

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

REGIANE SOUZA VILANOVA

REDES NEURAIS ARTIFICIAIS APLICADAS À SIMULAÇÃO DE VAZÃO NA BACIA HIDROGRÁFICA DO RIO ITAPEMIRIM - ES

Orientador: Prof. *D. Sc.* Sidney Sara Zanetti Coorientador: Prof. *D. Sc.* Roberto Avelino Cecílio

> JERÔNIMO MONTEIRO - ES FEVEREIRO - 2017

REGIANE SOUZA VILANOVA

REDES NEURAIS ARTIFICIAIS APLICADAS À SIMULAÇÃO DE VAZÃO NA BACIA HIDROGRÁFICA DO RIO ITAPEMIRIM - ES

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais, na Área de Concentração Ciências Florestais.

Orientador: Prof. *D. Sc.* Sidney Sara Zanetti Coorientador: Prof. *D. Sc.* Roberto Avelino Cecílio

> JERÔNIMO MONTEIRO - ES FEVEREIRO - 2017

REDES NEURAIS ARTIFICIAIS APLICADAS À SIMULAÇÃO DE VAZÃO NA BACIA HIDROGRÁFICA DO RIO ITAPEMIRIM - ES

Regiane Souza Vilanova

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 23 de Fevereiro de 2017.

Prof. Dr. Elias Fernandes de Sousa

UENF Examinador Externo

e

Prof. Dr. Vicente de Paulo S. de Oliveira IFF Examinador Externo

Prof. Dr. Roberto Avelino Cecilio UFES Coorientador

Prof. Dr., Sidney Sara Zanetti UFES Orientador "Ouça, meu filho, a instrução de seu pai e não despreze o ensino de sua mãe." Provérbios 1:8.

Este trabalho é dedicado ao meu pai Pedro, que antes de falecer me mostrou os princípios que regem minha vida até hoje, e a minha mãe Rosilda, pela garra e amor ao me criar, me ensinar e sempre acreditar em mim.

Agradecimentos

Agradeço primeiramente a Deus, por ter guardado meus caminhos em toda minha vida, e na pós-graduação, do começo ao fim.

Ao meu pai Pedro e minha mãe Rosilda pelos ensinamentos, amor, paciência e carinho para comigo sempre.

A toda minha família pelo incentivo, por acreditar em mim e pelo apoio constante.

Ao meu orientador, prof. Sidney, pelos conselhos e orientações durante todo o período da pós-graduação.

Ao meu coorientador, prof. Roberto, pelos auxílios para condução da pesquisa.

Ao meu namorado Michelangelo, pelo amor, paciência e carinho comigo, mesmo nos dias em que eu estava ausente ou de mau-humor, e por sempre acreditar no meu potencial.

Aos meus amigos do Laboratório de Modelagem Hidrológica e do coração: Sueliane, Markes, Alessandra, Estefânia, Tamires, Gisele, Elvis, Ana, Francielle, Fabrina, Carlos e Kaise.

As famílias que fiz no Espírito Santo, que me acolheram e me deram amor e carinho, em especial a família da Izonete e da Eliene.

A todos os funcionários, professores e alunos do Programa de Pós-Graduação em Ciências Florestais, os quais guardo comigo com grande carinho.

A FIBRIA e CAPES, pela concessão da bolsa de estudos.

SUMÁRIO

1.	IN	ITRODUÇÃO	9
2	0	BJETIVOS	. 11
	2.1	Objetivo geral	. 11
	2.2	Objetivos específicos	. 11
3.	R	EVISÃO DE LITERATURA	.12
	3.1	Modelos hidrológicos	.12
	3.2	Redes Neurais Artificiais	. 14
	3.3.	RNA do tipo perceptron de multicamadas	.15
	3.4	Aplicações de RNA's em recursos hídricos	.18
4	Μ	ETODOLOGIA	.23
	4.1	Área em estudo	.23
	4.2	Dados utilizados	.24
	4.3	Rede neural artificial utilizada	.28
	4.4	Índices de desempenho utilizados para avaliação dos modelos	.31
5	R	ESULTADOS E DISCUSSÃO	.33
	5.1	Análise preliminar dos dados de entrada utilizados no presente estudo	.33
	5.2	Análise dos resultados obtidos para a estação de Paineiras	.36
	5.3	Análise dos resultados para Rive	.43
	5.4	Análise dos resultados para Usina Fortaleza	.48
	5.5	Resultados com separação do escoamento superficial e subterrâneo	.52
6	С	ONCLUSÕES	.62
R	EFE	RÊNCIAS	.63

RESUMO

Há tempos o homem busca o adequado conhecimento dos processos hidrológicos para retirar deles o melhor aproveitamento. Simulações de vazões são bastante utilizadas e sugeridas para a gestão sustentável dos recursos hídricos. As redes neurais artificiais (RNA's) são modelos empíricos amplamente utilizados para modelar o processo chuva-vazão. O presente estudo tem por objetivo aplicar e testar a viabilidade de utilização de RNA's como uma opção para simular a vazão na bacia hidrográfica do Rio Itapemirim (BHRI), ES. Nesta pesquisa foi avaliada a capacidade da rede neural em modelar o processo chuva-vazão em base diária, usando 34 anos de dados pluviométricos e fluviométricos, em 12 sub-bacias. Três tipos de vazões foram simuladas: vazão diária total (q), vazão diária de escoamento superficial (qSup) e vazão diária referente ao escoamento subterrâneo (qSub). No processo de treinamento das redes foram testadas diversas combinações de dados de entrada, incluindo dados de precipitação e evapotranspiração potencial, em três sub-bacias: Paineiras (maior área); Rive (área intermediária) e Usina Fortaleza (menor área). As redes treinadas nessas sub-bacias foram testadas também nas outras sub-bacias. Os resultados mostram que as RNA's possuem maior eficiência nas bacias onde foram treinadas. O modelo composto pelas precipitações dos 5 dias anteriores e dos 30 dias antecedentes acumulados, (Pt, Pt-1, Pt-2, Pt-3, Pt-4, Pt-5, P30) simulou melhor a vazão diária total em todas as sub-bacias nas quais foi treinado, com NSE de 0,861, 0,837 e 0,711 para Paineiras, Rive e Usina Fortaleza, respectivamente. Ao treinar a rede para Paineiras e depois extrapolar para as sub-bacias de áreas menores (Lajinha, luna, Ibitirama e Usina Fortaleza), os resultados se mostraram insatisfatórios, Em virtude desses resultados insatisfatórios foram realizados testes para subbacias de áreas menores, com o intuito de verificar se a extrapolação de uma sub-bacia menor para uma menor apresentaria resultados melhores. As redes treinadas para Rive (área intermediária) apresentou resultados melhores quando testadas nas outras sub-bacias, indicando a provável influência da escala das bacias nesse tipo de comportamento. Em relação à separação do escoamento superficial e subterrâneo, a simulação do escoamento superficial apresentou melhores resultados do que o escoamento de base. Comparandose os valores obtidos com a entrada da vazão total na rede e a separação da mesma em escoamento superficial e subterrâneo, os valores foram semelhantes para Paineiras, apresentando NSE de 0,861 e 0,902, respectivamente, indicando que não há melhoria expressiva ao simular as vazões separadamente. A partir dos testes realizados, pode-se concluir que é possível estimar a vazão diária na BHRI, de forma satisfatória, utilizando RNA's e dados de precipitação como variáveis de entrada.

Palavras-chave: rede neural artificial; simulação de vazão; processo chuvavazão; modelagem.

ABSTRACT

For some time man has sought the adequate knowledge of the hydrological processes to obtain the best use of them. Flow simulations are widely used and suggested for the sustainable management of water resources. Artificial neural networks (ANNs) are empirical models widely used to model the rain-flow process. The present study aims to apply and test the feasibility of using ANNs as an option to simulate the flow in the Itapemirim River basin (BHRI), ES. This study evaluated the capacity of the neural network to model the rainfall-flow process on a daily basis using 34 years of rainfall and fluviometric data in 12 sub-basins. Three types of flows were simulated: total daily flow (q), daily outflow (qSup) and daily outflow (qSub). In the network training process, several combinations of input data. including precipitation and potential evapotranspiration data, were tested in three sub-basins: Paineiras (larger area); Rive (intermediate area) and Fortaleza (smaller area). The networks trained in these sub-basins were also tested in the other sub-basins. The results show that the ANNs have higher efficiency in the basins where they were trained. (Pt, Pt-1, Pt-2, Pt-3, Pt-4, Pt-5, P30) best simulated the total daily flow rate in all sub- Basins in which it was trained, with USE of 0.861, 0.837 and 0.711 to Paineiras, Rive and Fortaleza Plant, respectively. In order to train the network to Paineiras and then extrapolate to the sub-basins of smaller areas (Lajinha, Ibitirama and Usina Fortaleza), the results luna, proved to be unsatisfactory. Due to these unsatisfactory results, tests were performed for sub- With the purpose of verifying that the extrapolation of a smaller sub-basin to a smaller one would present better results. The networks trained for Rive (intermediate area) presented better results when tested in the other subbasins, indicating the probable influence of basin scale in this type of behavior. In relation to the separation of the surface and underground flow, the simulation of the surface run presented better results. Comparing the values obtained with the entrance of the total flow in the network and the separation of the same in surface and underground flow, the values were similar for Paineiras, presenting NSE of 0.861 and 0.902, respectively, indicating that there is no significant improvement when simulating the Flow rates separately. From the tests performed, it can be concluded that it is possible to estimate the daily flow in the BHRI, in a satisfactory way, using RNA.

Keywords: artificial neural network; flow simulation; rain-flow process; modeling.

1. INTRODUÇÃO

Nos últimos anos, o crescimento da população, a necessidade de geração de energia, alimentos e o aumento da produção industrial tem elevado significativamente o consumo de água. Atender a esse aumento de demanda por água tem sido um problema em várias partes do mundo (SOUSA; SOUSA, 2010).

Há tempos o homem busca o adequado conhecimento dos processos hidrológicos para retirar deles o melhor aproveitamento. Estes, por sua vez, se apresentam na natureza de forma complexa, dificultando a sua quantificação e, mais ainda, a sua previsão. A transformação de chuva em vazão é um dos processos mais difíceis de ser entendido, devido ao grande número de variáveis que se modificam no espaço e no tempo (SEDKI; OUAZAR; EL MAZOUDI, 2009).

As vazões previstas são bastante utilizadas e sugeridas para o planejamento de bacias hidrográficas e gestão sustentável dos recursos hídricos. Previsões de vazão podem ser geradas usando dois tipos de modelos matemáticos: modelos chuva-vazão que utilizam dados tanto climáticos quanto hidrológicos, e modelos de vazão que utilizam apenas os dados hidrológicos (YASEEN et al., 2015).

Atualmente vários modelos hidrológicos estão sendo utilizados para estudos ambientais, como modelos conceituais ou empíricos, discretos ou contínuos (LEAHY; KIELY; CORCORAN, 2008). Apesar dos bons resultados obtidos, para interpretar um modelo conceitual é necessário conhecer hidrologicamente quais são os principais processos envolvidos na modelagem hidrológica e como eles são representados matematicamente (JAIN; KUMAR, 2007; NOURANI; KISI; KOMASI, 2011). Além disso, os modelos conceituais, baseados em processos físicos, necessitam de muitos dados de entrada, fato que dificulta suas aplicações, podendo até inviabilizá-las (VERTESSY et al., 1993).

Uma rede neural artificial (RNA) é um modelo empírico e tem sido amplamente utilizada por apresentar potencial de modelar sistemas nãolineares complexos e com grandes quantidades de dados. Além disso, os modelos baseados em RNA's podem substituir ou se associar a modelos matemáticos ou estatísticos convencionais (ZHANG; PATUWO; MICHAEL Y., 1998; NOURANI; KISI; KOMASI, 2011; YASEEN et al., 2015).

ZHANG; PATUWO; MICHAEL Y. (1998) enfatizam que estas qualidades tornam as RNA's capazes não só de identificar, mais de assimilar as características consideradas mais marcantes das séries hidrológicas, como sazonalidade, tendência e periodicidade. Nos últimos anos, vários trabalhos têm sido realizados utilizando RNA's, mostrando o potencial de aplicação desta metodologia em diversas áreas e, em particular, na previsão de vazões, para intervalos temporais diários, semanais e mensais (JAIN; KUMAR, 2007; REZAEIANZADEH et al., 2013; YASEEN et al., 2015).

