



**UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE TECNOLOGIA  
CURSO DE GRADUAÇÃO EM ENGENHARIA AMBIENTAL  
TRABALHO DE CONCLUSÃO DE CURSO**

**PREVISÃO DE VAZÕES MÉDIAS DIÁRIAS EM RIOS COM DIFERENTES  
ÁREAS DE DRENAGEM UTILIZANDO REDES NEURAIS ARTIFICIAIS**

**SHARA SONALLY OLIVEIRA DE SOUSA**

**João Pessoa-PB**

**Dezembro de 2018**

SHARA SONALLY OLIVEIRA DE SOUSA

PREVISÃO DE VAZÕES MÉDIAS DIÁRIAS EM RIOS COM DIFERENTES  
ÁREAS DE DRENAGEM UTILIZANDO REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado  
como pré-requisito para obtenção do título de  
Bacharel em Engenharia Ambiental pela  
Universidade Federal da Paraíba.

Orientador: Prof. Gustavo Barbosa Lima da Silva

João Pessoa-PB

Dezembro de 2018

S725p Sousa, Shara Sonally Oliveira de.

Previsão de Vazões Médias Diárias em Rios com Diferentes Áreas de Drenagem Utilizando Redes Neurais Artificiais / Shara Sonally Oliveira de Sousa. - João Pessoa, 2019.

63 f. : il.

Orientação: Prof Gustavo Barbosa Lima da Silva Silva.

Monografia (Graduação) - UFPB/CT.

1. Previsão de Vazão. 2. Bacia Hidrográfica. 3. Redes Neurais Artificiais. I. Silva, Prof Gustavo Barbosa Lima da Silva. II. Título.

UFPB/BC

## FOLHA DE APROVAÇÃO

**SHARA SONALLY OLIVEIRA DE SOUSA**

### **PREVISÃO DE VAZÕES MÉDIAS DIÁRIAS EM RIOS COM DIFERENTES ÁREAS DE DRENAGEM UTILIZANDO REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado em 12/12/2018 perante a seguinte Comissão Julgadora:

Gustavo Barbosa da Silva  
Gustavo Lima Barbosa da Silva  
Departamento de Engenharia Civil e Ambiental do Curso de  
Engenharia Ambiental/UFPB

Aprovado

Ana Claudia Fernandes Medeiros Braga  
Ana Claudia Fernandes Medeiros Braga  
UFPB

Aprovado

Karine Cristiane de Oliveira Souza  
Karine Cristiane de Oliveira Souza  
UFPB

Aprovado

Elisângela M. R. Rocha  
Profa. Elisângela Maria Rodrigues Rocha  
Coordenadora do Curso de Graduação em Engenharia Ambiental

**Elisângela M. R. Rocha**  
Coordenadora de Eng. Ambiental  
CT/UFPB – Mat. 1821373

## **AGRADECIMENTOS**

À Deus, porque até aqui me sustentou;

Aos meus pais, **Júlio e Rosenda**, pelo apoio nas minhas decisões, pela paciência, pelo incentivo e por todo amor e carinho durante esta etapa da minha vida;

Aos meus irmãos, **Júlio e Ítalo**, pelo amor, carinho, atenção e por terem feito meus dias mais alegres;

À minha avó materna, **Maria da Salete**, pelo apoio nas minhas decisões, pelo incentivo a terminar curso e pela grande ajuda;

À minha avó paterna, **Zuleide Barros**, por ter me recebido em sua casa no início do curso e ter cuidado de mim, junto ao meu pai;

Ao meu Professor Orientador, **Gustavo Lima**, por ter me aceitado como orientanda, pela paciência e disponibilidade;

À professora e Coordenadora do Curso, **Elisângela Maria**, por ser minha professora orientanda no PIBIC, pela grande ajuda e ensinamentos sobre pesquisa;

À **Universidade Federal da Paraíba**, pela oportunidade de viajar representando a instituição na apresentação de trabalhos acadêmicos;

Aos grandes amigos que fiz durante o curso, **Amanda Gondim, Brener Gomes, Jonathan Antunes, Lysanne Souza, Raqueline Caldas, Thales Raonny, Jéssika Neles, Carolina Barros, Matheus Rodrigues**, por todos os momentos bons que se passaram dentro e fora da universidade;

Aos meus amigos da escola, **Ângela Regina, Bruna Lima, Ericksson Gadelha, Juliana Lacerda, Magda Ribeiro, Nathana Vital**, por me acompanharem nesta etapa do lado de fora da universidade;

Aos amigos que fiz no estágio pela SUDEMA, **Rubens Bruno, Itallo Harlam, Laryssa Viana, José Humberto, Paulo Roberto, Natália Gonzalez, Dona Emicléia, Verônica, Quintino, José Medeiros e José Silvestre**, por todos os bons momentos no melhor setor da SUDEMA;

A todos que fizeram parte da minha vida acadêmica, de forma direta ou indireta, agradeço!

