

# REDES NEURAIS ARTIFICIAIS APLICADAS À PREVISÃO DE VAZÕES SAZONAIS ATRAVÉS DA RELAÇÃO CHUVA-VAZÃO

Camila da Cruz Santos<sup>1</sup>, Jacson Hudson Inácio Ferreira<sup>2</sup>, Keiji Yamanaka<sup>3</sup>, José Roberto Camacho<sup>3</sup>

<sup>1</sup>Instituto Federal do Triângulo Mineiro – Campus Avançado Uberaba Parque Tecnológico, Uberaba – Minas Gerais.

<sup>2</sup>Instituto Federal do Triângulo Mineiro – Campus Ituiutaba, Ituiutaba – Minas Gerais.

<sup>3</sup>Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia – Minas Gerais.

camilacruz@iftm.edu.br, jacson@iftm.edu.br, keiji@ufu.br, jrcamacho@ufu.br

**Resumo** - Este artigo tem como objetivo apresentar uma metodologia para modelagem que envolve a relação de transformação chuva-vazão em um rio através da tecnologia de Redes Neurais Artificiais (RNA). A metodologia aplicada na modelagem teve duas abordagens: a primeira utilizou-se uma RNA sem realimentação (feedforward – MLP) e outra usando uma RNA com realimentação (feedback – Elman). Os resultados obtidos mostraram que a rede que obteve um melhor desempenho para a relação chuva-vazão foi a rede Elman.

**Palavras-Chave** - Redes Neurais Artificiais, Modelagem Chuva-Vazão, Retroalimentação.

## ARTIFICIAL NEURAL NETWORKS APPLIED TO SEASONAL PREDICTION FLOWS THROUGH THE RAIN FLOW RELATIONSHIP

**Abstract** - This article aims to present a methodology for modeling involving the rainfall-runoff transformation relation in a river through the Artificial Neural Network Technology (ANN). The methodology used in modeling had two approaches: the first used an ANN without feedback (feedforward - MLP) and the other using an ANN with feedback (Elman). The results showed that the network achieved a better performance for the rain-flow rate relation was the Elman network.

**Keywords** - Artificial Neural Networks, Rainfall-runoff modeling, Feedback.

### I. INTRODUÇÃO

O sistema hidroelétrico brasileiro apresenta aspectos peculiares que o torna diferente dos outros sistemas de base hidroelétrica. Inicialmente, pelas características das aflúncias nos rios brasileiros, que apresentam acentuada sazonalidade e elevado nível de incerteza [1].

Para viabilizar esse processo existem distribuídos em pontos específicos dos rios que integram as bacias

hidrográficas, pontos de medição que fornecem medidas discretas da vazão e de chuva, permitindo compor as séries históricas de vazão afluente e precipitação. Prever a vazão significa descobrir, por antecipação, os valores da quantidade de água que irá afluir nesses pontos de medição com base nas séries históricas disponíveis [1].

Modelos chuva-vazão descrevem a relação entre a chuva e a vazão de uma bacia hidrográfica, quantificando a transformação da chuva em vazão de um curso de água. Esta relação é descrita através de um hidrograma, que mostra a variação da vazão do curso de água no tempo, em um determinado ponto de interesse da bacia. Portanto, tem diversas finalidades práticas para a previsão de cheias, da recarga de reservatórios, da disponibilidade de água para abastecimento urbano ou irrigação, dentre outras [2].

O objetivo deste trabalho é testar o uso das redes neurais artificiais para a modelagem hidrológica da transformação chuva-vazão em um ponto intermediário da bacia do Rio Tijucu, localizada na cidade de Ituiutaba, Minas Gerais.

### II. REDE NEURAL ARTIFICIAL

Rede Neuronal representa uma tecnologia que tem raízes em muitas disciplinas: neurociência, matemática, estatística, física, ciência da computação e engenharia; e encontram aplicações em campos diversos, como modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle, em virtude de uma importante propriedade: a habilidade de aprender a partir de dados de entrada com ou sem supervisor [7].

Portanto uma Rede Neural Artificial (RNA) é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse; a rede é normalmente implementada, utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital.