Nas últimas décadas, as RNA's ganharam popularidade para a previsão hidrológica (YASEEN et al., 2015). Muitos estudos têm demonstrado que as RNA's são adequadas para modelar o processo de escoamento, podendo ter até um melhor desempenho que as técnicas de modelagem convencionais. Uma extensa revisão foi realizada por MAIER; DANDY (2000) e YASEEN et al. (2015), os quais analisaram 63 documentos, e enfatizam a adequabilidade das RNA's para a previsão e simulação da vazão.

A bacia hidrográfica do Rio Itapemirim representa 12,8% do território do estado do Espírito Santo, sendo considerada a maior e também a principal bacia do sul do estado, contribuindo com o abastecimento hídrico e desenvolvimento de várias atividades econômicas. Alguns estudos sobre modelagem hidrológica já foram realizados nesta bacia, como por exemplo a calibração e teste dos modelos SWAT (FUKUNAGA et al., 2015) e DHSVM (MENDES, 2016). Porém, modelos empíricos baseados em RNA's ainda não foram testados. Estudos adicionais desse tipo são necessários, tendo em vista que a bacia apresenta uma carência de dados de clima, solo, vegetação, dentre outros, fato que dificulta o uso de modelos físicos. Diante disso, simular a vazão utilizando RNA's nesta bacia representa uma alternativa promissora, que poderá vir a auxiliar no planejamento e gestão dos recursos hídricos da região.

2. OBJETIVOS

2.1 Objetivo geral

O presente estudo tem por objetivo, desenvolver um modelo utilizando RNA's aplicar e testar a viabilidade de utilização de redes neurais artificiais como uma opção para simular a vazão na bacia hidrográfica do Rio Itapemirim, ES.

2.2 Objetivos específicos

- Obter a vazão diária da bacia hidrográfica do Rio Itapemirim, ES;
- Separar os escoamentos superficial e subterrâneo;
- Desenvolver modelos de simulação da vazão para a bacia utilizando redes neurais artificiais;
- Testar e calibrar os modelos, avaliando-os na simulação de eventos diários de chuva-vazão, tendo-se como referência os dados de vazão medidos existentes na bacia.

3. REVISÃO DE LITERATURA

3.1 Modelos hidrológicos

De maneira geral, um modelo pode ser definido como uma proposição simplificada da natureza, com o propósito de conhecer e entender um fenômeno (RENNÓ; SOARES, 2000). O modelo é considerado a representação de um sistema, sendo uma estrutura qualquer com procedimentos particulares que, a partir de um estímulo, gera resposta (TUCCI, 2005).

Um modelo hidrológico pode ser definido como uma ferramenta criada para melhor entender e representar o comportamento da bacia hidrográfica. Assim sendo, algumas de suas vantagens principais estão relacionadas à previsão de diferentes condições e no auxílio às tomadas de decisão (BEVEN, 1989; TUCCI, 2005).

Um modelo hidrológico tem como objetivo determinar, com eficiência e precisão, os componentes do ciclo hidrológico em uma bacia hidrográfica, e também estimar eficientemente o comportamento da água. A bacia hidrográfica é o objeto de estudo da maioria dos modelos hidrológicos, reunindo as superfícies que captam e direcionam a água sobre um ou mais canais de escoamento que desaguam numa única saída (TUCCI, 2005).

As principais limitações da modelagem hidrológica, de modo geral, estão relacionadas com as condições tanto quantitativas como qualitativas dos dados hidrológicos. A escolha do modelo apropriado vai depender do objetivo do estudo, das características da bacia e do rio, da disponibilidade dos dados e familiaridade com o modelo (TUCCI, 2005; RENNÓ; SOARES, 2000).

TUCCI (2005) cita três tipos de modelos utilizados no gerenciamento dos recursos hídricos:

 Modelos de comportamento: são geralmente usados para apresentar o comportamento de um sistema. Por exemplo, um modelo de comportamento representando um trecho qualquer de um rio, busca reproduzir o hidrograma de jusante, que está sujeito a diferentes hidrogramas de entrada a montante. Neste caso, o modelo irá especular alternativas que são possíveis de ocorrência no sistema, predizendo a resposta do mesmo a essas ações.

- Modelos de otimização: são utilizados para determinar as melhores soluções no projeto de um sistema específico. Existem vários exemplos de modelos de combinação, como dimensionamento do controle de uma rede de drenagem urbana, operação de reservatórios dentre outros.
- Modelos de planejamento: são voltados para a simulação de condições globais de um sistema mais amplo. O modelo de planejamento não busca apenas soluções hidráulica, hidrológicas ou econômicas, mas vai além, envolvendo quantificações sócio-econômicas e ambientais, normalmente englobando uma região ou uma bacia.

Segundo VERTESSY et al. (1993) e TUCCI (2005), os modelos podem ser classificados, dentre outras opções, de acordo com a forma de representação dos dados (discretos ou contínuos), a existência ou não de relações espaciais (concentrado ou distribuídos), o tipo de variáveis utilizadas na modelagem (estocásticos ou determinísticos), e o tipo de relações entre essas variáveis (empíricos ou conceituais).

Os modelos são ditos contínuos quando as variáveis de entrada e saída ocorrem de forma contínua ao longo do tempo, e discretos quando as mudanças de estado se dão em intervalos discretos.

O modelo é concentrado quando não considera a variabilidade espacial das variáveis hidrológicas envolvidas no processo modelado, sendo sua principal variável, o tempo. Já os modelos distribuídos, além de considerar como cada fenômeno ocorre ao longo do tempo, também consideram as suas variações espaciais.

Os modelos que explicitamente consideram a probabilidade de certo evento ocorrer são ditos estocásticos. Se o modelo não considerar a natureza probabilística de certas variáveis hidrológicas, então o modelo é dito determinístico, e a forma como um evento ocorrerá será produto de regras claras e entradas bem determinadas.

Um modelo é considerado empírico quando visa ajustar matematicamente/estatisticamente os dados calculados aos dados observados, sem considerar explicitamente a relação entre as funções utilizadas e os processos físicos. Já nos modelos conceituais, os processos físicos são considerados na elaboração das funções que irão compor o modelo.

Apesar de bons resultados obtidos, os modelos conceituais apresentam certos limites em alguns aspectos, como a necessidade de interpretação do algoritmo do modelo, o grande número de parâmetros que devem ser calibrados e a necessidade de levantamento de dados em campo. Uma alternativa aos modelos conceituais são os modelos empíricos ou "caixas pretas", que relacionam entradas e saídas através de funções matemáticas sem relação com as características físicas do processo chuva-vazão (JAIN; KUMAR, 2007; NOURANI; KISI; KOMASI, 2011; VERTESSY et al., 1993; VERTESSY et al., 1993).

A aplicação do método empírico baseado em redes neurais artificiais tem viabilizado a obtenção de resultados animadores em diversos campos do conhecimento, inclusive como método eficaz no tratamento de variáveis temporais complexas, como no caso das variáveis hidrológicas chuva e vazão (YASEEN et al., 2015).

3.2 Redes Neurais Artificiais

As RNA's constituem sistemas de processamento distribuído paralelo que, por serem baseados no funcionamento do sistema nervoso biológico, possuem propensão natural de armazenar conhecimento experimental (HAYKIN, 2001).

A principal característica das RNA's está relacionada a sua habilidade de aprender um dado conteúdo, adaptando-se a várias situações que jamais fizeram parte do treinamento. As mesmas são compostas por neurônios interligados, formando camadas, conforme ilustrado na (HAYKIN, 2001).

Em 1943 foi realizado o primeiro trabalho sobre redes neurais artificiais por McCulloch e Pitts, os quais desenvolveram um estudo com o objetivo de criar um modelo matemático para o neurônio biológico (MCCULLOCH; PITTS, 1943). Após a publicação do trabalho de McCulloch e Pitts, houve vários avanços na área de redes neurais durante as décadas subsequentes (ZHANG; EDDY PATUWO; HU, 1998), por pesquisadores até da área de neurofisiologia, como Donald Hebb, que descobriu a base de aprendizagem das RNA's, e propôs a utilização de pesos como forma representativa da RNA assimilar o conhecimento (HEBB,1949).

Na década de 50, Frank Rosenblatt arquitetou a primeira RNA, nos padrões que são utilizados até hoje. A RNA de Rosenblatt foi denominada perceptron, que consiste em uma RNA de uma camada, com capacidade de aprender a identificar padrões conforme as regras propostas por Hebb (HAYKIN, 2001).

Em 1969, Marvin Minsky e Seymour Papert publicaram o livro Perceptron, no qual fizeram críticas severas a pesquisas voltadas para RNA's, alegando que, além de utilizar processos de aproximação empíricos, não realizavam algumas operações booleanas. O impacto dessa publicação culminou na retração de praticamente todo o investimento e programas de pesquisas voltados para as RNA's. Em 1974, surgiram novos rumores sobre as redes neurais, com Paul Werbos, o qual lançou as bases do algoritmo de treinamento backpropagation que, mais tarde, em 1986, seria apresentado por Rumelhart, Hinton e Williams (HAYKIN, 2001).

A ideia de utilizar RNA's para a previsão não é nova. Hu, em 1964, sugeriu o primeiro modelo de RNA para previsão de séries temporais. Um aumento no interesse de vários pesquisadores em relação a aplicação de RNA's no campo da previsão de séries temporais ocorreu após a publicação do livro *Parallel Distributed Processing* (RUMELHART, et al., 1986).

Existem vários tipos de redes neurais, dentre as principais podem ser citados o perceptron de multicamadas (MLP), redes de função de base radial (RBF), *neural network generalized regression* (GRNN), *Self Organizing Map* (SOM) e redes recorrentes (HAYKIN, 2001; YASEEN et al., 2015). Dentre estas, a mais utilizada e que tem apresentado melhores resultados para modelar o processo chuva-vazão é a MLP (KASHANI; GHORBANI; DINPASHOH, 2014; KENTEL, 2009; REZAEIANZADEH et al., 2013; YASEEN et al., 2015).

3.3. RNA do tipo perceptron de multicamadas

As RNA's do tipo perceptron de multicamadas ou *multilayer perceptron* (MLP) são formadas por um conjunto de neurônios dispostos em camadas,

sendo uma camada com as variáveis de entrada, uma ou mais camadas intermediárias de neurônios e uma camada de saída (Figura 1). Cada variável da camada de entrada é conectada a todos os neurônios da camada intermediária, e da mesma forma, cada neurônio da camada intermediária está conectado a todos os neurônios da camada de saída (GARDNER; DORLING, 1998).



Figura 1 – Exemplo de rede neural artificial MLP com três camadas.

Na RNA do tipo MLP o fluxo de dados se dá em uma única direção (*feedforward*), onde os dados de entrada propagam-se através da RNA, camada a camada, no sentido progressivo. Os valores da camada de entrada são ponderados pelos pesos das respectivas conexões, sendo que esta combinação passa por uma função de ativação, gerando uma resposta, sendo essa a entrada para a próxima camada (GARDNER; DORLING, 1998; ZHANG; EDDY PATUWO; HU, 1998)

A unidade básica de processamento de uma RNA é um neurônio artificial (Figura 2). Essa unidade básica processa suas entradas por meio da soma ponderada e de uma função de ativação (HAYKIN, 2001). Segundo HAYKIN (2001); MAIER; DANDY (2000), as funções de ativação comumente aplicadas em RNA são do tipo sigmóide (logística ou tangente hiperbólica).

Figura 2 – Modelo não-linear de um neurônio utilizado em redes neurais artificiais.



Fonte: adaptado de HAYKIN, (2001).

As funções logística (Equação 1) e tangente hiperbólica (Equação 2) são representadas, respectivamente, da seguinte forma:

$$f(x) = \frac{1}{1 + e^{-x}}$$
(1)

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \tag{2}$$

Tanto o número de camadas intermediárias como o número de neurônios em cada uma delas são escolhidos de forma empírica, de acordo com a maior ou menor necessidade de se processar as entradas da rede, isto é, os números de camadas e neurônios podem aumentam ou diminuir, dependendo da complexidade do processamento necessário para a rede capturar características não lineares do dados (SARMENTO, 1996; YASEEN et al., 2015; ZHANG; HU, 1998). Tanto o funcionamento como o desempenho de uma RNA depende diretamente da escolha dos componentes que serão adotados em sua estrutura e do método adotado no seu treinamento (ZHANG; HU, 1998).