*“E que amá-lo de todo o coração, e de todo o entendimento, e de toda a alma, e de todas as forças, e amar o próximo como a si mesmo, é mais do que todos os holocaustos e sacrifícios.”*

**Marcos 12:33**

## **LISTA DE SIGLAS**

ANA	Agência Nacional de Águas
ASCE	American Society of Civil Engineers
CBHSF	Comitê da Bacia Hidrográfica do Rio São Francisco
CE	Coeficiente de Eficiência
CHESF	Companhia Hidrelétrica do São Francisco
LM	Algoritmo de Levenberg-Marquardt
MARE	Erro Médio Absoluto Relativo
MLP	Perceptron Multicamadas – Multilayer Perceptron
MMA	Ministério do Meio Ambiente
MME	Ministério de Minas e Energia
ONS	Operador Nacional do Sistema
PL	Função de ativação Linear
RMSE	Raiz do Erro Quadrático Médio
RNA	Rede Neural Artificial
TS	Função de ativação Tangente Sísmoide
TL	Função de ativação Linear
UFPB	Universidade Federal da Paraíba

## Sumário

1. INTRODUÇÃO .....	10
1.3. Objetivos .....	12
<b>1.3.1. Objetivo Geral .....</b>	<b>12</b>
<b>1.3.2. Objetivos específicos .....</b>	<b>12</b>
2. FUNDAMENTAÇÃO TEÓRICA .....	13
2.1. Modelagem Hidrológica .....	13
2.2. Redes Neurais Artificiais .....	14
<b>2.2.1. Conceitos .....</b>	<b>14</b>
<b>2.2.2. Histórico .....</b>	<b>16</b>
<b>2.2.3. Neurônio.....</b>	<b>18</b>
<b>2.2.4. Funções de Ativação.....</b>	<b>19</b>
<b>2.2.5. Arquitetura .....</b>	<b>20</b>
<b>2.2.7. Treinamento.....</b>	<b>24</b>
<b>2.3.8. Aplicações.....</b>	<b>33</b>
<b>2.3.9. Vantagens e Desvantagens.....</b>	<b>34</b>
3. METODOLOGIA.....	36
3.2. Área de Estudo.....	37
3.3. Modelos de Previsão baseados em RNA .....	39
<b>3.3.1. Tipo de Rede .....</b>	<b>39</b>
<b>3.3.2. Padronização e Preparação dos dados .....</b>	<b>39</b>
<b>3.3.3. Arquitetura .....</b>	<b>40</b>
<b>3.3.4. Função de Ativação .....</b>	<b>41</b>
<b>3.3.5. Treinamento e Verificação.....</b>	<b>41</b>
<b>3.3.6. Critérios de parada.....</b>	<b>41</b>
<b>3.3.7. Avaliação da Performance.....</b>	<b>42</b>
4. RESULTADOS .....	43
5. CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES .....	58
REFERÊNCIAS BIBLIOGRÁFICAS .....	59
ANEXO 1 .....	63

## RESUMO

Devido à necessidade da previsão de vazões para melhor gestão dos recursos hídricos, utiliza-se a modelagem hidrológica como ferramenta para geração de vazões afluentes a reservatórios. Um dos modelos que vem se destacando com bom grau de precisão na previsão de vazões são as Redes Neurais Artificiais (RNA), sendo este considerado um modelo empírico com memória e não linear desenvolvido, composto de elementos computacionais chamados neurônios, os quais são arranjados em padrões semelhantes a redes neurais biológicas. Para identificar as relações lineares e não lineares entre as variáveis de entrada e saída, utilizam-se funções de ativação. A maneira pela qual os neurônios de uma rede neural são estruturados está ligada com o algoritmo de aprendizagem utilizado para treinar a rede, ou seja, sua arquitetura. Para o treinamento da rede tem-se o “*backpropagation*” como algoritmo mais utilizado. Este trabalho foi realizado com o objetivo de analisar a eficiência das RNAs em bacias com diferentes áreas de drenagem, desde muito pequenas a grandes áreas, onde analisou-se o comportamento do processo chuva-vazão a partir das vazões regularizadas dos reservatórios de Sobradinho e Três Marias, e da estação 73015 do rio Keer, situada no noroeste da Inglaterra. Foram realizadas previsões para vazões diárias com horizonte de 1, 3 e 5 dias. Para avaliar a performance do modelo, além da análise dos gráficos, foram utilizados 3 parâmetros estatísticos, sendo eles: o erro quadrático médio (RSME), o erro absoluto relativo (MARE) e o coeficiente de eficiência (CE). Quanto aos resultados, observou-se melhores resultados na previsão de 1 dia, ou seja, o modelo apresenta-se mais eficiente em horizontes de previsões menores. O reservatório de Sobradinho apresentou o melhor desempenho nas previsões, com um erro quadrático médio , de 125,65, maior que o reservatório de Três Marias, com 63,62. Já para o Rio Keer, o RSME apresentado foi o menor entre os três casos, com 0,58. Tratando-se da eficiência do modelo, Sobradinho apresentou resultados mais próximos de 1, com 0,99, enquanto Três Marias e o Rio Keer, 0,93 e 0,40, respectivamente. Tratando-se do MARE, Sobradinho apresentou os menores resultados, com 0,012. Já Três Marias e o rio Keer, obtiveram 0,34 e 0,48, respectivamente. Conclui-se assim, que o reservatório de sobradinho apresenta o melhor desempenho ao utilizar o RNA como modelo previsão, devido ao comportamento das vazões em bacias com grandes áreas de drenagem apresentar uma resposta mais lenta ao decorrer do fluxo, o que não ocorre em bacias com área de drenagem pequena, como no caso do rio Keer, que responde com rapidez às precipitações e gera vazões de pico rapidamente, sendo difícil simular tal comportamento sem apresentar grandes erros.

**Palavras Chave:** Previsão de Vazão; Bacia Hidrográfica; Redes Neurais Artificiais.

## 1. INTRODUÇÃO

A água é um recurso natural renovável indispensável para manutenção da vida no planeta, sendo utilizada para atender as mais diversas atividades, como o consumo humano, os processos industriais, a irrigação, a dessentença animal e a geração de energia. A distribuição desse recurso ocorre de forma em que a maior parte encontra-se como água salgada, com 97,5%, e 2,5% como água doce, sendo essa última subdividida em geleiras, rios, lagos e águas subterrâneas (GLEICK, 1993).