Os principais componentes dos neurônios artificiais são (Figura 1) [7]:




Figura 1. Esquema de representação de um neurônio artificial. Fonte: [7]



XIV CEEL - ISSN 2178-8308  
03 a 07 de Outubro de 2016  
Universidade Federal de Uberlândia - UFU  
Uberlândia - Minas Gerais - Brasil

- As entradas ( $x_n$ ) similares aos dendritos, que fornece os valores iniciais ou recebem os estímulos transmitidos de outros neurônios;
- A função soma ( $v$ ) e a função de ativação, similar ao corpo de neurônio. A função soma tem como finalidade realizar o processamento de todas as entradas do neurônio e a função de transferência verifica se o neurônio possuirá um processo de estímulo ou inibição;
- A saída ( $y$ ) similar ao axônio, que possui como característica fornecer a resposta ao sistema ou transmitir os estímulos para outros neurônios.

A solução de problemas através de redes neurais é bastante atraente, já que a forma como estes são representados internamente pela RNA e o paralelismo natural das arquiteturas das redes cria condições favoráveis do desempenho da RNA em relação aos modelos determinísticos convencionais [8].

Nas redes neurais o procedimento usual na solução de problemas passa inicialmente por uma fase de treinamento (ajuste do modelo), em que um conjunto de exemplos é apresentado para a rede, que deles extrai as características necessárias para modelar a informação recebida [8].

### III. ARQUITETURA

#### A. Tipos de Conexão

Há duas formas de conexão mais comuns existentes para a interação entre os neurônios constituintes de uma rede neural.

##### 1) Feedforward

Quando a rede possui conexão *feedforward* todos os neurônios da camada à montante se conectam a todos os neurônios da camada à jusante, não havendo realimentação de sinais propagados de uma camada a jusante para montante. As redes *feedforward* são referenciadas como sistemas de mapeamento não-linear estático [4].

A Figura 2 representa uma rede *feedforward*.




Figura 2. Representação de uma rede feedforward multicamadas. Fonte: [9]

A *feedforward* aplicada nesse trabalho será a Rede Multilayer Perceptron (MLP). A rede MLP é composta de uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída. Em cada uma dessas camadas é possível conter um ou mais neurônios.

##### 2) Feedback

Nesse tipo de conexão, pode haver realimentação de sinais já propagados na rede. As redes *feedback* são referenciadas

como sistemas não lineares dinâmicos. A Figura 3 representa uma rede *feedback*.




Figura 3. Representação de uma rede feedback. Fonte: [9]

A *feedback* será a Rede Elman, onde é criada uma camada de entrada com neurônios adicionais, chamados de Unidades de Contexto ou Operadores de atraso unitário. No tempo  $t$ , a camada de entrada recebe a primeira entrada da sequência. Dependendo da natureza do problema, essa entrada pode ser um valor escalar ou um vetor. As unidades de contexto recebem o valor inicial de 0,5. Tanto a camada de entrada como as unidades de contexto ativam a camada oculta. A camada oculta, por sua vez, ativa a camada de saída, como também ativam de volta as unidades de contexto. Esse processo constitui a ativação da rede neural recorrente de Elman [10].

#### B. Treinamento

A fase de aprendizado de uma RNA é essencial na resolução de problemas com essa técnica, pois, é através desta que a rede neural consegue captar informações importantes dos padrões de entrada por meio do algoritmo de aprendizado ou de treinamento, que é um processo iterativo de ajuste dos pesos e bias (parâmetros), por meio de regras bem definidas, visando a solução generalizada para o problema tratado, de tal forma que, as saídas calculadas pela rede sejam iguais ou próximas da saída desejada [5].

Os treinamentos podem ser classificados como: aprendizado supervisionado, quando existe uma resposta para o problema dado de forma que seja possível comparar com a resposta obtida, aprendizado não supervisionado, quando não existe agente externo indicando a resposta desejada para os padrões de entrada e aprendizado por reforço, quando um agente externo avalia a resposta fornecida pela rede [3].

Será utilizado o algoritmo de treinamento da *backpropagation*. *Backpropagation* é o algoritmo de treinamento supervisionado que busca minimizar o erro do aprendizado, se utilizando do método do gradiente descendente, realizando correção dos pesos no sentido contrário à propagação da informação. Ou seja, da camada de saída para a camada escondida, e das camadas escondidas até a camada de entrada [5].

