

UMA METODOLOGIA PARA CORREÇÃO DO ERRO DE DEFASAGEM DURANTE O PROCESSO DE PREVISÃO COM REDES NEURAIIS

Méuser Valença¹; Teresa Lusermir²

RESUMO --- Vários estudos têm observado que de forma similar aos modelos estatísticos auto-regressivos os modelos baseados em rede neural, também muitas vezes produzem erros de fase durante o processo de previsão, ou seja, os picos são previstos atrasados com relação ao tempo. Este trabalho investiga uma potencial solução para a correção do erro de defasagem através da aplicação de um procedimento de *feedback* dinâmico aplicado a uma rede neural modular. Este metodologia proposta foi aplicada a um caso de previsão de vazões médias diárias com um horizonte de previsão correspondente a sete dias à frente para a usina hidroelétrica de Tucuruí. A aplicação deste procedimento de correção produziu redução significativa nos erros de defasagem sem causar qualquer prejuízo nas outras métricas utilizadas para avaliação do desempenho.

ABSTRACT --- Several studies have observed that neural network models will often produce phase-shift errors or timing lags in their output results. This paper investigates a potential solution to the timing error problem through the application of a dynamic-feedback neural networks for runoff-runoff modeling. This procedure was applied to hydrological forecasting models for the River Tocantins, in northe Brazil. The application of this correction procedure produced timing improvements of up to about seven days ahead.

Palavras-chave: erro de defasagem, previsão de vazões, redes.

1) Professor da Universidade de Pernambuco (UPE) – Departamento de Sistemas e Computação. Recife/PE. E-mail: meuserv@yahoo.com.br.

2) Professora da Universidade Federal de Pernambuco (UFPE), Centro de Informática. Recife/PE. E-mail: tbl@cin.ufpe.br.

1 - INTRODUÇÃO

Na última década houve uma verdadeira explosão na utilização da técnica de redes neurais artificiais nas mais diferentes áreas. No que diz respeito à área de recursos hídricos um grande enfoque de aplicação tem sido na previsão de séries temporais hidrológicas em especial na previsão de vazões, Valença e Ludermir (1999); Dawson e Wilby (2001); Campolo et al.(2003); Valença e Ludermir (2004); De Vos e Rientjes (2005); Valença (2005); Abrahart *et al.* (2007); De Vos e Rientjes (2007).

Esta busca pela utilização das redes neurais artificiais deve-se ao fato destas se apresentarem como uma poderosa ferramenta para realização de mapeamentos não lineares entre um conjunto de entradas e de saídas tal qual acontece no processo hidrológico da transformação da chuva x vazão. De tal forma que a maioria dos estudos têm se concentrado em realizar uma análise comparativa entre os resultados obtidos com redes neurais artificiais e técnicas estatísticas tradicionalmente utilizadas, ou entre diferentes tipos de redes neurais (Redes Perceptron Multicamadas, Redes RBF, Redes Construtivas, Redes Recorrentes, etc), ou ainda entre redes Neurais Artificiais e alguns modelos conceituais de transformação de chuva x vazão. Entretanto um ponto que tem sido pouco explorado é o relacionado com o erro de defasagem do pico do hidrograma previsto. De uma forma geral os modelos de redes neurais fornecem uma boa aproximação do hidrograma, mas as previsões geralmente se apresentam com um erro de defasagem temporal. Este erro de defasagem tem como fator causador principal a utilização de valores passados da vazão como entrada para a rede neural (ou para modelos estatísticos tradicionais, isto é, os modelos autoregressivos). Estes valores passados de vazão tendem a dominar as entradas de tal forma que os valores previstos sofrem forte influência dos valores mais recentes a tal ponto destas serem responsáveis pelas previsões defasadas. Este fato tem sido relatado e abordado em alguns poucos trabalhos publicados sobre previsão de vazões tais como: de Vos & Rientjes, 2005, 2007, Abrahart et. al. 2007. Este problema é ilustrado na figura 1, onde as vazões previstas estão deslocadas para a direita, ou seja, o modelo em geral só é capaz de prever o pico depois que ele ocorre (o que chamamos popularmente de efeito sombra). Abrahart et. al. (2007) propuseram a utilização de uma ferramenta chamada de Neuro-Evolution software package Java SANE v1.2 (Matuszek, 1998). Esta ferramenta consiste na utilização de uma rede neural evolucionária, ou seja, a construção da camada escondida é feita pela utilização da técnica de algoritmos genéticos de tal forma que através da utilização de uma função de penalidade as redes neurais que apresentam valores de pico defasados têm sua função objetivo multiplicada por um fator de penalidade 500. Desta forma o algoritmo tende a gerar redes neurais com as menores defasagens possíveis durante o treinamento. Entretanto os resultados obtidos com o