Segundo Guedes (2011), os volumes de água armazenados são subutilizados, pois deveriam propiciar vazões regularizadas visando o atendimento de demandas e permitindo o equilíbrio entre a disponibilidade natural e a necessidade hídrica. Dessa forma, para que se tenha o uso racional dos recursos hídricos, é necessário aliar o exercício das atividades econômicas e sociais visando à sustentabilidade, ou seja, é necessário que haja a gestão desses recursos.

No estudo dos recursos hídricos, o processo de transformação de chuva em vazão é considerado um dos mais difíceis de serem entendidos, devido ao número de variáveis que se modificam no tempo e no espaço. O resultado da avaliação deste processo se torna uma ferramenta que permite o gerenciamento de maneira racional destes recursos (MACHADO, 2005). Portanto, face à complexidade do ambiente de corpos d'água naturais, surge a necessidade de aplicação de modelos para estudos, projetos e auxílio à gestão de recursos hídricos (AMARAL, 2003).

Modelos consistem em representações que, de forma simplificada, são criados com o intuito de facilitar o entendimento da realidade (RENNÓ, 2003). Essas representações são construídas com base em hipóteses sobre o comportamento e a estrutura de um sistema físico. No âmbito dos recursos hídricos, utiliza-se o modelo hidrológico como uma ferramenta extremamente útil que permite, através da modelagem matemática dos processos, representar, entender e simular o comportamento do processo de transformação de chuva-vazão em uma bacia hidrográfica (TUCCI, 1998). Sendo assim, os modelos se apresentam como uma importante ferramenta no auxílio da tomada de decisão na gestão hídrica.

Nos últimos anos, um dos modelos que vem se destacando na simulação de vazões são as Redes Neurais Artificiais (RNA), um modelo empírico que não necessita de levantamento de dados, como tipo do solo, seu uso e ocupação e considerações físicas. Porém, é definido por uma equação matemática, no qual consiste em estabelecer uma relação entre as variáveis de entrada e saída sem considerar as leis físicas que governam o processo natural de transformação de chuva em vazão (ASCE Task Committee, 2000b; IMRIE et al., 2000; HAYKIN, 2001; MACHADO, 2005).

Uma RNA é definida como uma estrutura de elementos conhecidos por neurônios distribuídos espacialmente e conectados, sendo esta representada por uma função. Dos mais diversos tipos de RNA, os mais utilizados são as RNAs *Multilayer Perceptron* – MLP (*Perceptron* Multicamadas). Os neurônios são distribuídos em diferentes camadas com os dados disponíveis em uma propagação única. Comumente, têm-se as RNAs do tipo MLP possuem três camadas, sendo a primeira a camada de entrada, uma camada intermediária e uma camada de saída.

Na gestão de recursos hídricos é necessário se ter uma simulação de cenários válida para tomada de decisões. No que diz respeito à previsão de vazões, há a necessidade de se achar a melhor forma de representar o comportamento da transformação de chuva em vazão. Porém, cada curso de água apresenta uma resposta diferente devido às variações climáticas periódicas, cheias de projeto e as demais características físicas da bacia hidrográfica. Assim, os modelos hidrológicos se apresentam como uma ferramenta desenvolvida para avaliação dos processos hidrológicos em diferentes escalas espaciais e temporais (SPRUILL et al, 2000). A escolha do modelo hidrológico para simulação do processo chuva-vazão depende da quantidade de dados disponíveis para descrever o processo e da variabilidade espacial.

As RNAs mostraram bons resultados na simulação de vazões diárias, onde se utiliza apenas dados de vazão para ajuste de dados em uma função, não necessitando da relação com os processos físicos envolvidos (SARLE, 1994; FLOOD & KARTMAN, 1994; ELSHORBAGY et al, 2000; RAMOS & GALVÃO, 2001; LIMA & FERREIRA FILHO, 2003; CHENG et al, 2005; SOUSA & SOUSA, 2006; BRAVO et al, 2008; GOMES et al, 2010; CRUZ et al, 2010; DEBASTIANI et al, 2016).

Porém, a eficiência da utilização deste modelo, no que diz respeito à variabilidade espacial não é conhecida. Desta forma, a análise do comportamento da vazão de rios principais, em bacias com diferentes escalas espaciais, é um importante objeto de pesquisa para avaliação da eficiência das RNA como ferramenta de gestão.

### **1.3. Objetivos**

#### **1.3.1. Objetivo Geral**

Avaliar o efeito da Previsão de Vazões Médias diárias em Rios com Diferentes Áreas de Drenagem Utilizando Redes Neurais Artificiais.

#### **1.3.2. Objetivos específicos**

- Avaliar, por meio de estatística descritiva, o desempenho das Redes Neurais Artificiais na previsão de vazões diárias, utilizando dados de vazão, em bacias hidrográficas com diferentes escalas espaciais;
- Analisar a influência do horizonte de previsão no desempenho das Redes Neurais.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1. Modelagem Hidrológica

Um problema ambiental real consiste em uma situação que envolve uma quantidade grande de variáveis, compreendendo desde uma variável espacial a uma variável temporal. Para melhor entendimento do fenômeno faz-se o uso de modelos matemáticos.