No treinamento supervisionado de uma rede neural artificial devem existir pares de dados, de entrada e saída. Toda vez que uma entrada for apresentada à RNA, uma saída será obtida. Se a diferença entre saída obtida e a saída desejada estiver fora dos limites considerados satisfatórios, os pesos entre as conexões devem ser ajustados (HAYKIN, 2001).

No treinamento de uma RNA, HAYKIN (2001) exemplifica que a aprendizagem termina quando a rede alcança um índice de desempenho estabelecido, ou quando o processo iterativo de treinamento atinge um determinado número de iterações.

Em recursos hídricos, as técnicas mais utilizadas para o treinamento de RNA's são o algoritmo backpropagation e o de Levenberg-Marquardt (LM) (MAIER; DANDY, 2000; ZHANG; HU, 1998).

O algoritmo Levenberg-Marquardt é uma extensão do método de Newton-Raphson. A opção por esse algoritmo no ajuste dos pesos de uma RNA torna o ajuste mais rápido e eficiente (MAIER; DANDY, 2000). Segundo HAGAN; MENHAJ (1994), esta técnica de otimização é muito mais eficiente que outras, quando se treinam redes que têm até poucas centenas de parâmetros (pesos e bias), provocando uma convergência mais rápida e resultados com maior precisão.

3.4 Aplicações de RNA's em recursos hídricos

Muitos estudos têm utilizado RNA's para a simulação e previsão de chuva-vazão e outras variáveis hidrológicas (KIŞI, 2007). MAIER; DANDY (2000) apresentou uma extensa revisão de literatura sobre as aplicações de RNA's até o ano 2000, examinando um total de 43 documentos. Comentários exaustivos também sobre a aplicação de RNA's foram relatados em um estudo realizado por YASEEN et al. (2015), do ano 2000 até 2015, examinando um total de 20 documentos.

Nos últimos anos, as aplicações de RNA's têm apresentado resultados animadores em diversos campos do conhecimento, inclusive como método

eficaz no tratamento de variáveis temporais complexas, como no caso das variáveis hidrológicas chuva e vazão (GHUMMAN et al., 2011; HUO et al., 2012; RIAD et al., 2004; SENTHIL KUMAR et al., 2005; SUDHEER; GOSAIN; RAMASASTRI, 2002; ZHANG; EDDY PATUWO; HU, 1998).

As RNA's têm sido utilizadas com sucesso para modelar relações envolvendo séries temporais complexas de entrada e saída em várias áreas (MAIER; DANDY, 2000; ZEALAND; BURN; SIMONOVIC, 1999). Neste contexto, SHAMSELDIN (1997) utilizou RNA's em simulações hidrológicas do tipo chuva-vazão em seis bacias, com áreas de drenagem entre 1.207 e 18.000 km². O objetivo era avaliar o desempenho da técnica, comparando com alguns modelos de chuva-vazão convencionais, modelo linear simples (SLM), modelo de perturbação linear baseado na sazonalidade (LPM), e modelo de perturbação linear do vizinho mais próximo (NNLPM). Os resultados mostraram que as RNA's são promissoras no contexto de modelagem chuva-vazão.

ANMALA et al. (2000) aplicaram RNA's em simulações hidrológicas mensais em três bacias hidrográficas no Kansas, EUA, com áreas de drenagem entre 518 e 640 km², obtendo desempenho superior a dois outros modelos empíricos, com coeficiente R² superior a 0,9. RIAD et al. (2004) desenvolveram uma RNA e a usaram para modelar o processo chuva-vazão. Utilizando uma rede MLP, os autores concluíram que a rede apresentou-se mais adequada para prever a vazão de um rio, em relação aos modelos clássicos de regressão testados.

KISI (2007) estudou a previsão de vazão diária de curto prazo usando diferentes algoritmos combinados com RNA's. Os algoritmos backpropagation, gradiente conjugado, correlação cascata e Levenberg-Marquardt foram aplicados aos dados de vazão contínua. Os resultados indicam que a RNA com o algoritmo LM apresentou as melhores previsões de vazão em comparação com os outros modelos.

JAIN; KUMAR (2007) aplicaram modelos com RNA's e modelos autorregressivos para a previsão hidrológica mensal em uma bacia do rio Colorado, Estados Unidos, com área de 290.000 km². Foram testadas diferentes configurações de modelos, e em todos os casos, os modelos baseados em RNA's obtiveram resultados melhores que os autorregressivos. Em outro estudo, desenvolvido por TOTH; BRATH (2007), avaliou-se a capacidade de previsão em tempo real de um modelo conceitual usando rede neural. Os resultados indicaram as redes neurais como excelentes ferramentas para a simulação em tempo real de chuva-vazão de períodos contínuos (incluindo fluxos de vazão baixa, média e de pico), desde que um extenso conjunto de dados hidrometeorológicos esteja disponível para fins de calibração.

MUTLU et al. (2008) utilizaram dois modelos diferentes de rede neural, uma MLP e a rede neural de base radial (RBF), para prever a vazão em quatro estações de medição. Ambos os modelos realizaram de forma satisfatória as previsões da vazão em várias estações de medição. No entanto, o modelo MLP apresentou-se mais eficiente que o modelo RBF.

KAGODA et al. (2010) utilizaram uma rede RBF para a previsão da vazão diária, para o rio luvuvhu, na Áfica do Sul. Os resultados sugerem que as RNA's são promissoras para a previsão de vazões na área de estudo.

Mais recentemente, DANANDEH MEHR et al. (2014) investigaram a aplicabilidade de modelos de previsão sucessiva de estação, como uma prática alternativa para a previsão de vazão em bacias hidrográficas com poucos dados pluviométricos, usando registros de vazão mensais de duas estações sucessivas sobre o rio Çoruh, Turquia. Os resultados indicaram um papel promissor da metodologia sucessiva-estação na previsão de vazões mensais.

Questões de modelagem que afetam o desempenho de uma RNA devem ser consideradas com cuidado. Uma decisão considerada crítica é determinar a arquitetura apropriada, isto é, o número de camadas e o número de nós em cada camada (MAIER; DANDY, 2000).

SARMENTO (1996) realizou uma análise relacionando a arquitetura da rede neural em função do problema a ser tratado. O objetivo foi mostrar a possibilidade do uso das técnicas de RNA's na modelagem de variáveis hidrológicas. Para isso, foram mostrados dois exemplos: (a) simulação da relação chuva-vazão mensal em uma bacia da região semi-árida do Nordeste; e (b) na previsão de vazões médias diárias com intervalos de 1 e 2 dias do rio Leine, localizado na região central da Alemanha. SARMENTO (1996) concluiu que o uso das RNA's deve ser indicado nas modelagens dos fenômenos

naturais, em casos que não se tenha uma formulação matemática explícita que traduza as relações entre as diversas variáveis envolvidas.

Em aplicações de RNA's, várias decisões são necessárias, envolvendo a escolha do tipo de rede utilizada, número de camadas e de neurônios em cada camada, algoritmo de treinamento, função de ativação, forma de padronização dos dados, etc. (MAIER; DANDY, 2000). Neste contexto, é apresentado no Quadro 1 uma revisão de vários trabalhos relativamente atuais relacionados com a aplicação de RNA's em modelos chuva-vazão. Embasado nessa revisão, enfatiza-se que o tipo de rede neural mais utilizado nesse tipo de aplicação é a MLP, com apenas uma camada intermediária, utilizando como algoritmo de treinamento o LM e função de ativação tangente sigmóide.

Autores	Variáveis de entrada	Neurônios na(s) camada(s) oculta(s)	Função de ativação	Algoritmo de treinamento*	Tipo de rede utilizada+
JAIN; KUMAR (2007)	Vazão	7, 8 e 9	Sigmóide unipolar	Não informado	MLP
DANANDEH MEHR et al. (2014)	Vazão	8	Sigmóide	LM	FFBP, GRNN, RBF
KENTEL (2009)	Precipitação e vazão	?	Sigmóide	LM	MLP
REZAEIANZADEH et al., 2013	Precipitação e vazão	7	Tangente sigmóide	SCG	MLP
KASHANI et al., 2014	Precipitação	1	Tangente sigmóide	LM e BFGS	MLP e Volterra (FOV)
ZEALAND; BURN; SIMONOVIC (1999)	Precipitação, temperatura e vazão	1	Sigmóide	BP	MLP
BEHZAD et al. (2009)	BEHZAD et al. (2009) Precipitação, vazão, temperatura, evaporação		Sigmóide	LM e momento	MLP
CHANG et al. (2014)	Precipitação	2 e 4	Sigmóide	BP	MLP
SOUSA; SOUSA (2010)	Vazão e precipitação	15	Logística sigmóide	LM	MLP
REZAEIAN-ZADEH; TABARI; ABGHARI (2013)	Vazão e precipitação	30	Tangente sigmóide	LM, BP, GDX e SCG	MLP

Quadro 1 - Detalhes dos trabalhos revisados sobre aplicações de redes neurais artificiais em modelos chuva-vazão

* Levenberg-Marquardt (LM); scaled conjugate gradient (SCG); back-propagation (BP); variable learning rate (GDX)

+ feed-forward back-propagation (FFBP); rede neural generalizada (GRNN); função de base radial (RBF); multilayer perceptron (MLP)

4 METODOLOGIA

Neste estudo foram aplicadas e testadas redes neurais artificiais para simular a vazão diária utilizando dados de chuva e evapotranspiração para a bacia hidrográfica do rio Itapemirim.

4.1 Área em estudo

A bacia hidrográfica do rio Itapemirim – BHRI (Figura 3) situa-se na região Sudeste do Brasil, Sul do estado do Espírito Santo. A bacia possui aproximadamente 5.919,5 km² (IEMA, 2012) Está situada entre os meridianos 40º48' e 41º52' de Longitude Oeste, entre os paralelos 20º10' e 21º15' de Latitude Sul.



Figura 3 – Localização da bacia hidrográfica do rio Itapemirim.

Fonte: Adaptação de Sistema Integrado de Bases Georreferenciadas do estado do Espírito Santo – GEOBASES.

A área da bacia abrange um total de 16 municípios capixabas (Itapemirim, Cachoeiro de Itapemirim, Vargem Alta, Jerônimo Monteiro, Muqui, Atílio Vivácqua, Presidente Kennedy, Castelo, Venda Nova do Imigrante, Conceição do Castelo, Muniz Freire, Iúna, Ibatiba, Marataízes, Ibitirama e Alegre) e um município mineiro (Lajinha).

Segundo a classificação de Köppen, os climas predominantes na região são do tipo Cwa na região serrana (Subtropical) e Aw nas regiões mais baixas da bacia (Tropical úmido), com período seco no inverno e verão chuvoso. A precipitação média anual varia entre 1.000 e 1.300 mm, e a temperatura média anual é de 24°C nas regiões mais baixas e 21°C na região serrana da bacia (ALVARES et al., 2013).

4.2 Dados utilizados

Neste estudo foram utilizados dados de vazão diária referente a doze estações fluviométricas, apresentadas na Tabela 1 e Figura 4, ordenadas em ordem decrescente de área de drenagem (sub-bacis). A vazão foi dividida pela área de cada sub-bacia, visando obter a vazão específica, para facilitar a comparação dos resultados. Os dados diários de precipitação е evapotranspiração potencial utilizados foram obtidos na base de dados disponibilizada por XAVIER; KING; SCANLON, (2016), a qual foi elaborada para todo o Brasil a partir da interpolação dos dados das estações brasileiras, incluindo as 18 estações pluviométricas apresentadas na Figura 4, gerando a grade apresentada na Figura 5, recortada na área da BHRI, e cujas células quadradas apresentam dimensão de 0,25º (aproximadamente 28 km).

Ordem	Código	Nome da estação	Rio	Área de drenagem (km ²)
1	57580000	Usina Paineiras	Rio Itapemirim	5.170
2	57555000	Coutinho	Rio Itapemirim	4.510
3	57460000	Pacotuba	Rio Itapemirim	2.720
4	57450000	Rive	Rio Itapemirim	2.180
5	57550000	Usina São Miguel	Rio Castelo	1.420
6	57400000	Itaici	Rio Braço Norte Esquerdo	1.010
7	57490000	Castelo	Rio Castelo	972
8	57370000	Terra Corrida	Rio Pardo	566
9	57360000	lúna	Rio Pardo	412
10	57476500	Fazenda Lajinha	Rio Castelo	410
11	57420000	Ibitirama	Rio Braço Norte Direito	337
12	57350000	Usina Fortaleza	Rio Braço Norte Esquerdo	205

Tabela 1 – Estações utilizadas como fonte de informações fluviométricas.