#### C. Normalização dos dados

A normalização dos dados serve para evitar que grandes variações dos valores de entrada atrapalhem o treinamento e o aprendizado da rede, aumentando a eficiência do algoritmo de treinamento. Com isso, todos os padrões de informações da série histórica podem ser normalizados no intervalo de  $[0, 1]$  e  $[-1, 1]$  seguindo a normalização linear conforme a Equação (1) [6]:

$$y = \frac{(b - a) \times (x_i - x_{\min})}{x_{\max} - x_{\min}} + a \quad (1)$$

Onde:

- $y$  - Valor normalizado.
- $b$  - Intervalo máximo da normalização.
- $a$  - Intervalo mínimo da normalização.
- $x_i$  - Valor a ser normalizado.
- $x_{\min}$  - Valor mínimo das variáveis.
- $x_{\max}$  - Valor máximo das variáveis.

#### D. Função de Ativação

A função de ativação  $F(\cdot)$  possui a finalidade de processar e mapear toda somatória dos estímulos, ponderados pelos pesos, advindos dos neurônios que o alimenta com informações. O resultado deste processamento faz com que o neurônio alcance um novo estado de ativação que será propagado através de sua saída, como um novo estímulo de chegada para os demais neurônios receptores deste [5].

As funções mais utilizadas são expostas na Tabela I.

Tabela I – Funções de ativação utilizadas em Redes Neurais Artificiais

Função	Representação Gráfica
Linear	
Degrau	
Tangente hiperbólica	
Sigmoide	

A função sigmoide, também conhecida como função logística, é uma função contínua que tem a forma de um S que faz a transição gradual entre os dois extremos, variando de 0 a 1. A função tangente hiperbólica é uma função sigmoide que varia entre -1 e +1.

#### IV. ESTUDO DE CASO

O método descrito foi aplicado na bacia hidrográfica do rio Tijuco, limitado ao município de Ituiutaba-MG. A bacia hidrográfica do Rio Tijuco, município de Ituiutaba - MG,

com área aproximada de 1.335,1 (Km<sup>2</sup>), região de grande significado econômico para o Estado de Minas Gerais, localiza-se no Triângulo Mineiro, entre as coordenadas geográficas 18°40' e 19°47' S e 47°53' a 50°13' W [6].

O rio Tijuco nasce a 950 m de altitude, nas coordenadas 19°31'39.88" S; 47°54'41.40" W, no município de Uberaba-MG, e tem sua foz na cota de 526 m, sendo afluente da margem esquerda do Rio Paranaíba, tendo como principais afluentes os rios Prata, Babilônia, Cabaçal, Douradinho, Panga, dentre outros [6].

Para este trabalho, escolheu-se o trecho onde se localiza a estação fluviométrica e pluviométrica Ituiutaba para realizar a análise dos dados de chuva e vazão. A estação fluviométrica Ituiutaba, localizada nas coordenadas 18°56'S e 49°26'W, entre os quilômetros 15 e 20, encontra-se entre a cota 497m e termina na cota 487m (1,31 Km). Os dados contidos na estação compreendem o período de 1969 a 2015 [6].

Os dados da série histórica foram disponibilizados pelo Sistema Nacional de Informações sobre Recursos Hídricos – SNIRH, através da plataforma Hidroweb, gerenciado e coordenado pela Agência Nacional de Águas – ANA.

O *software* Matlab foi utilizado como ferramenta de desenvolvimento e simulação dos dados da série histórica para as redes MLP e Elman. Para a rede MLP foi desenvolvido um código no programa e para a rede Elman foi utilizado a *toolbox* do Matlab.

No presente trabalho será empregado os dois casos de conexão afim de verificar qual a melhor conexão para análise da série histórica em estudo.

As Tabelas II e III apresentam a divisão dos dados da série histórica que foi utilizado nas simulações para as duas redes com valores máximos, mínimos, média e desvio padrão do período analisado para chuva e vazão, respectivamente.