uso desta metodologia proposta não apresentaram resultados globais satisfatórios, uma vez que, quando alguma melhoria de defasagem era verificada se observava que as demais métricas sofriam uma grande deterioração.




Figura 1 – Vazão ocorrida versus a prevista mostrando o erro de defasagem

Quanto ao trabalho de De Vos & Rientjes (2007), estes propuseram a utilização de uma rede neural com otimização multiobjetivo, ou seja, o treinamento da rede neural foi realizado com uma função objetivo que agrega duas ou mais funções objetivo individuais, bem como utilizou também um fator de penalidade para o erro de defasagem. De uma maneira geral o resultado de previsão obtido foi considerado bom, quando se analisa as métricas globais, mas o problema de defasagem não foi possível de ser solucionado através da metodologia proposta.

Este trabalho apresenta uma proposta de correção do erro de defasagem quando da utilização de redes neurais para a previsão de vazões. O processo foi implementado tendo como base o conceito de redes neurais modulares recorrentes. O objetivo da metodologia aqui proposta é de reduzir o erro de defasagem sem que ocorra deterioração significativa nas demais métricas utilizadas para avaliação do desempenho.

O nosso experimento de previsão de vazões médias diárias foi realizado para a usina hidroelétrica de Tucuruí, localizada no Norte do Brasil.

2 – METODOLOGIA

A metodologia proposta neste artigo consiste na utilização de uma rede neural com estrutura modular com entradas recorrentes para correção do erro.

2.1 – Arquitetura proposta

A arquitetura proposta é composta por uma rede neural principal que recebe valores passados de vazão e ou chuva como entradas e fornece como saídas às previsões. Neste artigo a rede neural principal é uma rede neural construtiva chamada NSRBN, Valença (2005). Esta rede neural construtiva pode ser entendida como uma rede similar a uma rede tradicional MLP (Rede Perceptron Multicamadas) que apresenta como característica principal uma única camada escondida cuja quantidade de neurônios é estabelecida automaticamente. Uma rede tradicional MLP (Perceptron Multicamadas) também poderia ser utilizada, bem como outras estruturas de redes neurais. As saídas desta rede neural (vazões previstas) serviram como entrada para os demais módulos que ficaram responsáveis pela ação de correção. Os módulos de correção têm como entradas valores defasados das séries temporais geradas durante o treinamento em função das previsões realizadas. Esta arquitetura proposta pode ser vista de forma simplificada na figura 2.




Figura 2 – Exemplo de arquitetura recorrente para a rede neural proposta

A rede neural principal (utilizada para previsão de vazão) utiliza para todos os neurônios escondidos e de saída uma função de ativação sigmoidal logística (função limitada entre 0 e 1), onde todos os valores de entrada foram normalizados entre 0,30 e 0,70 (normalizar neste trecho mais linear minimiza distorções quando da reconstituição dos valores reais, bem como pode acomodar valores pouco superiores aos utilizados para treinamento).