Fonte: Sistema de Informações Hidrológicas - HidroWeb, da Agência Nacional de Águas (ANA, 2015).

Figura 4 – Estações fluviométricas e pluviométricas presentes na bacia que foram utilizadas no estudo.



Fonte: Adaptação de Sistema Integrado de Bases Georreferenciadas do estado do Espírito Santo – GEOBASES.

Todas as bases de dados adotadas apresentaram, em comum, no mínimo, dados no período entre 1980 a 2013 (34 anos), sendo este o período considerado no presente estudo, totalizando 408 meses de observação. As precipitações e evapotranspirações médias diárias da BHRI foram calculadas utilizando a grade de XAVIER; KING; SCANLON, (2016) na forma de polígonos de Thiessen, adotando o ponto central de cada célula como sendo uma estação, onde para cada sub-bacia foi utilizado somente as estações que de acordo com a grade apresentava influência para a mesma (Figura 5).

Figura 5 – Grade obtida na base de dados disponibilizada por XAVIER; KING; SCANLON, (2016), recortada na área da bacia hidrográfica do rio Itapemirim.



Fonte: Adaptação de Sistema Integrado de Bases Georreferenciadas do estado do Espírito Santo – GEOBASES e XAVIER; KING; SCANLON, (2016).

No presente estudo três tipos de vazões específicas foram simuladas: vazão diária total (q), vazão diária de escoamento superficial (qSup) e vazão diária referente ao escoamento subterrâneo (qSub). As vazões qSup e qSub foram separadas utilizando o programa SepHidro, desenvolvido por MIRANDA et al. (2014). Na aplicação do SepHidro utilizou-se o método do Mínimo Local (ML) para separar as vazões, tendo em vista que esse método gera hidrogramas com linhas mais suavizadas, consideradas mais condizentes com a realidade natural das bacias.

No método do ML, o SepHidro verifica se a vazão do dia $D_{(i)}$ é a menor dentro do intervalo $2N^*_{(i)}$ dias (cinco dias). Atendida essa condição, então este dia é considerado um mínimo local, ou seja, é considerado como escoamento subterrâneo. Em seguida, o intervalo de $2N^*_{(i)}$ é deslocado para o próximo dia da série de vazões, verificando se a vazão do dia $D_{(i+5)}$ é a menor dentro do intervalo. Assim como anteriormente, se for a menor vazão, esta é então considerada também um mínimo local, e assim sucessivamente (Figura 6).

Figura 6 – Ilustração da separação dos escoamentos superficial (qSup) e subterrâneo (qSub) para os últimos 3 anos dos dados utilizados, utilizando o método do Mínimo Local.



O intervalo de 2N*_(i) dias é o número inteiro imediatamente superior ao dobro de N, que é o intervalo de duração em dias do escoamento superficial direto após o pico de vazão, utilizado para a aplicação do método, sendo determinado pela equação empírica:

$$N = 0,827 A^{0,2}$$
(3)

Em que:

A = área de drenagem da bacia, km^2 .

4.3 Rede neural artificial utilizada

Utilizou-se a RNA do tipo "multiLayer perceptron", com três camadas, sendo uma de entrada, uma intermediária e uma de saída. Na rede utilizou-se apenas uma camada intermediária pelo fato da maioria dos estudos utilizarem somente uma e apresentarem resultados satisfatórios (MAIER; DANDY, 2000). Com embasamento na literatura pesquisada neste trabalho (Quadro 1), em relação à função de ativação e ao número de neurônios utilizados na camada intermediária, optou-se por adotar a função sigmóide tangente hiperbólica (Equação 2) e 30 neurônios, dispensando-se a dispendiosa etapa de testes por tentativa para se determinar essas configurações de rede.

Na camada de entrada foram realizados testes com as combinações de variáveis de entrada apresentadas na Tabela 2, para escolha de tais modelos realizou-se uma correlação linear simples na qual pode ser visto influência das chuvas anteriores nas vazões total, superficial e subterrânea. A metodologia de variar o número de entradas possibilita, além de novas formas funcionais, a avaliação da sensibilidade das RNA's em função das variáveis de entrada (JAIN; KUMAR, (2007); NOU RANI; KISI; KOMASI, (2011) e REZAEIANZADEH et al., (2013).

Entradas	Saídas
Pt	
P _t , P _{t-1}	
P _t , P _{t-1} , P _{t-2}	
P _t , P _{t-1} , P _{t-2} , P _{t-3}	
P _t , P _{t-1} , P _{t-2} , P _{t-3} , P _{t-4}	
P _t , P _{t-1} , P _{t-2} , P _{t-3} , P _{t-4} , P _{t-5}	
P _t , P ₃₀	q e qSup
P _t , P _{t-1} , P ₃₀	
P _t , P _{t-1} , P _{t-2} , P ₃₀	
P _t , P _{t-1} , P _{t-2} , P _{t-3} , P ₃₀	
$P_{t}, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{30}$	
$P_{t}, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5}, P_{30}$	
P _t , P ₆₀	
P_{t}, P_{t-1}, P_{60}	
P _t , P _{t-1} , P _{t-2} , P ₆₀	
P _t , P _{t-1} , P _{t-2} , P _{t-3} , P ₆₀	
P_{t} , P_{t-1} , P_{t-2} , P_{t-3} , P_{t-4} , P_{60}	
P_{t} , P_{t-1} , P_{t-2} , P_{t-3} , P_{t-4} , P_{t-5} , P_{60}	
P _t , P ₉₀	q
P_{t}, P_{t-1}, P_{90}	
P _t , P _{t-1} , P _{t-2} , P ₉₀	
$P_{t}, P_{t-1}, P_{t-2}, P_{t-3}, P_{90}$	
$P_{t}, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{90}$	
$P_{t}, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5}, P_{90}$	
P ₃₀	
P ₆₀	
P ₉₀	
P ₃₀ , P ₆₀	
P ₃₀ , P ₉₀	qSub
P ₆₀ , P ₉₀	
$P_{30}, P_{60} P_{90}$	

Tabela 2 – Combinações de variáveis de entrada testadas nos modelos chuvavazão, utilizando redes neurais artificiais, na bacia do rio Itapemirim.

P_t: precipitação diária (mm); P_{t-i}: precipitação do i-ésimo dia anterior ao da vazão estimada (mm); P₃₀, P₆₀ e P₉₀: precipitação acumulada dos últimos 30, 60 e 90 dias, respectivamente, anteriores ao dia da vazão estimada (mm); q: vazão específica diária (m³.s⁻¹.km⁻²); qSup: vazão de escoamento superficial (m³.s⁻¹.km⁻²); qSub: vazão proveniente do escoamento subterrâneo ou vazão de base (m³.s⁻¹.km⁻²); t: intervalo de tempo diário.

Foram testadas também combinações de variáveis de entrada considerando a evapotranspiração de referência (ET₀). Nesse caso, foram utilizadas as mesmas combinações apresentadas na Tabela 2, substituindo a precipitação pela diferença entre precipitação e evapotranspiração.

As RNA's foram treinadas utilizando o algoritmo de Levenberg-Marquardt, pelo fato de ser um dos métodos mais eficientes e utilizados com propósitos semelhantes (BEHZAD et al., 2009; CHANG et al., 2014; KASHANI; GHORBANI; DINPASHOH, 2014; REZAEIAN-ZADEH; TABARI; ABGHARI, 2012).

Os dados (34 anos) foram divididos em 70% para a fase de treinamento, 15% para a validação cruzada e 15% para a fase de teste das redes. Na validação cruzada, o subconjunto de treinamento (aleatorizado) é utilizado para treinar a rede e, após cada iteração, a sessão de treinamento é interrompida visando verificar o erro. O treinamento é finalizado na iteração referente ao menor erro da rede, calculado usando a amostra de validação cruzada, conforme ilustrado na Figura 7.

Figura 7 – Ilustração da regra de parada antecipada baseada na validação cruzada



Fonte: HAYKIN, (2001).

Cada RNA foi treinada dez vezes, adotando-se a rede com o menor valor da raiz do quadrado médio do erro (RMSE), calculado usando os dados de teste. Para o treinamento, todos os dados de entrada foram padronizados entre -1 e 1 (Equação 4).

$$X_{norm} = 2 \frac{X_i - X_{min}}{X_{max} - X_{min}} - 1$$
(4)

Em que:

X_{norm} = dados padronizados utilizados no treinamento das redes;
 X_i = dados originais das variáveis de entrada;
 X_{max} e X_{min} = valores mínimos e máximos de cada variável de entrada.

O processo de criação, treinamento e simulação das RNA's foi realizado a partir de algoritmos (*scripts*) implementados no MATLAB.

4.4 Índices de desempenho utilizados para avaliação dos modelos

Para avaliar o ajuste dos modelos foram elaborados gráficos de dispersão entre os dados observados e estimados, sendo ajustadas regressões lineares simples. Adicionalmente, foram utilizados os seguintes indicadores estatísticos:

Coeficiente de determinação (r²): calculado como sendo o quadrado do coeficiente de correlação de Pearson.

Raiz do quadrado médio do erro (RMSE, m³.s⁻¹.km⁻²):

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n} (E_i - O_i)^2}{n}}$$
(5)

Coeficiente de eficiência de Nash e Sutcliffe (NSE) (NASH; SUTCLIFFE, 1970):

NSE =
$$1 - \frac{\sum_{i=1}^{n} (E_i - O_i)^2}{\sum_{i=1}^{n} (O_i - \overline{O})^2}$$
 (6)

Erro absoluto médio (MBE):

$$MBE = \frac{1}{n} \sum_{i=1}^{n} \left(\mathsf{E}_{i} - \mathsf{O}_{i} \right)$$
(7)

Em que:

 O_i = vazão observada, m³.s⁻¹.km⁻²; E_i = vazão estimada, m³.s⁻¹.km⁻²; n = número de observações;

 \overline{O} = vazão observada média, m³.s⁻¹.km⁻².

5 RESULTADOS E DISCUSSÃO

No presente estudo, RNA's foram treinadas e aplicadas para estimar a vazão na BHRI, utilizando dados de precipitação e evapotranspiração como variáveis de entrada. Entretanto, diante das diversas possibilidades de combinações de variáveis de entrada para aplicação nas redes, e visando selecionar as variáveis principais, foi realizado um estudo prévio, apresentado no tópico subsequente. Após a realização desse estudo, combinações das variáveis de entrada mais representativas foram aplicadas no treinamento das redes para estimar a vazão na bacia, viando selecionar definitivamente as variáveis de entrada a serem utilizadas. O critério utilizado na seleção dos modelos foi avaliar a capacidade de generalização das RNA's, através de análises estatísticas entre os dados calculados e observados, usando o período de dados de teste. Finalmente, após a realização dos testes com o treinamento e seleção das variáveis de entrada, as RNA's foram aplicadas para estimar a vazão das sub-bacias do rio Itapemirim, analisando-se os resultados obtidos.