Tabela II. Dados pluviométricos da série histórica

Chuva (mm)	36 meses	60 meses	180 meses
Máximo	327,2	327,2	518,5
Mínimo	0,00	0,00	0,00
Média	69,23	69,17	87,49
Desvio Padrão	87,26	86,52	110,69

Tabela III. Dados fluviométricos da série histórica

Vazão (m <sup>3</sup> /s)	36 meses	60 meses	180 meses
Máximo	266,96	317,98	423,99
Mínimo	23,47	18,10	18,10
Média	74,25	85,89	91,04
Desvio Padrão	48,64	63,79	62,98

#### V. RESULTADOS E ANÁLISES

##### A. Rede MLP

As Figuras 4 e 5 representam os gráficos das simulações de treinamento e teste da rede MLP com a mesma quantidade de variáveis de entrada, porém, modificando a quantidade de neurônios na camada escondida. Em todas as representações dos treinamentos feitas na rede MLP a linha azul é a função esperada e a vermelha a aproximada.




Figura 4. (a) Treinamento – 150:50:1. (b) Teste – 27:50:1




Figura 5. (a) Treinamento – 153:500:1. (b) Teste – 27:500:1

As simulações que compreendem as Figuras 4 e 5 possuem análise da série histórica dos últimos 15 anos da bacia estudada, resultando em 180 dados, dividindo 153 para treinamento e 27 para teste. Pode-se observar, conforme as Figuras 4 e 5, que a rede MLP respondeu melhor quando a quantidade de neurônios na camada escondida era maior.

A Figura 6 representa o gráfico da simulação da rede MLP com menos variáveis de entrada. Ela possui dados dos últimos 5 anos da série histórica.




Figura 6. (a) Treinamento – 48:1500:1. (b) Teste – 12:500:1

Nesse período a vazão máxima é de 317,91 m<sup>3</sup>/s (janeiro/11), mínima de 18,09 m<sup>3</sup>/s (agosto/09), média de 69,16 m<sup>3</sup>/s. Dos 60 dados observados, 78% possuem valores próximos da média. Observa-se na Figura 6 que a rede não consegue aproximar dos valores que estão longe da média observada. Pela compreensão da série histórica, alguns valores são esporádicos ou anormais. Assim, foram retirados alguns valores desse período que poderiam distorcer a compreensão e aproximação da rede. A Figura 7 representa o gráfico da nova simulação. Nota-se que o treinamento da

rede apresenta uma melhor modelagem que nas outras simulações realizadas.




Figura 7. (a) Treinamento – 38:500:1. (b) Teste – 12:500:1

Como a análise foi feita nos últimos 5 anos, que envolve todos os meses do ano, há a sazonalidade dos períodos de chuva e seca que existem no Brasil. Assim sendo, uma análise mensal ou diária seria importante para compreender o comportamento climático do rio.

A Figura 8 e 9 representam os gráficos da simulação que envolve uma análise mensal com e sem dados que podem prejudicar a análise. Foi escolhido o mês de janeiro, compreendendo os dados do mês de 1986-2015.




Figura 8. (a) Treinamento – 15:1000:1. (b) Teste – 8:500:1




Figura 9. Treinamento – 12:1000:1. (b) Teste – 6:500:1

Com a análise prévia dos dados, a rede apresentou uma aproximação melhor, conforme Figura 9.

## B. Rede Elman

As Figuras 10, 11 e 12 representam o gráfico da rede Elman, compreendendo o período dos últimos 15, 5 e 3 anos, respectivamente.




Figura 10. Gráfico da rede Elman no período de 15 anos – Arquitetura 180:1000:1




Figura 11. Gráfico da rede Elman no período de 5 anos – Arquitetura 60:2000:1




Figura 12. Gráfico da rede Elman no período de 3 anos – Arquitetura 36:500:1

Confrontando as Figuras 5 e 6 com as Figuras 10 e 11, onde as simulações das redes MLP e Elman tinham o mesmo período de análise, o comportamento da rede Elman apresenta melhores respostas para a modelagem chuva-vazão que a rede MLP.

Quando foi utilizado dados dos últimos 5 e 15 anos, a rede Elman convergiu melhor com um número elevado de neurônios na camada escondida, assim como na rede MLP. Já para os dados dos últimos 3 anos, a rede precisou de menos neurônios na camada escondida para obter uma melhor aproximação.

A figura 12 representa o gráfico da rede Elman mostrando o comportamento da relação chuva-vazão para o mês de janeiro nos últimos 40 anos.