No que diz respeito aos processos hidrológicos, faz-se o uso dos chamados modelos hidrológicos para simulação. A compreensão da relação entre os fenômenos que envolvem o ciclo hidrológico permite ao homem simular o comportamento da água em bacias hidrográficas decorrente de alterações climáticas e do uso do solo. Dessa maneira, surge o conceito de simulação hidrológica, que pode ser entendido como a representação do comportamento do ciclo hidrológico por meio de equações matemáticas, onde a área de estudo é a bacia hidrográfica (BATISTA, 2009).

Segundo Sousa e Sousa (2010), modelos hidrológicos são uma das ferramentas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos, devido aos mecanismos climáticos que produzem precipitações aliados a fatores, como orografia da região, sistemas atmosféricos de médio e grande escalas e a proximidade do mar, resultam em forte variabilidade espaço-temporal das precipitações que podem gerar eventos extremos, como grandes cheias ou secas devastadoras. Os principais usos desse tipo de metodologia são: entender o comportamento dos fenômenos hidrológicos; análise de consistência e preenchimento de falhas de dados; previsão de vazão; dimensionamento e previsão de cenários de planejamento (LOU, 2010).

O que deve nortear a escolha de um modelo para simulação hidrológica é o objetivo do estudo, os dados disponíveis para o estudo e a familiaridade com o modelo. Segundo Tucci (1998), os modelos podem ser classificados em diferentes categorias, sendo elas: concentrado ou distribuído, estocástico ou determinístico e conceitual ou empírico. No caso do modelo concentrado, é desprezada a variabilidade espacial das variáveis hidrológicas, onde a precipitação torna-se apenas função do tempo. Já para o distribuído, as variáveis ou parâmetros dependem do espaço, sendo distribuídos em sub-bacias ou módulos. Modelos determinísticos são aqueles que produzem um mesmo

resultado para uma mesma condição inicial, não levando em consideração o conceito da probabilidade como no estocástico. Quanto à descrição dos processos, os modelos conceituais caracterizam-se por utilizar equações associadas a uma ou mais equações empíricas. Já os modelos empíricos, ajustam-se aos dados observados através de funções que não têm relação com os processos físicos envolvidos.

Fazendo uma análise segundo as vantagens e desvantagens, determina-se o tipo de modelo a ser aplicado para cada situação. Considerando o caso dos modelos determinísticos, é necessário levar em consideração as variáveis físicas da área de estudo, sendo incorporadas em equações empíricas e analíticas como, por exemplo, a capacidade de infiltração da água no solo. Contudo, as limitações de modelos hidrológicos estão associadas à quantidade e à qualidade dos dados hidrológicos, à dificuldade de formulação matemática de alguns fenômenos e à descrição da distribuição espacial das variáveis envolvidas (TUCCI, 1997).

No que se refere a modelos empíricos, têm-se que estes não incorporam as características físicas do espaço, porém analisam o comportamento dos dados e apresentam fácil adaptabilidade a novos dados, sem a necessidade de formulações estatísticas elaboradas e possuem menor custo (BALINI *et al*, 2003; OLIVEIRA *et al*, 2013). Nesse contexto, surge a metodologia das Redes Neurais Artificiais, sendo classificada como um modelo matemático empírico, com memória, ou seja, consegue armazenar e gravar dados, e não linear desenvolvido com base no funcionamento do cérebro humano (MACHADO, 2005).

## **2.2. Redes Neurais Artificiais**

### **2.2.1. Conceitos**

Uma rede neural artificial (RNA) é um modelo matemático empírico, com memória e não linear composto de elementos computacionais chamados neurônios, no qual são arranjados em padrões semelhantes a redes neurais biológicas (BALINI, 2000; MACHADO, 2005).

Uma célula neural biológica (Figura 1) é composta basicamente pelos dendritos, o corpo celular, o axônio e as terminações de axônio. As sinapses se comunicam por meio das ligações de entrada chamada de dendritos (MACHADO, 2005; GUEDES, 2011).

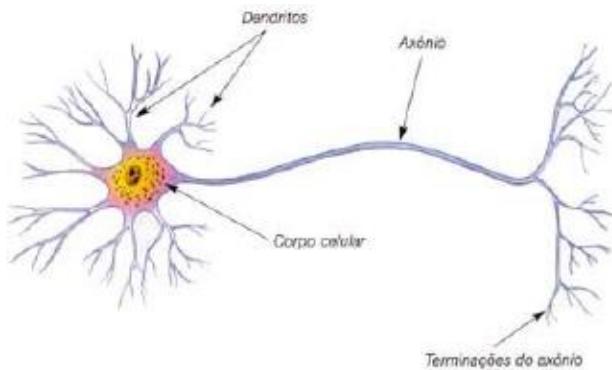


Figura 1- Neurônio Biológico. Fonte: MACHADO, 2005.

Assim como o cérebro humano é capaz de transmitir e armazenar informações por meio de impulsos nervosos entre os neurônios, as RNAs possuem conexões interneurais, representadas por pesos sinápticos, com função de armazenar e processar o conhecimento (HAYKIN, 1994). O conhecimento é adquirido pela rede a partir de registros das condições de entrada e saída de um processo qualquer, por meio de um processo de aprendizagem, que pode ser dirigido ou autônomo (LORENZI, A. *et al.*, 2017).

Segundo Haykin (1994), do ponto de vista estrutural, as RNAs podem ser classificadas como redes neurais estáticas ou como redes neurais dinâmicas. A principal diferença funcional entre as duas estruturas é a presença ou não de conexões que realimentam os neurônios presentes na arquitetura da rede. Entre essas estruturas, a mais utilizada é a rede neural multicamadas (*MultiLayerPerceptron-MLP*), na qual não existe dependência das saídas com seus valores passados, sendo, portanto, consideradas estáticas (BATISTA, 2009).