5.1 Análise preliminar dos dados de entrada utilizados no presente estudo

Os modelos de entrada foram escolhidos com base na correlação calculada entre os dados de chuva e vazão, onde pode ser constatada a influência das chuvas anteriores nas vazões total, superficial e subterrânea. No Quadro 2 são mostradas as correlações chuva-vazão para todas as 12 subbacias, organizadas de forma decrescente por área. Para qSub, a chuva acumulada de 90 dias anteriores apresentou a maior correlação em todas as sub-bacias analisadas, com valor médio de 0,75, exceto na estação de lbitirama, cujo maior valor ocorreu para 60 dias anteriores. Para qSup, a chuva de apenas um dia anterior apresentou a maior correlação em todas as subbacias analisadas, com valor médio de 0,69, exceto nas três maiores subbacias, cujo maior valor ocorreu para a chuva de dois dias anteriores nas estações de Coutinho e Pacotuba, e para a chuva de três dias anteriores na

	1 – Paineiras		2 – Coutinho 3 – Pacotuba			uba	4 – Rive			5 – Usina São Miguel			6 – Itaici					
	q	qSub	qSup	q	qSub	qSup	q	qSub	qSup	q	qSub	qSup	q	qSub	qSup	q	qSub	qSup
Pt	0.26	0.23	0.22	0.30	0.23	0.26	0.30	0.24	0.27	0.34	0.24	0.32	0.30	0.19	0.28	0.33	0.20	0.32
Pt-1	0.39	0.24	0.38	0.53	0.24	0.56	0.63	0.26	0.66	0.65	0.25	0.69	0.56	0.21	0.59	0.67	0.21	0.72
Pt-2	0.60	0.25	0.65	0.59	0.25	0.63	0.66	0.27	0.69	0.63	0.26	0.66	0.55	0.22	0.58	0.61	0.22	0.64
Pt-3	0.63	0.26	0.69	0.50	0.26	0.51	0.51	0.28	0.50	0.49	0.27	0.48	0.42	0.22	0.41	0.45	0.23	0.45
Pt-4	0.55	0.27	0.58	0.42	0.26	0.41	0.41	0.29	0.38	0.40	0.28	0.38	0.34	0.23	0.32	0.37	0.24	0.34
Pt-5	0.47	0.27	0.47	0.38	0.27	0.35	0.37	0.30	0.32	0.36	0.28	0.32	0.33	0.24	0.29	0.34	0.24	0.30
P030	0.79	0.70	0.66	0.69	0.66	0.55	0.69	0.69	0.56	0.69	0.70	0.56	0.67	0.67	0.53	0.68	0.64	0.54
P060	0.73	0.80	0.54	0.66	0.73	0.46	0.65	0.78	0.47	0.64	0.80	0.46	0.63	0.77	0.43	0.64	0.75	0.45
P090	0.67	0.81	0.46	0.59	0.73	0.38	0.59	0.80	0.40	0.58	0.81	0.39	0.58	0.79	0.36	0.59	0.78	0.37
P120	0.59	0.78	0.36	0.52	0.70	0.30	0.52	0.78	0.31	0.50	0.79	0.30	0.51	0.77	0.28	0.52	0.77	0.29
P150	0.50	0.72	0.27	0.43	0.65	0.22	0.43	0.72	0.23	0.41	0.73	0.22	0.44	0.74	0.21	0.44	0.73	0.21
		7 - Caste	elo	8	8 - Terra Corrida			9 - Lajinha			10 - Iúna		11 - Ibitirama		12 - Usina Fortaleza			
Р	0.31	0.21	0.28	0.35	0.19	0.35	0.33	0.21	0.31	0.32	0.12	0.35	0.41	0.29	0.38	0.39	0.21	0.38
Pt-1	0.69	0.22	0.74	0.67	0.20	0.74	0.71	0.22	0.75	0.59	0.13	0.70	0.66	0.31	0.67	0.62	0.22	0.64
Pt-2	0.56	0.23	0.58	0.58	0.21	0.62	0.50	0.23	0.51	0.50	0.13	0.57	0.56	0.31	0.55	0.49	0.23	0.49
Pt-3	0.40	0.24	0.39	0.43	0.22	0.43	0.37	0.24	0.35	0.38	0.14	0.41	0.46	0.32	0.43	0.39	0.24	0.37
Pt-4	0.35	0.25	0.31	0.35	0.22	0.33	0.32	0.25	0.28	0.32	0.15	0.33	0.40	0.33	0.36	0.34	0.24	0.30
Pt-5	0.33	0.26	0.29	0.31	0.23	0.28	0.32	0.25	0.28	0.29	0.15	0.28	0.36	0.33	0.31	0.32	0.25	0.28
P030	0.66	0.67	0.52	0.66	0.62	0.52	0.64	0.68	0.50	0.58	0.39	0.51	0.64	0.74	0.51	0.64	0.66	0.50
P060	0.60	0.74	0.42	0.63	0.73	0.44	0.60	0.76	0.41	0.55	0.47	0.42	0.57	0.77	0.42	0.59	0.74	0.40
P090	0.55	0.75	0.35	0.59	0.78	0.36	0.54	0.77	0.34	0.51	0.50	0.34	0.50	0.73	0.34	0.52	0.74	0.32
P120	0.47	0.72	0.27	0.52	0.78	0.28	0.46	0.73	0.26	0.45	0.50	0.26	0.40	0.66	0.25	0.44	0.70	0.24
P150	0.39	0.67	0.20	0.44	0.75	0.19	0.37	0.68	0.18	0.38	0.48	0.18	0.30	0.57	0.16	0.36	0.64	0.17

Quadro 2 – Correlação chuva-vazão para as 12 sub-bacias em um período de até 150 dias anteriores de chuva acumulada (P₁₅₀). Obs.: P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4} e P_{t-5} são chuvas de dias anteriores, sem acumular.

Para a vazão total (q), existe um efeito combinado de qSub e qSup. Como visto acima, a qSub é mais influenciada pela chuva acumulada de dezenas de dias anteriores e a qSup é mais influenciada pela chuva de poucos dias anteriores. Nesse caso, duas variáveis apresentaram maior correlação com a vazão total: a chuva acumulada de 30 dias anteriores, em todas as subbacias analisadas, com correlação média de 0,67; e a chuva de apenas um dia anterior, em todas as sub-bacias analisadas, com valor médio de 0,64, exceto nas três maiores sub-bacias, da mesma forma como ocorreu para qSup.

Na Figura 8 as correlações são apresentadas de forma gráfica, apenas para a bacia de Paineiras. Como visto no Quadro 2, os resultados para qSup e vazão total (q) foram melhores, para Paineiras, para a chuva de três dias anteriores, porém, no Figura 8 (A), utilizando chuvas diárias acumuladas, percebe-se que as correlações para qSup aumentam até 5 dias anteriores, permanecendo relativamente constante até aproximadamente 20 dias, e em seguida, apresentam queda acentuada, conforme Figura 8 (B).

Para a vazão subterrânea (qSub), a curva apresenta sua melhor ascensão ao se adicionar os últimos 90 dias acumulados de chuva, exatamente como apresentado no Quadro 2. Anteriormente aos 90 dias, vê-se que os resultados vem melhorando a medida que se adiciona mais dias antecedentes. Após 90 dias, a correlação diminui, indicando que a adição de mais dias tem pouca influência na vazão atual

A partir da análise desses resultados, optou-se por adotar as seguintes variáveis de entrada para a realização de testes, visando selecionar as variáveis mais representativas para estimar a vazão na BHRI, utilizando RNA's:

q: P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5}, P₃₀, P₆₀ e P₉₀ qSup: P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5} e P₃₀ qSub: P₃₀, P₆₀ e P₉₀ Figura 8 – Correlação chuva-vazão para a bacia de Paineiras em um período de até 240 dias anteriores de chuva acumulada.



5.2 Análise dos resultados obtidos para a estação de Paineiras

A análise preliminar realizada anteriormente, onde pode ser vista a influência de dias anteriores de chuva na vazão de hoje, norteou os testes aqui realizados em relação aos modelos de entradas utilizados. Na Figura 9 (A e B) são apresentados os resultados referentes às diferentes combinações de dados de entrada testados para estimar a vazão na sub-bacia de Paineiras. O modelo que teve como entrada as precipitações P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5} e P₃₀ foi considerado o que melhor simulou a vazão diária (q), com menor RMSE $(0,007 \text{ m}^3.\text{s}^{-1}.\text{km}^{-2})$ e maior r² (0,856), obtidos utilizando a amostra de teste.

Figura 9 – Diferentes combinações de dados de entrada testados (A e C) e valores observados e estimados (B e D) para estimar a vazão na sub-bacia Paineiras.





Resultados similares também foram encontrados por REZAEIAN ZADEH et al. (2013), que em seu estudo para as bacias hidrográficas Khosrow Shirin dentro da província de Fars no Irã, avaliaram doze modelos diferentes de entradas para a rede e concluíram que o desempenho melhorou com a adição de chuvas antecedentes. Em um estudo realizado por REZAEIAN ZADEH et al. (2010), no qual se utilizou 5 modelos diferentes como entrada para a rede, verificou-se também que ao se adicionar mais dias anteriores de chuva o desempenho do modelo melhorou simulando melhor a vazão. JAIN; KUMAR, (2007) também chegaram à mesma constatação em seu trabalho realizado para o rio Colorado, em Lees Ferry, EUA.

Os resultados para precipitação menos a evapotranspiração (PET), apresentados na Figura 9 (C e D), foram semelhantes aos resultados encontrados para a precipitação (P). O modelo composto pelas variáveis de entradas Pt-ETt, Pt-1-ETt-1, Pt-2-ETt-2, Pt-2-ETt-3, Pt-4-ETt-4, Pt-5-ETt-5, P30-ET30 apresentou o menor RMSE (0,007 m³.s⁻¹.km⁻²) e o maior r² (0,858). Comparando-se os gráficos apresentados na Figura 9 (A e B versus C e D), vêse que a inserção da variável evapotranspiração nos modelos de entrada da rede não apresentou ganhos significativos na simulação da vazão para a área de estudo.

As melhores combinações de entrada da rede para P e PET treinadas para paineiras foram testadas nas outras onze sub-bacias, com o intuito de verificar se o modelo que melhor simulou a vazão para Paineiras apresentaria bons resultados se utilizado nas outras sub-bacias.

O RMSE para cada modelo de P e PET bem como outros cinco critérios de avaliação de desempenho para as doze sub-bacias, estão dispostos na Tabela 3, onde as sub-bacias estão organizadas de forma decrescente em termos de área. Gráficos de dispersão mostrando as relações entre dados observados e estimados também para P e PET são mostrados na Figura 10, e um hidrograma é apresentado na Figura 11 para os dois últimos anos dos dados de teste para P e PET.

Efetuando uma análise da tabela vê-se que o modelo escolhido tanto para P como para PET simulou bem a vazão na bacia de Paineiras (1), apresentando valores de RMSE de 0,006 e 0,006 m³.s⁻¹.km⁻² e um NSE de 0,861 e 0.863, respectivamente. Valor semelhante foi encontrado por KAGODA et al. (2010), que utilizaram como entrada para a rede dados de precipitação da bacia do rio Luvuvhu, no nordeste da África do Sul, obtendo um NSE de 0,894.

Continuando a análise percebe-se, de maneira geral, que os critérios de avaliação de desempenho apresentaram resultados melhores para as bacias com maior área de drenagem, como, por exemplo, Paineiras (1), Pacotuba (3) e Rive (4), que apresentaram valores de NSE para P de 0,861, 0,675 e 0,628, respectivamente. Ibitirama (11) e Usina fortaleza (12), bacias que possuem a menor área de drenagem, sofreram uma depreciação dos resultados, apresentando um NSE de 0,228 e 0,395, respectivamente. Essa depreciação dos resultados pode ser explicada pelo fato das bacias com menor área de drenagem apresentarem uma reposta mais rápida aos fenômenos a que são expostas, provocando uma maior dinâmica para a vazão.

Nos resultados para PET as bacias de menor área de drenagem citadas acima tiveram valores de NSE de 0,220 e 0,387, respectivamente, evidenciase também os melhores resultados obtidos com as bacias de maior área de drenagem que apresentaram um desempenho de NSE de 0,863, 0,680 e 0,634, respectivamente.

Os valores de r² tanto para P (0,861) como para PET (0,863) foram melhores para a bacia com maior área de drenagem, quando comparados com a de menor área, que apresentou r² de 0,506 e 0,502 respectivamente. No hidrograma, vê-se que a vazão estimada pelo modelo foi bem próxima da vazão observada tanto para P como para PET.

Vê-se que, o comportamento hidrológico em cada sub-bacia se dá de forma distinta, ou seja, para uma entrada (chuva) no sistema (sub-bacia), a resposta (vazão) será ajustada às suas condições físicas inerentes. Assim, sub-bacias de maior porte podem não conseguir, através do modelo, representar a vazão de sub-bacias de pequeno porte no teste.

Na Tabela 3, figura 10 e 11, evidencia-se também os ganhos insignificativos obtidos com a adição da variável evapotranspiração como entrada na rede. Nota-se que a simulação da vazão realizada apenas com a precipitação como entrada obteve resultados satisfatórios apresentando RMSE de 0.0060 m³.s⁻¹.km⁻² e NSE de 0.861, valores estes bem próximos dos obtidos com a inserção da variável evapotranspiração como entrada na rede que apresentou RMSE de 0.0060 m³.s⁻¹.km⁻² e NSE de 0.863.