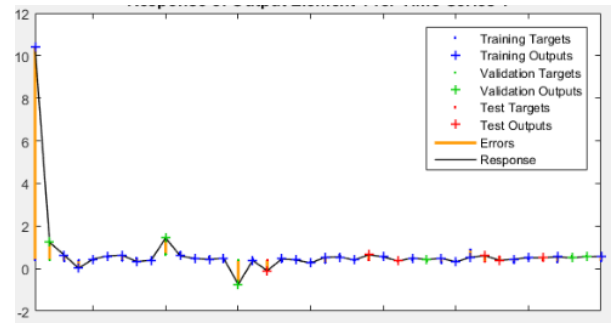


Figura 13. Gráfico da rede Elman no período de 40 anos – Arquitetura 40:2000:1

Após uma distorção no período inicial, a figura 13 mostra que a rede Elman apresentou um erro muito pequeno entre a saída conhecida e a saída encontrada. Também apresentou resultados melhores quando comparados com a rede MLP para o mesmo mês.

## VI. CONCLUSÕES

A aplicação das técnicas de Redes Neurais Artificiais na modelagem chuva-vazão pode ser uma ferramenta que o setor elétrico venha a utilizar para previsão e assim ter um conhecimento prévio do comportamento da vazão de um rio em um dia, mês ou ano.

Durante a execução do trabalho houve muitos ajustes com relação ao número de neurônios na camada escondida e também uma análise comportamental dos dados de entrada da série histórica, fatores que influenciavam nos resultados.

Valores que não se enquadravam ou que eram anormais presentes na série histórica ou em um período analisado, prejudicavam a aproximação dos valores de *target* com os de saída.

A partir da comparação feita, podemos concluir que para este problema, a rede Elman apresentou um resultado muito mais próximo ao real nas simulações realizadas neste trabalho do que a rede MLP.

## REFERÊNCIAS

- [1] L.B. Neto, P.H.G. Coelho, L. Chiganer, L.A. Meza e L.P. Monteiro, “Previsão da vazão afluente mensal do Rio São Francisco usando-se Redes de Elman”, *ENGEVISTA*, vol. 7, no. 1, pp. 63-72, Abril 2005.
- [2] F.A. Scheidt e M. A. C. Brunetto, “Modelagem Chuva-vazão utilizando Redes Neurais Artificiais e Algoritmos Genéticos”, in *XXXI Congresso da Sociedade Brasileira de Computação*, pp 1399-1408, Junho 2011.
- [3] C. Y. Tatibana. Uma Introdução às Redes Neurais. Acessado em 23 de Junho de 2016, em: <http://www.din.uem.br/ia/neurais/>.
- [4] J. R. A. Maracajá. Previsão regionalizada de vazão sazonal utilizando redes neurais artificiais. Dissertação de Mestrado. Universidade Federal de Campina Grande. Campina Grande, Paraíba. 2005. 122f.
- [5] C. C. Ferreira. Previsão de vazões naturais diárias afluentes ao reservatório da UHE Tucuruí utilizando as técnicas de redes neurais artificiais. Dissertação de

- Mestrado. Universidade Federal de Goiás. Goiânia, Goiás. 2012. 99f.
- [6] J. H. I. Ferreira. Uma contribuição ao estudo da estimativa do potencial hidrelétrico de pequenas centrais hidráulicas. Dissertação de Mestrado. Universidade Federal de Uberlândia. Uberlândia, Minas Gerais. 2014. 108f.
- [7] S. Haykin. Neural Networks and Learning Machines. 3. ed. Prentice Hall Publisher, 2008
- [8] J. L. C. Gutiérrez, J. L. C.; Romanel, C. Aplicação de redes neurais na previsão de vazão através da fundação da ombreira esquerda da barragem Corumbá-I. In: XXV Seminário Nacional de Grandes Barragens, 2003, Salvador. Anais. Salvador: Comitê Brasileiro de Barragens, 2003.
- [9] F.M. Soares, R.C.L. Oliveira. Inferência de Temperatura de Fornos de Redução de Alumínio Primário através de Sensores Virtuais IX Congresso Brasileiro de Redes Neurais, Ouro Preto – MG, 25-28 de Outubro de 2009.
- [10] L. C. M. Andrade, I. N. SILVA. Redes neurais recorrentes de Elman para previsão de demanda de energia elétrica no curtíssimo prazo. X SBAI – Simpósio Brasileiro de Automação Inteligente, São João del-Rei – MG, 18-21 de setembro de 2011.