Segundo Honorato (2017), do ponto de vista matemático, as RNA correspondem a uma composição aditiva de funções pré-definidas, ponderada por parâmetros chamados pesos, capaz de representar o comportamento de uma curva qualquer, incluindo características não-lineares.

De modo geral, uma RNA funciona por meio da disseminação de estímulos entre suas camadas, onde a matriz dos pesos sinápticos vão modificando estes estímulos, gerando diferentes respostas (LORENZI, A. *et al*, 2017).

### 2.2.2. Histórico

As RNAs surgiram como primeiro modelo artificial de um neurônio biológico, resultado do trabalho de Warren McCulloch e Walter Pitts, em 1943. O pioneiro no trabalho, McCulloch, dedicou sua carreira para representar e modelar eventos no sistema nervoso. Neste trabalho, intitulado de “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, os autores relatam que os eventos neurais podem ser tratados por meio da lógica proposicional, onde o comportamento de cada rede pode ser descrito nos termos com adição de meios lógicos mais complicados que satisfaça certas condições (MCCULLOCH e PITTS, 1943; BRAGA *et al.*, 2007).

Em 1949, esse assunto veio a ser estudado novamente por Hebb no livro intitulado de “*The Organization of Behavior*”, no qual o autor apresenta uma teoria do comportamento que é baseada na fisiologia do sistema nervoso e faz uma tentativa de encontrar alguma comunidade biológica e concepções psicológicas. Hebb mostrou como a flexibilidade da aprendizagem de redes neurais é possibilitada por meio de variações dos pesos de entrada dos neurônios, onde esta teoria apresenta o aprendizado em neurônios biológicos baseado no reforço das ligações sinápticas entre neurônios excitados (HEBB, 1949).

Após quase 10 anos, Frank Rosenblatt demonstrou o novo modelo chamado “*perceptron*”, para lidar com o problema de reconhecimento de padrões. O modelo proposto por Rosenblatt possui três camadas. A primeira consiste em uma camada de unidades sensoriais e com conexões fixas, denominada *retina*. A camada seguinte é denominada de camadas de unidades ocultas, chamada de associativa, no qual recebe impulso da primeira camada. Para saída dos dados, têm-se a camada de saída, chamada de camada de *resposta* (BRAGA *et al.*, 2007).

Em 1960, Widrow e Hoff, incorporou o *leastmean-square* (LMS) utilizado para formular a RNA *Adaline* (*Adaptive Linear Element*) (MACHADO, 2005).

A primeira crítica real do “*Perceptron*” de Rosenblatt foi apresentada por Minsky e Selfridge em 1961, onde foi apontado que o modelo não poderia generalizar para a noção de paridade binária, muito menos fazer abstrações gerais. Mais tarde, as limitações computacionais foram colocadas em uma base sólida matemática no livro “*Perceptrons*”, por Minsky e Papert em 1969. Os Autores demonstraram que as redes *Perceptrons* simples eram incapazes de resolver problemas não linearmente separáveis (BRAGA *et al.*, 2007; HAYKIN, 2009). O principal argumento de Minsky e Papert

seria de que o problema do crescimento explosivo, do espaço ocupado e o tempo requerido para a solução de problemas complexos afetaria as RNAs. Outro argumento foi que, embora existisse um algoritmo de aprendizado, que garantia a convergência para modelos com uma única camada de neurônios, para o caso do perceptron original, o mesmo não ocorre para redes com mais de uma camada (BRAGA *et al.*, 2007; HAYKIN, 2009). Após esta última publicação, nos anos 70, o assunto deixou de ser pauta da comunidade científica e pouquíssimos pesquisadores continuaram trabalhando na área.

Nos anos 80, especificamente no ano de 1982, foi publicado um artigo por John Hopfield relatando as propriedades associativas das RNAs, fazendo uma analogia entre redes decorrentes e sistemas físicos, abrindo espaço para utilização de teorias de corrente da Física. Mais tarde, o algoritmo da retropropagação do erro foi novamente trabalhado por Rumelhart *et al.* (1986). Eles constaram que o procedimento ajusta repetidamente os pesos das conexões na rede, de modo a minimizar uma medida da diferença entre o vetor de saída real da rede, o vetor de saída desejado. Como resultado dos ajustes de peso, as unidades ocultas internas que não fazem parte da entrada ou saída passam a representar recursos importantes do domínio da tarefa e as regularidades na tarefa são capitalizadas pelas interações dessas unidades.

Desde a volta do estudo das RNAs nos anos 1980 até os dias atuais, a área passou por diversas transformações, com proposições de variações do algoritmo *back-propagation* para que tenha maior velocidade (BRAGA *et al.*, 2007).

Vários Autores já aplicaram a técnica das RNA para análise de fenômenos hidrológicos. Honorato (2017) utilizou as RNA para previsão de vazões diárias e mensais juntamente com modelos híbridos de transformadas Wavelet, ao comparar as RNAs com a associação RNA-Wavelet, o autor obteve bom desempenho na previsão diária para o horizonte de 1 dia utilizando apenas RNA; Batista (2009) utilizou para previsão de vazão do Rio Grande, afluente do reservatório da usina hidrelétrica de Camargos/MG, onde observou o bom desempenho das RNAs na associação de padrões e na generalização de padrões desconhecidos; Balini (2000) realizou a previsão de vazões utilizando modelos de séries temporais, RNA e Redes Neurais Nebulosas e obteve um bom desempenho com previsão para 1 dia à frente.