Sub-		Precipita	ção		Precipitação menos evapotranspiração				
bacia	RMSE*	MBE*	NSE	r²	RMSE*	MBE*	NSE	r ²	
1	0,006	0,0000	0,861	0,861	0,006	0,0000	0,863	0,863	
2	0,010	0,0004	0,645	0,651	0,010	0,0004	0,652	0,657	
3	0,011	-0,0006	0,675	0,677	0,011	-0,0007	0,680	0,683	
4	0,013	-0,0031	0,628	0,653	0,013	-0,0031	0,634	0,660	
5	0,011	0,0006	0,541	0,567	0,011	0,0007	0,538	0,564	
6	0,013	-0,0016	0,590	0,599	0,013	-0,0016	0,594	0,603	
7	0,012	0,0006	0,554	0,558	0,012	0,0005	0,568	0,570	
8	0,013	-0,0021	0,514	0,554	0,012	-0,0021	0,526	0,561	
9	0,015	-0,0012	0,490	0,494	0,015	-0,0014	0,497	0,502	
10	0,016	-0,0039	0,307	0,417	0,015	-0,0039	0,320	0,422	
11	0,045	-0,0195	0,228	0,525	0,044	-0,0194	0,230	0,535	
12	0,021	-0,0079	0,395	0,506	0,021	-0,0080	0,387	0,502	

Tabela 3 – Avaliação de desempenho para os modelos de P e PET para as doze sub-bacias

*Unidade: m³.s⁻¹ km⁻².

Não se pode afirmar com precisão que a utilização de dados de evapotranspiração na previsão de vazões seja dispensável, porém, isso pode ser um indicativo que a utilização de outras variáveis de entrada relacionadas às vazões, não seja tão significativa na inferência de valores de vazões diárias.

BARATTI et al. (2003) utilizou, em seu trabalho, dados de precipitação de 30 estações pluviométricas e informações sobre o clima a partir de 2 estações de temperatura, a fim de estimar os valores de escoamento na bacia Tirso. Os experimentos foram realizados considerando-se apenas as chuvas, e acrescentando, a seguir, escoamento, temperatura e informações sobre o clima na camada de entrada. Verificou-se que nenhuma vantagem na previsão dos dados de vazão foi obtida em função da utilização da temperatura ou evapotranspiração como entrada da rede, assim como foi verificado no presente trabalho. Diante do exposto acima, os modelos de entrada de PET foram descartados para os próximos testes realizados neste trabalho.

Figura 10 - Gráficos de dispersão para os modelos de precipitação (a) e precipitação menos a evapotranspiração (b) para as sub-bacias de Paineiras, Rive e Usina Fortaleza.



Vazão observada (m³.s⁻¹. km⁻²)

0.00 0.10 0.20 0.30 0.40 (b) Vazão observada (m³.s⁻¹. km⁻²)

Figura 11 – Hidrograma da vazão diária observada e estimada para P (a) e PET (b) pelas redes neurais artificiais, para os ultimos dois anos dos dados de teste.



5.3 Análise dos resultados para Rive

Em virtude dos piores resultados encontrados anteriormente para a bacia de Paineiras, em relação a extrapolação para bacias de menor área de drenagem, foram realizados testes para Rive que é considerada uma sub-bacia de área intermediária. Os dados foram treinados para Rive com o intuito de verificar se a extrapolação para bacias menores apresentaria resultados satisfatórios.

Os mesmos modelos de precipitação usados para Paineiras foram utilizados para Rive, na Figura 12 é apresentado o resultados referentes às diferentes combinações de dados de entrada testados para estimar a vazão e gráfico de dispersão na sub-bacia de Rive. Vê-se que o modelo que simulou melhor a vazão para a bacia foi o que teve como entrada as seguintes precipitações (Pt, Pt-1, Pt-2, Pt-3, Pt-4, Pt-5, P30) apresentando um RMSE de 0,010 m³.s⁻¹ km⁻² e r² de 0,8016.

Figura 12 – Diferentes combinações de dados de entrada testados e gráfico de dispersão para estimar a vazão na sub-bacia de Rive.



Na Tabela 4 são mostradas as performances dos cinco critérios de avaliação para as sub-bacias de Paineiras e Rive, na Figura 13 pode ser visto a dispersão dos dados em torno da reta e na Figura 14 um hidrograma da vazão observada e estimada. Analisando a tabela percebe-se que o modelo simulou bem a vazão para Rive, apresentando um RMSE de 0,009 m³.s⁻¹.km⁻² e NSE

de 0,837. Resultados satisfatórios também podem ser vistos para outras bacias, como Coutinho (2) e Pacotuba (3), que apresentaram valores de NSE de 0,593 e 0,817, respectivamente. Quando se analisou a questão das bacias com área de drenagem menor, notou-se uma melhora nos resultados obtidos, que pode ser vista em uma comparação apresentada na Tabela 4.

Sub-	Trei	nado para	a Paineira	as		Treinado para Rive				
bacia	RMSE*	MBE*	NSE	r ²	. –	RMSE*	MBE*	NSE	r ²	
1	0,006	0,000	0,861	0,861		0,011	0,003	0,553	0,673	
2	0,010	0,000	0,645	0,651		0,011	0,003	0,593	0,680	
3	0,011	-0,001	0,675	0,677		0,008	0,002	0,817	0,831	
4	0,013	-0,003	0,628	0,653		0,009	0,000	0,837	0,837	
5	0,011	0,001	0,541	0,567		0,011	0,003	0,538	0,663	
6	0,013	-0,002	0,590	0,599		0,009	0,001	0,781	0,802	
7	0,012	0,001	0,554	0,558		0,009	0,003	0,758	0,792	
8	0,013	-0,002	0,514	0,554		0,010	0,001	0,704	0,772	
9	0,015	-0,001	0,490	0,494		0,011	0,001	0,734	0,738	
10	0,016	-0,004	0,307	0,417		0,014	-0,001	0,415	0,565	
11	0,045	-0,020	0,228	0,525		0,039	-0,017	0,416	0,685	
12	0,021	-0,008	0,395	0,506		0,017	-0,005	0,611	0,674	

Tabelas 4 – Critérios de avaliação de desempenho para Paineiras, Rive e para as outras dez sub-bacias.

*Unidade: m³.s⁻¹.km⁻².

Os valores dos critérios de avaliação de desempenho para as bacias menores foram, na maioria, melhores para a bacia de Rive, quando comparado com Paineiras. Usina Fortaleza, que tem a menor área de drenagem, apresentou uma melhora, com NSE passando de 0,395 (ajuste com dados de Paineiras) para 0,611 (ajuste com dados de Rive). Essa diferença pode ser explicada pelo fato de a bacia de Rive possuir menor área que Paineiras e, consequentemente, possuir área mais próxima das bacias menores; Porém, mesmo com essa ligeira melhora nos resultados, ainda se evidencia valores

insatisfatórios para as bacias de pequena área de drenagem, como Fazenda Lajinha (10) e Ibitirama (11).

BESAW et al. (2010), em trabalho realizado na bacia do Rio Winooski, localizada no noroeste de Vermont, EUA, também constataram a depreciação dos resultados quando se analisou as sub-bacias com áreas de drenagem menores.

MORIASI et al. (2007) considera um desempenho satisfatório para um modelo se os valores de NSE forem superiores a 0,5. Tanto para Paineiras como para Rive, os resultados se enquadram nesse critério. Entretanto, mesmo com a ligeira melhora dos resultados de Rive, para as sub-bacias de menor área de drenagem, ainda se observa valores de NSE menores que 0,5. Quando se treinou os dados para Paineiras, quatro sub-bacias apresentaram valores de NSE menores que 0,5, e quando se treinou para Rive, apenas duas apresentaram valores de NSE inferiores a 0,5. Contudo, como no presente trabalho foram simulados dados diários de vazão, considera-se que a classificação de desempenho proposta por MORIASI et al. (2007) seja muito rigorosa, pois foi baseada em dados mensais de vazão, os quais possuem naturalmente menor variabilidade.

FUKUNAGA et al. (2015), em trabalho utilizando o modelo SWAT para simular a vazão na sub-bacia de Rive, encontraram, após a calibração do modelo, um valor de NSE de 0,75 (obtido com a amostra de calibração), inferior ao encontrado no presente estudo (0,837) utilizando redes neurais.

MENDES (2016), em trabalho realizado na BHRI, aplicando o modelo DHSVM, encontrou valores de NSE de 0,56 e 0,61, respectivamente, para as sub-bacias de Rive e Paineiras, após a calibração do modelo para cada sub-bacia. Porém, tais valores são também inferiores aos obtidos neste estudo, utilizando redes neurais, nas sub-bacias de Rive e Paineiras (0,837 e 0,861, respectivamente). MENDES (2016) também testaram a opção de calibrar o modelo em uma bacia e testar em outras, de forma análoga ao realizado no presente estudo, porém os resultados também foram inferiores quando comprados aos obtidos utilizando redes neurais.

Observando a Figura 13 vê-se a dispersão dos dados em torno da reta bem como valores de r² para Paineiras, Rive e Usina Fortaleza. Os três primeiros gráficos de dispersão na ordem vertical refere-se ao teste realizado para Paineiras e os outros três para Rive, nota-se que o valor de r^2 é ligeiramente melhor quando se treina os dados para Rive e extrapola para as bacias menores. Por exemplo, a bacia Usina fortaleza, que apresentou r^2 de 0,674 para Rive, tendo apresentado para Paineiras um valor de 0,506. Na Figura 14, onde têm-se o hidrograma, vê-se que a vazão estimada pelo modelo aproximou-se bastante da vazão observada para a sub-bacia de Rive

Figura 13 – Gráficos de dispersão para as sub-bacias de Paineiras, Rive e Usina Fortaleza, onde os três primeiros gráficos na ordem vertical são referentes ao treinamento para Paineiras e os outros três ao treinamento realizado para Rive. Paineiras



Figura 14 – Hidrograma da vazão diária observada e estimada para a subbacia de Rive pela rede neural artificial, para os ultimos dois anos dos dados de teste.



5.4 Análise dos resultados para Usina Fortaleza

Diante dos resultados obtidos anteriormente para Paineiras e Rive, um teste foi realizado para Usina Fortaleza, sub-bacia de menor área de drenagem, no sentido de averiguar se o modelo treinado para a mesma apresentaria resultados satisfatórios para as bacias de maior área de drenagem. Os mesmos modelos de entrada para precipitação citados anteriormente, também foram utilizados para este teste (P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5}, P₃₀).

Na Tabela 5 são mostrados os valores de RMSE bem como os outros quatro critérios de avaliação de desempenho para as sub-bacias, e dispersão dos dados em torno da reta (Figura 15) e na figura 16 tem-se um hidrograga da vazão diária observada e estimada. Os resultados para a sub-bacia Usina Fortaleza foram considerados satisfatórios, com RMSE de 0,015 m³.s⁻¹.km⁻² e NSE de 0,711. Como pode ser visto na tabela, o modelo se ajusta bem para algumas sub-bacias, porém, para outras, como Paineiras e Coutinho, os resultados não foram tão satisfatórios, por serem bacias com maior área de

drenagem. Estas ofereceram uns dos piores resultados, obtendo para o caso um NSE de 0.066 e 0.185, respectivamente.

Uma comparação entre os resultados obtidos para Paineiras e Usina Fortaleza, pode ser vista na Tabela 5. Em termos de RMSE a sub-bacia que apresentou o melhor resultado foi Paineiras com um valor de 0,006 m³.s⁻¹.km⁻². O desempenho do NSE foi melhor também para a bacia de Paineiras, que apresentou um NSE de 0,831. Esse valor foi superior ao da sub-bacia Usina Fortaleza, que foi de 0,711. Esse fato pode ser explicado pelo maior número de estações fluviométricas e pluviométricas presentes na sub-bacia de Paineiras, que apresenta uma maior área e assim engloba uma maior quantidade de estações, enquanto que a sub-bacia de Usina fortaleza foi levado em consideração apenas os dados de uma estação pluviométrica devido a sua pequena área de drenagem.