2.1 – Algoritmo para treinamento da rede neural modular recorrente

Nesse artigo o treinamento da rede neural foi realizado pela utilização do algoritmo de enxame de partículas. A escolha desta técnica de otimização deveu-se ao fato das dificuldades encontradas para treinamento da arquitetura proposta com a utilização do algoritmo *backpropagation* tradicionalmente utilizado. Este algoritmo forneceu resultados rápidos bem como apresentou redes treinadas com excelente desempenho.

O algoritmo de otimização por enxame de partículas (*Particle Swarm Optimization* - PSO) foi proposto em 1995 por Kennedy e Eberhart. Este trabalho teve por base uma análise do comportamento de pássaros em busca de alimento. O algoritmo de enxame de partículas é um algoritmo estocástico de fácil implementação e computacionalmente eficiente. Neste algoritmo, cada partícula é uma candidata à solução de um dado problema e aprendem a partir de suas próprias experiências e da experiência das outras partículas, daí a metáfora com os pássaros.

Em termos matemáticos, os principais componentes deste algoritmo são: a posição da partícula e a sua velocidade. Durante o processo iterativo a nova velocidade da partícula e sua nova posição são calculadas pelas seguintes expressões:

$$v_i^{t+1} = w^t \cdot v_i^t + c_1 \cdot \text{rand}()^t \cdot (pbest_i^t - x_i^t) + c_2 \cdot \text{rand}()^t \cdot (gbest_i^t - x_i^t) \quad (1)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (2)$$

onde:

w - componente inercial

v_i - velocidade atual da partícula i

c_1, c_2 - parâmetros de confiança

$\text{rand}()$ – número gerado aleatoriamente

$pbest_i$ - melhor posição que a partícula i já obteve durante a busca

$gbest_i$ - melhor posição encontrada pelas partículas no enxame

x_i - posição atual da partícula i

3 – DADOS UTILIZADOS

O Operador Nacional do Sistema Elétrico - ONS, responsável pelo planejamento e programação da operação dos recursos de geração e transmissão, integrantes do Sistema Interligado Nacional - SIN, possui dentre suas atribuições principais a previsão de vazões semanais para o Programa Mensal de Operação – PMO. O principal modelo que suporta essa previsão é o modelo de nome Previzaz, desenvolvido pelo Centro de Pesquisas de Energia Elétrica (Cepel) pertencente ao

grupo ELETOBRÁS (Centrais Elétricas Brasileiras S.A). Este modelo Previvaz que é um modelo estocástico univariado é então utilizado pelo ONS num dia certo da semana que antecede à primeira semana prevista. Atualmente outras metodologias estão sendo testadas pelo ONS com o intuito de aprimorar a qualidade dos resultados das previsões de vazões, dentre elas as Redes Neurais. A utilização de novas metodologias como redes neurais artificiais testadas têm mostrado ganhos substanciais no que diz respeito à qualidade das previsões realizadas. Entretanto um aspecto importante ainda não plenamente solucionado é aquele relacionado com o erro de defasagem do pico já apresentado anteriormente.

Desta forma para realizar nosso experimento selecionamos a Usina Hidrelétrica de Tucuruí que pertence ao sistema interligado nacional e que tem grande importância para o sistema tanto pela potência instalada como pela interligação com a região Nordeste do Brasil.

A UHE Tucuruí situa-se no rio Tocantins, Estado do Pará, distando aproximadamente 300 km em linha reta da cidade de Belém. Sua construção foi iniciada em 1976, pelas Centrais Elétricas do Norte do Brasil S.A. (Eletronorte), sendo que sua operação comercial teve início em 1984, contando atualmente com 8365 MW de potência instalada. A bacia hidrográfica do rio Tocantins abrange superfícies dos estados de Goiás, Tocantins, Mato Grosso, Pará, Maranhão e Distrito Federal. A área de drenagem da bacia totaliza 757.577 km² até a Usina Hidroelétrica Tucuruí, dos quais 384.460 km² pertencem à bacia do rio Araguaia. No trecho denominado baixo Tocantins, a partir da localidade de Marabá, apresenta seus principais afluentes pela margem esquerda, destacando-se, além do rio Araguaia, o rio Itacaiúnas (figura 3). O regime fluvial apresenta períodos de cheias e de recessão bem definidos.