### 2.2.3. Neurônio

A unidade básica do processamento de uma RNA é denominada neurônio artificial. Esse elemento transmite a ideia matemática de simular o comportamento de uma célula neural biológica, ou seja, ela recebe estímulos do meio ou de outro neurônio através dos “m” terminais de entrada, representada pelos dendritos (Figura 2). Os estímulos, ou sinapses, são medidos pelos pesos  $w_{kj}$ , que determinam o grau em que o neurônio deve considerar o sinal da conexão.

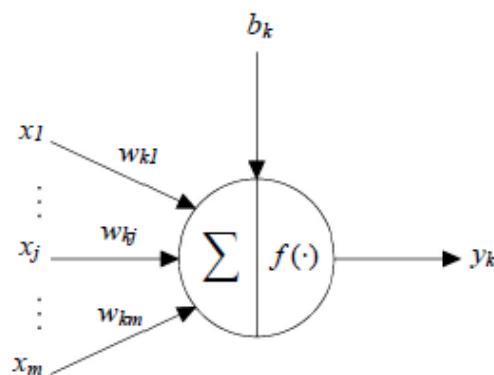


Figura 2 - Neurônio Artificial  $k$ , o operador  $\sum$  representa a soma ponderada das entradas e  $f(\cdot)$  a função de ativação. Fonte: HONORATO, 2017.

Dessa maneira, o efeito de uma sinapse é dado por  $x_j w_{kj}$ . Para representar a transferência do estímulo seguinte, o neurônio faz a soma ponderada ( $\sum$ ) dos estímulos e aplica na função de ativação ( $f(\cdot)$ ) (Equação 1). (BRAGA *et al.*, 2007).

$$Y_k = (\sum_{j=1}^m x_j w_{kj} + b_k) \quad (1)$$

Segundo Guedes (2011), a célula de rede é constituída, basicamente, pelos pesos, somatório e função de transferência. O conjunto de pesos atribui às RNAs a capacidade de aprendizado, simulando a forma de entrada de dados em uma célula neural biológica.

Portanto, considera-se que um neurônio artificial possui três elementos básicos (HAYKIN, 2009):

- Um conjunto de sinapses, ou conexões no qual são caracterizados por um peso próprio. O sinal  $x_j$ , na entrada da sinapse  $j$  (terminal de entrada) ligada ao neurônio  $k$  e multiplicada pelo peso  $w_{kj}$ ;

- Um operador de soma, para realizar somas ponderadas pelas respectivas forças sinápticas do neurônio, constituindo uma combinação linear;
- Uma função de ativação, sendo essa uma unidade do processamento, para limitar a amplitude de saída de um neurônio.

#### 2.2.4. Funções de Ativação

A função de ativação é aquela responsável por definir a saída de um neurônio a partir dos valores dos pesos  $w=(w_1, w_2, \dots, w_n)$  e dos valores de entrada  $x=(x_1, x_2, \dots, x_n)$  (BRAGA *et al.*, 2007; HAYKIN, 2009). A utilização da função de ativação permite às RNA identificar relações lineares e não lineares entre as variáveis de entrada e saída. As funções de ativação mais comumente utilizadas, como Log - Sigmóide, Linear e Tn-Sigmóide, são apresentadas na figura 3 e suas funções representadas nas equações 2, 3,4 e 5.

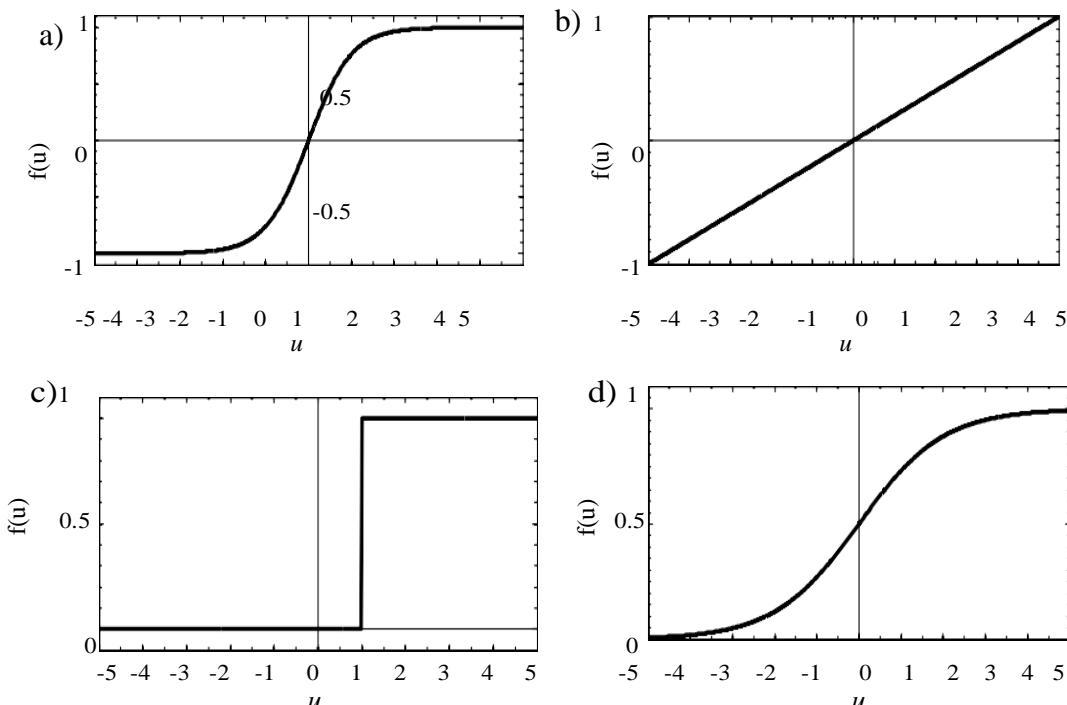


Figura 3- Funções de ativação comuns em RNA. a) Tangente Sigmóide. b) Linear. c) Deslocada Limiar de ativação  $\theta$  em relação à origem ( $\theta = 1$ ). d) Sigmóide. Fonte: HONORATO, 2017.