	Painei	ras			Usina Fortaleza				
RMSE*	MBE*	NSE	r ²		RMSE*	MBE*	NSE	r ²	
0,006	0,000	0,861	0,861		0.016	0.007	0.066	0.624	
0,010	0,000	0,645	0,651		0.016	0.008	0.185	0.643	
0,011	-0,001	0,675	0,677		0.013	0.007	0.537	0.767	
0,013	-0,003	0,628	0,653		0.012	0.004	0.689	0.789	
0,011	0,001	0,541	0,567		0.015	0.008	0.092	0.636	
0,013	-0,002	0,590	0,599		0.014	0.006	0.510	0.761	
0,012	0,001	0,554	0,558		0.013	0.008	0.491	0.763	
0,013	-0,002	0,514	0,554		0.014	0.005	0.360	0.748	
0,015	-0,001	0,490	0,494		0.013	0.006	0.621	0.733	
0,016	-0,004	0,307	0,417		0.018	0.003	0.078	0.559	
0,045	-0,020	0,228	0,525		0.034	-0.012	0.545	0.683	
0,021	-0,008	0,395	0,506		0.015	-0.001	0.711	0.713	
	RMSE* 0,006 0,010 0,011 0,013 0,011 0,013 0,012 0,013 0,015 0,016 0,045 0,021	Painei RMSE* MBE* 0,006 0,000 0,010 0,000 0,011 -0,001 0,013 -0,003 0,011 0,001 0,013 -0,002 0,012 0,001 0,013 -0,002 0,014 -0,002 0,015 -0,001 0,016 -0,004 0,045 -0,020 0,021 -0,008	Paineiras RMSE* MBE* NSE 0,006 0,000 0,861 0,010 0,000 0,861 0,010 0,000 0,645 0,011 -0,001 0,675 0,013 -0,003 0,628 0,011 0,001 0,541 0,013 -0,002 0,590 0,012 0,001 0,554 0,013 -0,002 0,514 0,015 -0,001 0,490 0,016 -0,004 0,307 0,045 -0,020 0,228 0,021 -0,008 0,395	PaineirasRMSE*MBE*NSE r^2 0,0060,0000,8610,8610,0100,0000,6450,6510,011-0,0010,6750,6770,013-0,0030,6280,6530,0110,0010,5410,5670,013-0,0020,5900,5990,0120,0010,5540,5580,013-0,0020,5140,5540,015-0,0010,4900,4940,016-0,0040,3070,4170,045-0,0200,2280,5250,021-0,0080,3950,506	PaineirasRMSE*MBE*NSE r^2 0,0060,0000,8610,8610,0100,0000,6450,6510,011-0,0010,6750,6770,013-0,0030,6280,6530,0110,0010,5410,5670,013-0,0020,5900,5990,0120,0010,5540,5580,013-0,0020,5140,5540,015-0,0010,4900,4940,016-0,0040,3070,4170,045-0,0200,2280,5250,021-0,0080,3950,506	PaineirasRMSE*MBE*NSE r^2 RMSE*0,0060,0000,8610,8610.0160,0100,0000,6450,6510.0160,011-0,0010,6750,6770.0130,013-0,0030,6280,6530.0120,0110,0010,5410,5670.0150,013-0,0020,5900,5990.0140,0120,0010,5540,5580.0130,013-0,0020,5140,5540.0140,015-0,0010,4900,4940.0130,016-0,0040,3070,4170.0180,045-0,0200,2280,5250.0340,021-0,0080,3950,5060.015	PaineirasUsina FortaRMSE*MBE*NSE r^2 RMSE*MBE*0,0060,0000,8610,8610.0160.0070,0100,0000,6450,6510.0160.0080,011-0,0010,6750,6770.0130.0070,013-0,0030,6280,6530.0120.0040,0110,0010,5410,5670.0150.0080,013-0,0020,5900,5990.0140.0060,0120,0010,5540,5580.0130.0080,013-0,0020,5140,5540.0140.0050,015-0,0010,4900,4940.0130.0060,016-0,0040,3070,4170.0180.0030,045-0,0200,2280,5250.034-0.0120,021-0,0080,3950,5060.015-0.001	PaineirasUsina FortalezaRMSE*MBE*NSE r^2 RMSE*MBE*NSE0,0060,0000,8610,8610.0160.0070.0660,0100,0000,6450,6510.0160.0080.1850,011-0,0010,6750,6770.0130.0070.5370,013-0,0030,6280,6530.0120.0040.6890,0110,0010,5410,5670.0150.0080.0920,013-0,0020,5900,5990.0140.0060.5100,0120,0010,5540,5580.0130.0080.4910,013-0,0020,5140,5540.0140.0050.3600,015-0,0010,4900,4940.0130.0060.6210,045-0,0200,2280,5250.034-0.0120.5450,021-0,0080,3950,5060.015-0.0010.711	

Tabela 5 – Critérios de avaliação de desempenho para Paineiras eUsina Fortaleza e para as outras nove sub-bacias.

*Unidade: m³ .s⁻¹ .km⁻².

Assim, como foi mencionado anteriormente, sub-bacias de pequeno porte podem não conseguir, através do modelo, representar a vazão de subbacias maiores no teste e vice-versa.

Em uma análise da figura do teste realizado para a sub-bacia Usina Fortaleza, vê-se que o coeficiente de determinação para a mesma foi considerado satisfatório, apresentando um valor de 0,713. Nota-se uma ligeira depreciação do resultado de r² para a sub-bacia Paineiras, que apresentou um valor de 0,624.

Uma comparação entre os dois testes mostra que Paineiras apresentou o maior coeficiente de determinação ($r^2 = 0,861$), como citado anteriormente, esse resultado pode ser explicado tanto pelo fato da sub-bacia possuir uma maior área de drenagem e a resposta hidrológica dessas bacias se dar de forma mais lenta, do que nas de menor área. No hidrograma apresentado na Figura 16 vê-se que a vazão estimada pelo modelo foi bem próxima da vazão observada para a sub-bacia de Usina Fortaleza. Figura 15 – Gráficos de dispersão para os testes das sub-bacias de Paineiras, Rive e Usina Fortaleza, onde os três primeiros gráficos na ordem vertical são referentes ao treinamento para Paineiras e os outros três ao treinamento realizado para Usina Fortaleza.



Figura 16 – Hidrograma da vazão diária observada e estimada pela rede neural artificial, para a sub-bacia de Rive, para os ultimos dois anos dos dados de teste.



5.5 Resultados com separação do escoamento superficial e subterrâneo

A vazão utilizada neste trabalho para este teste para Paineiras foi separada em duas, sendo uma referente ao escoamento superficial e outra referente ao subterrâneo, utilizando o programa computacional SepHidro. Assim como foi realizado nos testes anteriores, os modelos de entradas da rede foram testados para ambas as vazões. Os modelos de entrada que melhor simularam as vazões superficial e subterrânea tiveram como entrada as seguintes precipitações, (Pt, Pt-1, Pt-2, Pt-3, Pt-4, Pt-5, P30) e (P60, P90), respectivamente. Os modelos para qSup e qSub foram escolhidos por apresentar o menor RMSE de 0,005 e 0,004 m³ s⁻¹ km⁻² respectivamente. Sendo os mesmos treinados para Paineiras e testado nas outras onze subbacias. (Figura 17 e Tabela 6).



Figura 17 – Diferentes combinações de dados de entrada de precipitação testados para estimar a vazão na sub-bacia de Paineiras.

Tabela 6 – Diferentes combinações de dados de entrada testados para precipitação menos evapotranspiração para estimar a vazão na sub-bacia de Paineiras.

Entradas	RMSE (m ³ . s ⁻¹ . km ⁻²)
P30	0.006
P60	0.005
P90	0.005
P30, P60	0.005
P30, P090	0.005
P60, P90	0.004
P30, P60 P90	0.004

Na Tabela 7 estão dispostos os valores dos critérios de avaliação de desempenho para o escoamento superficial (qSup) e subterrâneo (qSub) para as doze sub-bacias, na Figura 18 e 19 vê-se a dispersão dos dados em torno da reta para (qSup) (qSub) e na Figura 20, vê-se o hidrograma da vazão observada e estima para qSup e qSub. Ao analisar a tabela percebe-se que os modelos apresentaram resultados satisfatórios na simulação da vazão, tanto para qSup como para qSub. Contudo, observa-se que a simulação de qSup apresentou melhor desempenho do que para qSub, na bacia de Paineiras, com valores de NSE de 0,878 para qSup e de 0,736 para qSub.

O mesmo fato ocorrido nos outros testes sobre as bacias de menores áreas de drenagens pôde ser visto também nos resultados obtidos para qSup e qSub. Ao contrário do que foi citado anteriormente, onde qSup foi superior a qSub nos resultados para Paineiras, neste caso das bacias com áreas menores, como por exemplo, Lajinha e Usina fortaleza, qSub teve resultados superiores, com valores de NSE de 0,640 e 0,428, respectivamente. De modo geral, os testes feitos nas outras onze sub-bacias, com os dados treinados para Paineiras, apresentaram valores de critérios de desempenho melhores para qSub.

Tabelas 7 – Critérios de avaliação de desempenho para qSup e qSub para as doze sub-bacias.

Sub-		qSup			qSub				
bacia	RMSE*	MBE*	NSE	r²	RMSE*	MBE*	NSE	r ²	
1	0,004	0,000	0,878	0,879	0,003	0,000	0,736	0,738	
2	0,009	0,000	0,557	0,564	0,005	0,001	0,598	0,615	
3	0,010	-0,001	0,607	0,612	0,004	0,000	0,652	0,669	
4	0,012	-0,002	0,555	0,571	0,004	-0,001	0,686	0,719	
5	0,010	0,000	0,431	0,459	0,004	0,001	0,642	0,670	
6	0,012	-0,001	0,493	0,497	0,004	-0,001	0,628	0,641	
7	0,012	-0,001	0,429	0,436	0,004	0,001	0,572	0,621	
8	0,011	0,000	0,436	0,459	0,005	-0,002	0,525	0,625	
9	0,014	-0,001	0,330	0,342	0,004	0,000	0,640	0,642	
10	0,011	0,000	0,344	0,409	0,009	-0,004	0,056	0,247	
11	0,038	-0,012	0,219	0,404	0,013	-0,008	0,210	0,570	
12	0,019	-0,004	0,318	0,366	0,007	-0,004	0,428	0,626	

*Unidade: $m^3.s^{-1}.km^{-2}$.

Nas figuras 18, 19 e 20 são evidenciados os fatos mencionados anteriormente. Para a sub-bacia de Paineiras observa-se que qSup apresentou melhores resultados apresentando um r² de 0,879, porém quando analisa Usina Fortaleza que é a sub-bacia com menor área de drenagem, os resultados se apresentam-se ligeiramente melhor para qSub com um r² de 0,626.

Figura 18 – Gráficos de dispersão para qSup para as sub-bacias Paineiras, Rive e Usina Fortaleza, onde os dois primeiros gráficos correspondem aos dados de teste e dados totais para Paineiras e os outros dois gráficos aos dados totais para Rive e Usina Fortaleza.



Paineiras

Figura 19 – Gráficos de dispersão para qSub para as sub-bacias Paineiras, Rive e Usina Fortaleza, onde os dois primeiros gráficos correspondem aos dados de teste e dados totais para Paineiras e os outros dois gráficos aos dados totais para Rive e Usina Fortaleza.



Paineiras

Figura 20 – Hidrograma da vazão diária observada e estimada pelas redes neurais artificiais, para qSup (a) e qSub (b) para a sub-bacia de Paineiras, para os ultimos dois anos dos dados de teste.



Após a análise da separação da vazão em superficial e subterrânea, a mesma foi unida novamente, obtendo-se a vazão total. A realização deste teste teve a intenção de verificar se a simulação com vazões separadas seria mais eficiente.

A performance em termos de RMSE, bem como outros quatro critérios de avaliação de desempenho estão dispostos na Tabela 8. Como se pode ver, o modelo apresentou resultados satisfatórios (RMSE de 0,005 e NSE de 0,902). Assim como ocorreu nos outros testes realizados, aqui também houve um depreciação dos resultados para as sub-bacias de menor área de drenagem.

Sub-		Sem separa	ção			Com separação				
bacia	RMSE*	MBE*	NSE	r ²	RMSE*	MBE*	NSE	r ²		
1	0,006	0,000	0,861	0,861	0,005	0,000	0,902	0,903		
2	0,010	0,000	0,645	0,651	0,010	0,001	0,677	0,682		
3	0,011	-0,001	0,675	0,677	0,011	0,000	0,700	0,702		
4	0,013	-0,003	0,628	0,653	0,013	-0,003	0,652	0,676		
5	0,011	0,001	0,541	0,567	0,010	0,001	0,583	0,601		
6	0,013	-0,002	0,590	0,599	0,012	-0,001	0,622	0,628		
7	0,012	0,001	0,554	0,558	0,012	0,001	0,573	0,576		
8	0,013	-0,002	0,514	0,554	0,012	-0,002	0,563	0,591		
9	0,015	-0,001	0,490	0,494	0,013	0,002	0,490	0,504		
10	0,016	-0,004	0,307	0,417	0,015	-0,004	0,337	0,434		
11	0,045	-0,020	0,228	0,525	0,044	-0,019	0,232	0,515		
12	0,021	-0,008	0,395	0,506	0,021	-0,008	0,398	0,512		

Tabelas 8 – Critérios de avaliação de desempenho para Paineiras e para as onze sub-bacias.