Figura 3 – Diagrama esquemático da localização da hidrelétrica de Tucuruí

O modelo estocástico univariado de nome Previvaz atualmente em uso realiza a previsão de vazão para uma semana à frente levando em conta os valores passados das vazões ocorridas, isto é, trata-se de um modelo vazão x vazão.

Os modelos que são apresentados neste trabalho foram desenvolvidos para prever as vazões médias diárias no horizonte de 1 (um) dia até 7 (sete) dias à frente de tal forma que nos permite calcular a média de uma semana à frente como desejado ao final.

Os dados disponíveis e aqui utilizados correspondem à série de vazões naturais médias diárias consistidas e disponibilizadas pelo ONS abrangendo o período que vai de 1969 a 2001. Estes dados apresentam uma sazonalidade marcante sendo o período que vai de Novembro a Abril considerado como o período úmido, e aquele que compreendem os meses de Maio a Outubro como sendo o período seco. Portanto as metodologias aqui utilizadas foram aplicadas separadamente aos dois períodos. As entradas utilizadas foram os valores passados das vazões ocorridas que de acordo com as análises estatísticas já realizadas quando da utilização dos modelos estocásticos nos indicavam a dependência temporal de duas semanas passadas. Logo se utiliza neste trabalho quatorze valores passados de vazões médias diárias (que corresponde aos valores de duas médias semanais passadas) para realizar a previsão de vazões sete dias à frente (uma semana). O objetivo deste experimento será utilizar a técnica de Redes Neurais Artificiais, sem a correção da defasagem do pico e de redes Neurais Artificiais com a correção da defasagem de pico proposta neste artigo.

4 – APLICAÇÃO E RESULTADOS

Os dados foram divididos em três conjuntos: um conjunto para treinamento, período que vai de 1969 até 1985, utilizado para ajustar os pesos da rede neural, um conjunto para validação cruzada, período de 1986 até 1995, utilizado para prevenir “overfitting” e um conjunto de verificação que abrange o período de 1996 até 2001 que será utilizado para avaliar o desempenho da metodologia proposta.

O número de entradas neste caso será de 14 (quatorze) que corresponde aos 14 dias anteriores e 7 (sete) saídas que correspondem aos 7 dias à frente que desejamos prever. A camada escondida construída pela rede construtiva, tanto para a rede principal como para os módulos é composta por quatro blocos possuindo, portanto uma quantidade de 12 neurônios. A arquitetura da rede que representa cada módulo diário de correção proposto possui 8 (oito) entradas.

O quadro 1 apresenta um resumo do desempenho obtido com a metodologia em termos de erro percentual médio absoluto dado pela equação 3.

$$EPMA = \frac{1}{n} \sum_{i=1}^n \frac{(Q_{o,i} - Q_{s,i})}{Q_{o,i}} * 100 \quad (3)$$

Quadro 1 – Resumo dos resultados

		Tucuruí
Rede Neural sem correção	Média	8,7%
	D. Padrão	8,0%
	D. Padrão	7,0%
Rede Neural com correção	Média	7,4%
	D. Padrão	7,5%
Estatístico	Média	11,5%
	D. Padrão	9,0%

As figuras apresentadas a seguir apresentam graficamente para melhor visualização do erro de defasagem e sua correção os resultados obtidos para o período que vai de 07/02/2001 até 01/05/2001.

