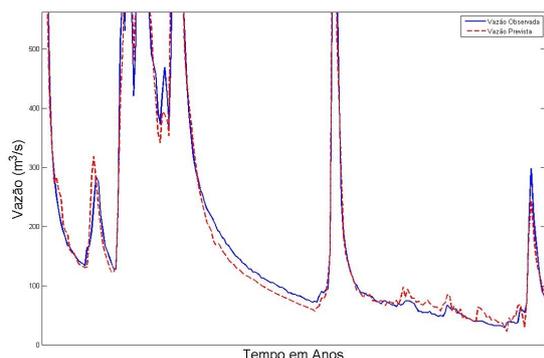


Figura 4: Ampliação dos resultados obtidos pela Rede de Elman na predição do período: junho de 1998 a agosto de 1998.

as como uma ferramenta útil e eficiente à resolução de problemas de pesquisas e de gestão dos recursos hídricos da bacia do rio Piquiri.

Embora o tempo gasto nos ajustes e treinamento da RNA seja considerado computacionalmente alto, é pequeno se comparado à construção de modelos hidrológicos conceituais, que podem levar anos para serem construídos e calibrados. Ademais, após a preparação dos dados, o treinamento se dá de forma automática, diminuindo o esforço e a influência do especialista na construção desses modelos. Reduzir a subjetividade imposta por um especialista aumenta a confiança dos resultados apresentados, validando a modelagem.

Alguns dos parâmetros requeridos na modelagem conceitual estão relacionados a características físicas da bacia hidrográfica, exigindo coletas de dados em campo. Modelos baseados em RNAs capturam as relações físicas da bacia hidrográfica implicitamente inseridas nos dados, reduzindo o número de parâmetros necessários à modelagem, reduzindo tempo e custos.

Referências

- Ardrib, M. A. (2003). *The Handbook of Brain Theory and Neural Networks*, 2 edn, A Bradford Book, Cambridge, MA, USA, pp. 81–1239.
- Ballini, R. (2000). *Análise e Previsões de Vasões Utilizando Modelos de Séries Temporais, Redes Neurais e Redes Neurais Nebulosas*, Tese, Universidade Estadual de Campinas, Campinas, SP.
- Barbosa, F. A. R. (2006). *Medidas de proteção e controle de inundações urbanas na bacia do rio mamanguape/pb*, Dissertação, UFPB – Universidade Federal da Paraíba, João Pessoa - PB.
- Braga, A. P., Carvalho, A. P. L. and Lubermir, T. B. (2007). *Redes Neurais Artificiais: teoria e aplicações*, 2 edn, LTC, Rio de Janeiro.
- Dawson, C. W. and Wilby, R. (1998). An artificial neural network approach to rainfall runoff modeling, *Journal Hydrological Sciences* **43**(1): 47–65.
- Elman, J. L. (1990). Finding structure in time, *Cognitive Science* **14**(2): 179–211.
- Haykin, S. (2000). *Redes Neurais: Princípios e Prática*, 2 edn, BOOKMAN, São Paulo - SP.
- Jain, A. and Indurthy, S. K. V. P. (2003). Comparative analysis of event based rainfall runoff modeling techniques deterministic, statistical, and artificial neural networks, *Journal Hydrology* **8**: 93–98.
- Jain, A. and Kumar, A. M. (2007). Hybrid neural network models for hydrologic time series horecasting, *Applied Soft Computing* **7**(2): 585–592.
- Linsley, R. and Franzini, J. (1978). *Engenharia de Recursos Hídricos*, 3 edn, USP/McGraw Hill do Brasil, Recife, PE.
- Machado, F. W. (2005). *Modelagem chuva-vazão mensal utilizando redes neurais artificiais*, Dissertação, UFPR - Universidade Federal de Campina Grande, Curitiba - PR.
- Makridakis, S. (1994). Time series prediction: Forecasting the future and understanding the past, in A. S. Weigend and N. A. Gershenfeld (eds), *International Journal of Forecasting*, Vol. 10, Addison-Wesley Publishing Company, MA, USA, pp. 463–466.
- Morettin, P. A. and Tolo, C. M. C. (1985). *Previsão de Séries Temporais*, 2 edn, Atual Editora, São Paulo - SP.
- Righetto, A. M. (1998). *Hidrologia e Recursos Hídricos*, 1 edn, EESC-USP, São Carlos, SP.
- Rumelhart, D. E., Hilton, D. E. and Williams, R. J. (1986). *Learning Internal Representations by Error Propagation*, Vol. 1, bradford books edn, MIT Press, Cambridge - MA.
- SUDERHSA (2008). Superintendência de desenvolvimento de recursos hídricos e saneamento ambiental, <http://www.suderhsa.pr.gov.br>>. Último acesso: 08 de novembro de 2008.
- Tucci, C. E. M. (1998). *Modelos hidrológicos*, 1 edn, UFRGS & ABRH, Porto Alegre - RS.
- Widrow, B., Rumelhart, D. E. and Lehr, M. A. (1994). Neural network applications in industry, business and science, *Communications of the ACM* **37**(3): 93–105.