*Unidade: $m^3.s^{-1}.km^{-2}$.

Em relação aos resultados obtidos com a separação e sem separação, a Tabela 8 apresenta uma comparação entre ambos os casos. Para o teste realizado para Paineiras sem separar a vazão, vê-se que os valores de RMSE e NSE foram melhores quando comparados com o teste que considerou a vazão sem separação, que apresentou valores de 0,006 e 0,861 m³.s⁻¹.km⁻², respectivamente.

Na Figura 21 e 22 são apresentados gráficos de dispersão e um hidrograma da vazão para ambos os testes para as sub-bacias de Paineiras, Rive e Usina Fortaleza. Pode-se ver que o coeficiente de determinação foi satisfatório para ambos os testes, a exemplo das sub-bacias de Paineiras, Rive e Usina Fortaleza, que apresentaram valores de 0,903, 0,676 e 0,512,

respectivamente, para o teste com separação da vazão, e 0,831, 0,653 e 0,506 para o teste em que não se separou a vazão.

De modo geral, o teste que separou e depois juntou novamente a vazão apresentou resultados melhores (Figura 21 e 22). Porém, analisando os testes, vê-se que a diferença entre os resultados são mínimas, e por isso não se indica separar a vazão, visto que são mais testes e análises a serem realizadas para se obter ganhos mínimos.



Figura 21 – Gráficos de dispersão para os testes de separação e junção da vazão e vazão total para as sub-bacias Paineiras, Rive e Usina Fortaleza.

Figura 22 – Hidrograma da vazão diária observada e estimada pelas redes neurais artificiais, da separação e junção da vazão (a) e vazão total (b) para a sub-bacia Paineira, para os ultimos dois anos dos dados de teste.



6 CONCLUSÕES

Este estudo propôs investigar a técnica de redes neurais artificiais como método para a simulação da vazão diária para a bacia hidrográfica do rio Itapemirim, tendo-se chegado às seguintes conclusões:

- As RNA's foram capazes de acompanhar a tendência dos dados de vazão observados, sendo considerada eficaz para simular o processo chuva-vazão na bacia hidrográfica do rio Itapemirim.
- Os ganhos para a simulação da vazão foram mínimos quando adicionada a variável evapotranspiração como entrada na rede.
- Os dados treinados para Paineiras e Rive, quando testados nas outras sub-bacias de áreas de drenagem menores, apresentaram resultados insatisfatórios. Porém, de modo geral, o teste para Rive apresentou resultados melhores para as sub-bacias de menor área.
- Os resultados para qSup foram melhores que qSub para os dados de teste para Paineiras, para as outras sub-bacias de menor área qSub obteve resultados melhores.
- Os ganhos para simulação da vazão diária quando a mesma foi separada em qSup e qSub foram mínimos quando comparados com a vazão total (q).

REFERÊNCIAS

ANA - AGÊNCIA NACIONAL DE ÁGUAS. Sistema de Informações Hidrológicas – Hidroweb. Disponível em: . Acesso em: julh. 2016.

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 1 dez. 2013.

ANMALA, J.; ZHANG, B.; GOVINDARAJU, R. S. Comparison of ANNs and Empirical Approaches for Predicting Watershed Runoff. **Journal of Water Resources Planning and Management**, v. 126, n. 3, p. 156–166, maio 2000.

BARATTI, R. et al. River ow forecast for reservoir management through neural networks. **Neurocomputing**, v. 55, p. 421–437, 2003.

BEHZAD, M. et al. Expert Systems with Applications Generalization performance of support vector machines and neural networks in runoff modeling. **Expert Systems with Applications**, v. 36, n. 4, p. 7624–7629, 2009.

BESAW, L. E. et al. Advances in ungauged streamflow prediction using artificial neural networks. **Journal of Hydrology**, v. 386, n. 1-4, p. 27–37, 2010.

BEVEN, K. Changing ideas in hydrology - The case of physically-based models. **Journal of Hydrology**, v. 105, n. 1-2, p. 157–172, 1989.

CHANG, F. et al. Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control. **Journal of Hydrology**, v. 517, p. 836–846, 2014.

DANANDEH MEHR, A. et al. Successive-station monthly streamflow prediction using different artificial neural network algorithms. **International Journal of Environmental Science and Technology**, v. 12, n. 7, p. 2191–2200, 21 jul. 2014.

FUKUNAGA, D. C. Application of the SWAT hydrologic model to a tropical watershed at Brazil. **Catena**, p. 206–2013, 2015.

GARDNER, M. .; DORLING, S. . Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences.

Atmospheric Environment, v. 32, n. 14-15, p. 2627–2636, ago. 1998.

GHUMMAN, A. R. et al. Runoff forecasting by artificial neural network and conventional model. **Alexandria Engineering Journal**, v. 50, n. 4, p. 345–350, dez. 2011.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, 1994.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001, p. 900.

HEBB, D. O. The first stage of perception: growth of the assembly. The Organization of Behavior, n. 4, p. 60–78, 1949.

MENDES, H. A. Modelo para otimização da calibração dos parâmetros do modelo hidrológico dhsvm jerônimo monteiro - ES. 2016. 140 f. Tese (Doutorado em Ciências Florestais) — Universidade Federaldo Espírito Santo. 2016.

HUO, Z. et al. Integrated neural networks for monthly river flow estimation in arid inland basin of Northwest China. **Journal of Hydrology**, v. 420-421, p. 159–170, fev. 2012.

IEMA - Instituto Estadual de Meio Ambiente e Recursos Hídricos.
Ortofotomosaicos 2007/2008. Escala 1:35.000, resolução espacial de 1m, georeferenciado no Sistema de Projeção UTM, Datum WGS 84, Zona 24S.Vitória: Instituto Estadual de Meio Ambiente e Recursos Hídricos, 2007.

JAIN, A.; KUMAR, A. M. Hybrid neural network models for hydrologic time series forecasting. **Applied Soft Computing Journal**, v. 7, n. 2, p. 585–592, 2007.

KAGODA, P. A. et al. Application of radial basis function neural networks to short-term streamflow forecasting. **Physics and Chemistry of the Earth**, v. 35, n. 13-14, p. 571–581, 2010.

KASHANI, M. H.; GHORBANI, M. A.; DINPASHOH, Y. Comparison of Volterra Model and Artificial Neural Networks for Rainfall – Runoff Simulation. **Natural**

Resources Research, v. 23, n. 3, 2014.

KENTEL, E. Estimation of river flow by artificial neural networks and identification of input vectors susceptible to producing unreliable flow estimates. **Journal of Hydrology**, v. 375, n. 3-4, p. 481–488, set. 2009.

KIŞI, Ö. Streamflow Forecasting Using Different Artificial Neural Network Algorithms. **Journal of Hydrologic Engineering**, v. 12, n. 5, p. 532–539, set. 2007.

LEAHY, P.; KIELY, G.; CORCORAN, G. Structural optimisation and input selection of an artificial neural network for river level prediction. **Journal of Hydrology**, v. 355, n. 1-4, p. 192–201, 2008.

MAIER, H. R.; DANDY, G. C. Neural networks for the prediction and forecasting of water resources variables: A review of modelling issues and applications. **Environmental Modelling and Software**, v. 15, n. 1, p. 101–124, 2000.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, 1943.

MIRANDA, A. C. R. et al. Métodos de Separação dos Escoamentos Superficial Direto e Subterrâneo: Estudo de Caso para a Bacia do Rio das Velhas. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 2, p. 169–181, 2014.

MORIASI, D. N. et al. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **Transactions of the ASABE**, v. 50, n. 3, p. 885–900, 2007.

MUTLU, E. et al. Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed. **Hydrological Processes**, v. 22, n. 26, p. 5097–5106, 30 dez. 2008.

NOURANI, V.; KISI, Ö.; KOMASI, M. Two hybrid Artificial Intelligence approaches for modeling rainfall–runoff process. **Journal of Hydrology**, v. 402, n. 1-2, p. 41–59, maio 2011.

RENNÓ, C. D.; SOARES, J. V. Modelos Hidrológicos para Gestão Ambiental. Programa de Ciência e Tecnologia para Gestão de Ecossistemas - Ação "Métodos, modelos e geoinformação para a gestão ambiental", p. 65, 2000.

REZAEIANZADEH, M. et al. Assessment of a conceptual hydrological model and artificial neural networks for daily outflows forecasting. **International Journal of Environmental Science and Technology**, v. 10, n. 6, p. 1181– 1192, 2013.

REZAEIAN ZADEH, M. et al. Daily Outflow Prediction by Multi Layer Perceptron with Logistic Sigmoid and Tangent Sigmoid Activation Functions. **Water Resour Manage**, n. September, p. 2673–2688, 2010.

REZAEIAN ZADEH, M.; TABARI, H.; ABGHARI, H. Prediction of monthly discharge volume by different artificial neural network algorithms in semi-arid regions. **Arabian Journal of Geosciences**, v. 6, n. 7, p. 2529–2537, 12 jul. 2012.

RIAD, S. et al. Rainfall-runoff model usingan artificial neural network approach. **Mathematical and Computer Modelling**, v. 40, n. 7-8, p. 839–846, out. 2004.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, 9 out. 1986.

SARMENTO, J. F. modelagem de séries hidrológicas através de redes de neurônios. **Revista Brasileira de Recursos Hídricos**, 1996.

SEDKI, A.; OUAZAR, D.; EL MAZOUDI, E. Evolving neural network using real coded genetic algorithm for daily rainfall-runoff forecasting. **Expert Systems** with Applications, v. 36, n. 3 PART 1, p. 4523–4527, 2009.

SENTHIL KUMAR, A. R. et al. Rainfall-runoff modelling using artificial neural networks: comparison of network types. **Hydrological Processes**, v. 19, n. 6, p. 1277–1291, 15 abr. 2005.

SHAMSELDIN, A. Y. Application of a neural network technique to rainfall-runoff modelling. **Journal of Hydrology**, v. 199, n. 3-4, p. 272–294, 1997.

SOUSA, W. S.; SOUSA, F. A. S. DE. Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó. **Revista Brasileira de**

Engenharia Agrícola e Ambiental, v. 14, n. 2, p. 173–180, fev. 2010.

SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. A data-driven algorithm for constructing artificial neural network rainfall-runoff models. **Hydrological Processes**, v. 16, n. 6, p. 1325–1330, 30 abr. 2002.

TOTH, E.; BRATH, A. Multistep ahead streamflow forecasting: Role of calibration data in conceptual and neural network modeling. **Water Resources Research**, v. 43, n. 11, p. 1–11, 2007.

TUCCI, C. E. M. **Modelos hidrológicos**. 2. ed. Porto alegre: UFRGS, 2005. p. 678.

VERTESSY, R. A. et al. Predicting water yield from a mountain ash forest catchment using a terrain analysis based catchment model. **Journal of Hydrology**, v. 150, n. 2-4, p. 665–700, 1993.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980 – 2013). **International Journal of Climatology**, v. 2659, n. October 2015, p. 2644–2659, 2016.

YASEEN, Z. M. et al. Artificial intelligence based models for stream-flow forecasting: 2000 – 2015. **Journal of Hydrology**, v. 530, p. 829–844, 2015.

ZEALAND, C. M.; BURN, D. H.; SIMONOVIC, S. P. Short term streamflow forecasting using artificial neural networks. **Journal of Hydrology**, v. 214, n. May 1998, p. 32–48, 1999.

ZHANG, G.; EDDY PATUWO, B.; HU, M. Y. Forecasting with artificial neural networks: **International Journal of Forecasting**, v. 14, n. 1, p. 35–62, mar. 1998.

ZHANG, G.; HU, M. Y. Neural network forecasting of the British Pound/US Dollar exchange rate. **Omega**, v. 26, n. 4, p. 495–506, ago. 1998.