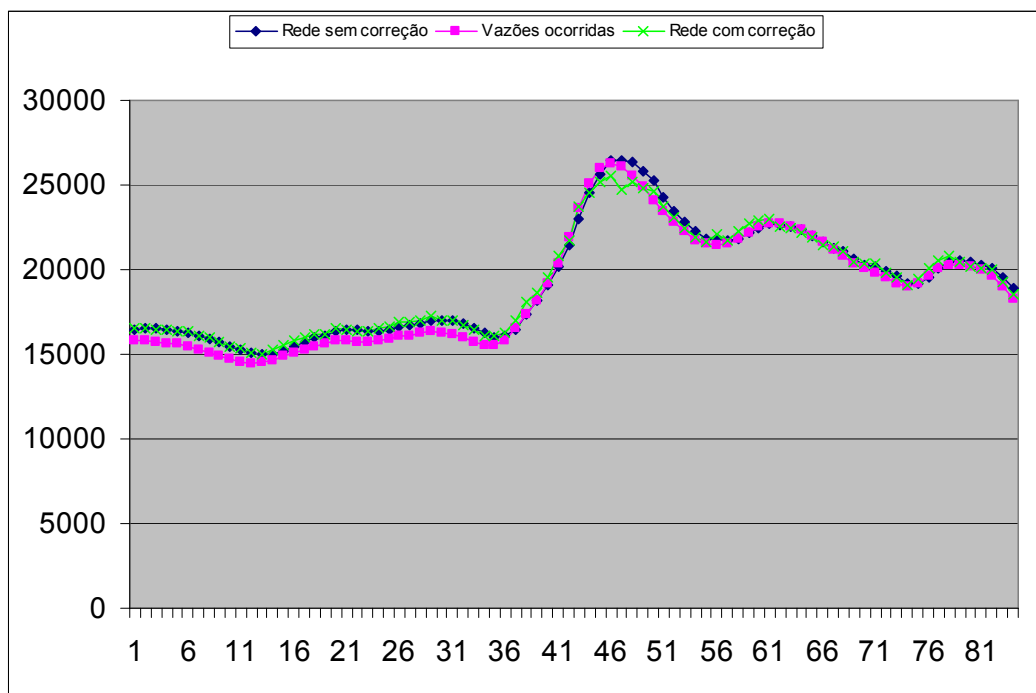


Figura 4 – Vazões previstas 1 dia à frente




Figura 5– Vazões previstas 2 dias à frente




Figura 6 – Vazões previstas 3 dias à frente

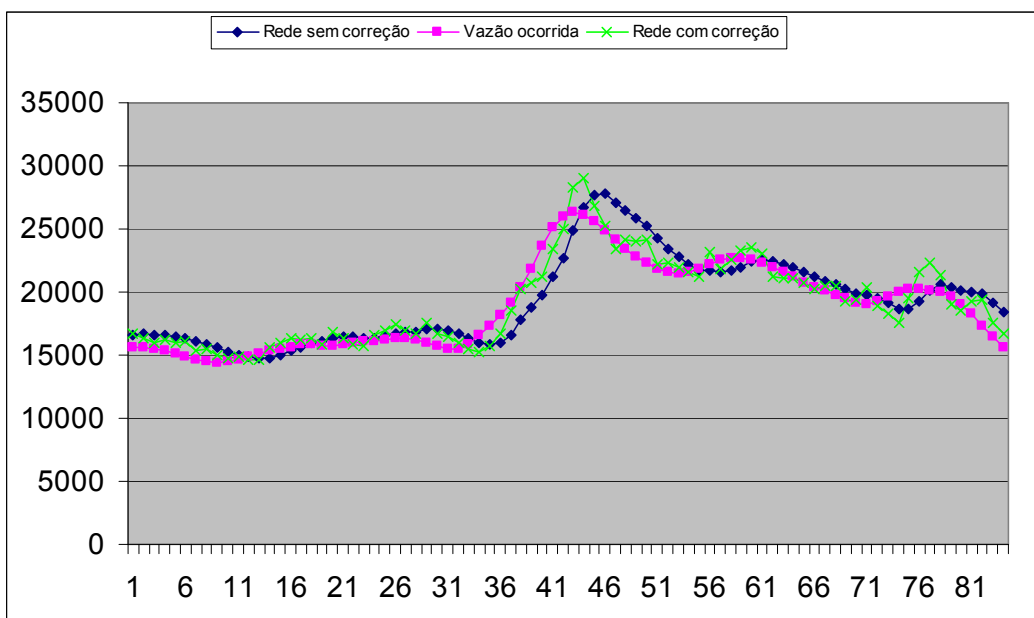


Figura 7 – Vazões previstas 4 dias à frente




Figura 8 – Vazões previstas 5 dias à frente




Figura 9 – Vazões previstas 6 dias à frente




Figura 10 – Vazões previstas 7 dias à frente




Figura 11 – Vazões previstas média de 7 dias

5 – CONCLUSÕES

Os resultados obtidos com a metodologia proposta foram de maneira geral considerados satisfatórios. A grande vantagem da metodologia proposta é que esta além de melhorar o erro de defasagem não causa qualquer perda de qualidade nas outras métricas de avaliação de tal forma que os desempenhos obtidos são até melhores. A utilização da técnica de enxame de partículas em vez da utilização do tradicional algoritmo *backpropagation* é também um ponto importante, uma vez que, este tende a ficar preso a mínimos locais e tem dificuldade de treinar esta rede de forma dinâmica com muitos pesos. Esta metodologia esta agora sendo aplicada a outros aproveitamentos Hidroelétricos de forma a verificar seu desempenho em outras Bacias hidrográficas.

BIBLIOGRAFIA

- ABRAHART, R. J.; HEPPENSTALL, A. J. ; SEE, L. M. (2007). Timing error correction procedure applied to neural network rainfall–runoff modelling. *Hydrological Sciences –Journal–des Sciences Hydrologiques*, 52(3).
- CAMPOLO, M., SOLDATI, A. & ANDREUSSI, P. (2003) Artificial neural network approach to flood forecasting in the River Arno. *Hydrol. Sci. J.* 48(3), 381–398.