$$f(u) = \frac{1}{1+e^{-u}} \quad (2)$$

$$f(u) = u \quad (3)$$

$$f(u) = \begin{cases} 1, & \text{se } u \geq 1 \\ 0, & \text{se } u < 0 \end{cases} \quad (4)$$

$$f(u) = \frac{2}{1+e^{-2u}} \quad (5)$$

Independente da função de ativação escolhida, muitas vezes essas funções possuem características restritivas, ou seja, não podem ser aplicadas a qualquer série de dados, devido ao domínio da função. Dessa forma, os dados necessitam ser normalizados para que se possa aplicar.

### 2.2.5. Arquitetura

A maneira pela qual os neurônios de uma rede neural são estruturados está ligada com o algoritmo de aprendizagem utilizado para treinar a rede. A arquitetura é definida como a maneira em que os neurônios são organizados nas camadas e os padrões de conexão entre as unidades de processamento (FAUSETT, 1994; HAYKIN, 2009).

A depender da função de ativação escolhida, neurônios individuais possuem capacidade computacional limitada. A estrutura mais simples de se organizar uma RNA corresponde a uma rede neural de camada única alimentada adiante (*feedforward*) (Figura 4-a). Nessa configuração, têm-se a camada de entrada, recebendo estímulos, e a camada de saída onde se produz o resultado. Estruturas como essa são capazes de resolver problemas multivariáveis de múltiplas funções acopladas, mas com algumas restrições de complexidade (BRAGA, 2007).

Além da rede *feedforward* de uma única camada, têm-se a rede com múltiplas camadas, entre as camadas de entrada e saída (Figura 4-b). A presença de uma camada intermediária confere à RNA uma maior capacidade computacional e universalidade de aproximações contínuas (BRAGA, 2007). O funcionamento desse tipo de rede dà-se onde a primeira camada intermediária recebe os sinais processados da camada de entrada e os conduz para a próxima camada intermediária ou para a camada de saída.

As estruturas de RNAs apresentadas são consideradas estáticas, por não possuírem recorrência. As estruturas que possuem essa característica são chamadas de Redes recorrentes (Figura 4-c e 4-d). O funcionamento das redes recorrentes ocorre de forma em que suas saídas não dependem somente das entradas, mas também de seu valor atual. Segundo Braga *et al* (2007), essa estrutura de RNA é utilizada na resolução de problemas que envolvem processamento temporal, como em previsão de eventos futuros.