- DAWSON, C. W. & WILBY, R. L. (2001) Hydrological modelling using artificial neural networks. *Progr. Phys. Geogr.* 25(1), 80–108.

- DE VOS, N. J. & RIENTJES, T. H. M. (2005) Constraints of artificial neural networks for rainfall–runoff modelling: trade-offs in hydrological state representation and model evaluation. *Hydrol. Earth System Sci.* 9(1/2), 111–126. SRef-ID: 1607-7938/hess/2005-9-111.
- DE VOS, N. J. & RIENTJES, T. H. M. (2007) Correction of timing errors of artificial neural network rainfall–runoff models. In: *Hydroinformatics in Practice: Computational Intelligence and Technological Developments in Water Applications* (ed. by R. J. Abrahart, L. M. See & D. Solomatine). Springer (in press).
- VALENÇA, M. J. S.; LUDERMIR, T. B.(1999). Aplicações de Redes Neurais. Capítulo 2: 49-84p. In: GALVÃO, Carlos de Oliveira; VALENÇA, Mêuser Jorge Silva (orgs.). *Sistemas Inteligentes: aplicações a recursos hídricos e ciências ambientais*. Coleção ABRH de Recursos Hídricos; 7. Porto Alegre, RS: Editora da Universidade.
- VALENÇA, M. J. S.; LUDERMIR, T. B.(2004).. A NON-LINEAR CONSTRUCTIVE NEURAL NETWORK TECHNIQUE FOR UPDATING OF RIVER FLOW FORECASTS. 8th Brazilian Symposium on Neural Networks (SBRN), Published by the IEEE Computer Society, São Luis, Maranhão, Brazil, Sep. 29 – Oct.01.
- VALENÇA, M.J.S. (2005). *Aplicando Redes Neurais: um guia completo*. Livro Rápido, Olinda – PE, 264 p.
- VALENÇA, M.J.S. (2007). *Fundamentos das Redes Neurais: exemplos em java*. Livro Rápido, Olinda – PE, 382p.