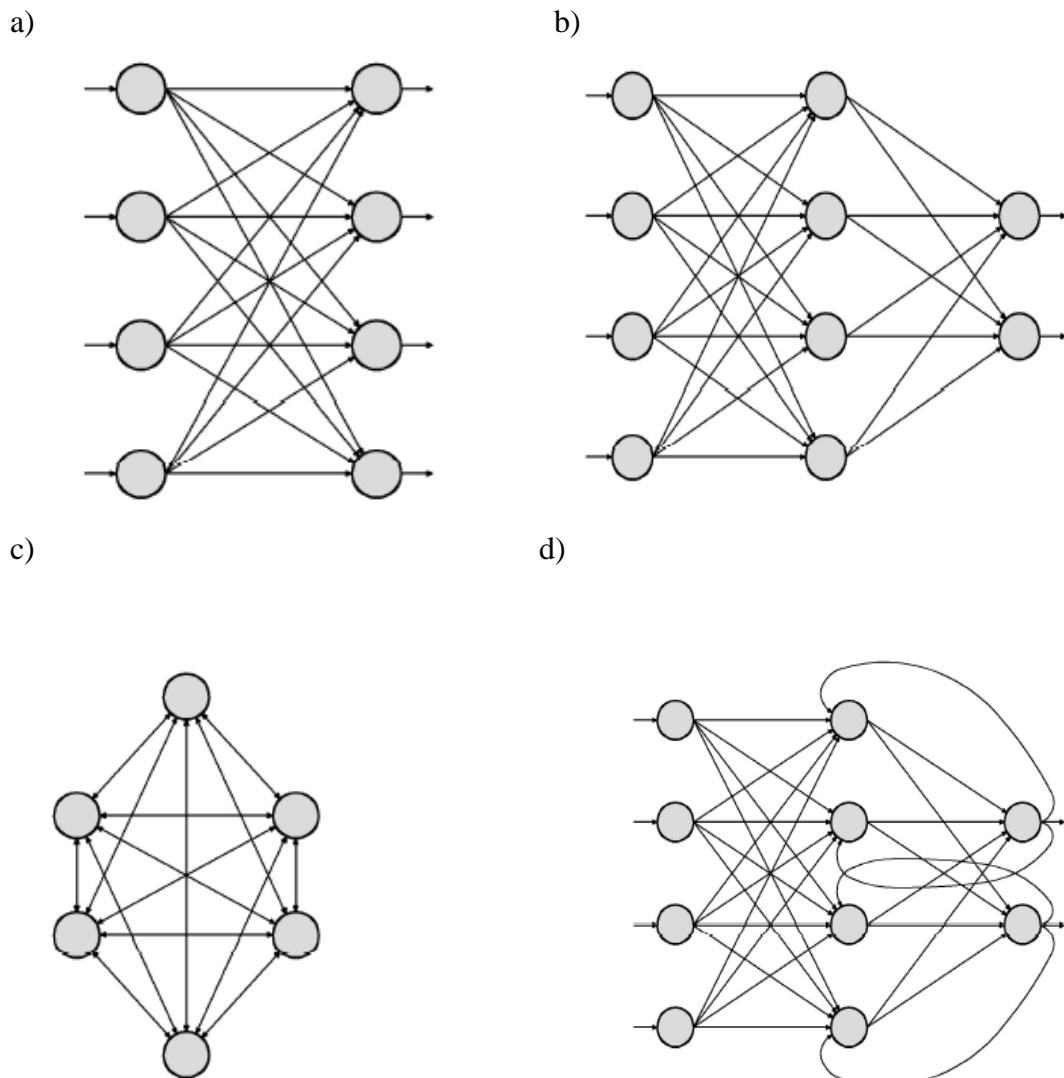


Figura 4 - Arquiteturas comuns para RNA: a) Rede *feedforward* de camada única; b) Rede *feedforward* de duas camadas; c) Rede com recorrência auto-associativa; d) Rede com recorrência entre camadas de saída e intermediária.

Fonte: HONORATO, 2017.

O tipo de arquitetura que é comumente utilizada em trabalhos que abordam a hidrologia é a Rede *feedforward* de três camadas, sendo uma camada de entrada, uma intermediária e uma de saída. Batista (2009) utilizou apenas uma camada intermediária no seu trabalho tratando de modelos de séries temporal e RNA na previsão de vazão, assim como Honorato (2017) em seu trabalho abordando a previsão de vazões diárias e mensais utilizando modelos híbridos de transformadas Wavelet e RNA, e Machado (2005), em seu trabalho sobre a modelagem chuva-vazão utilizando RNA.

#### **2.2.6. Rede Perceptron Multicamadas**

A rede *Perceptron* Multicamadas (*MultiLayerPerceptron*- MLP) é um dos mais conhecidos modelos de RNA e o mais simples, a qual representa uma generalização do *Perceptron* proposto por Rosenblatt no final da década de 50, sendo constituída por vários elementos de entrada conectados aos neurônios de uma única camada de saída.

As unidades de entradas, chamadas de camada de entrada, direcionam os dados entrada ( $x_1, x_2, \dots, x_m$ ) para as camadas seguintes. A camada seguinte, chamada de camada intermediária, transmite as informações por meio de conexões, os pesos ( $w$ ), entre as camadas de entrada e a camada de saída ( $y_1, y_2, \dots, y_m$ ), ou para uma próxima camada intermediária (Figura 5).

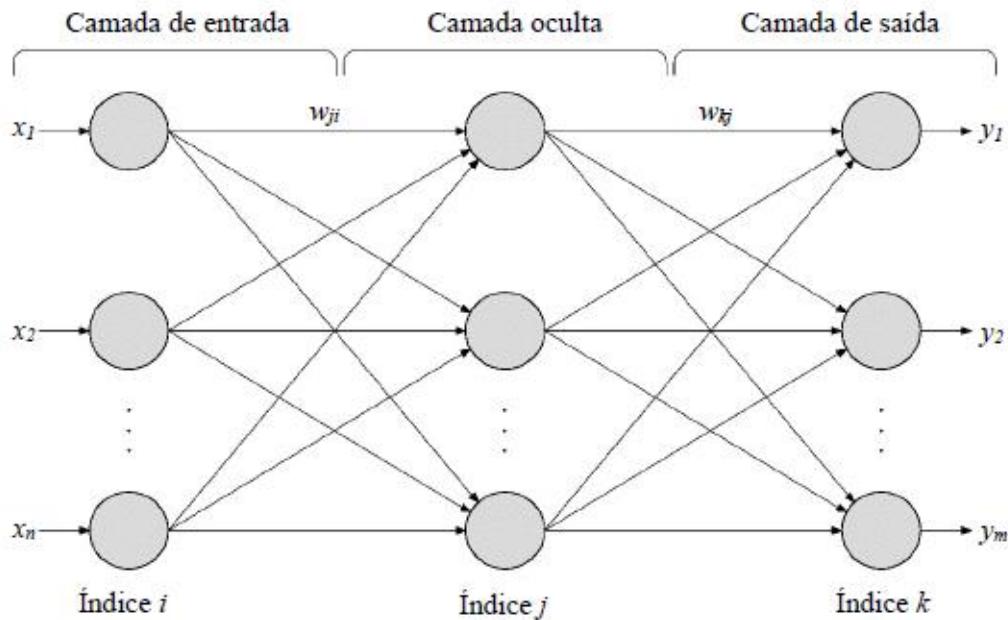


Figura 5- Rede *MultiLayerPerceptron*- MLP.

Fonte: HONORATO, 2017.

$$y_k = f_0(\sum_{j=1}^m f_1 w_{kj} (\sum_{i=1}^n x_i w_{ji} + b_j) + b_k) \quad (6)$$

Desta forma, a saída  $y_k$  de uma rede com uma camada intermediária é dada pela Equação 6.

Segundo Haykin (2009), os recursos básicos para o funcionamento da Rede *MultiLayer Perceptron* - MLP são:

- O modelo de cada neurônio na rede inclui uma função de ativação não linear, isto é, diferenciável;
- A rede contém uma ou mais camadas que estão ocultas da entrada à saída;
- A rede exibe um alto grau de conectividade, cuja extensão é determinada pelos pesos sinápticos da rede.

Pesquisas demonstraram que o uso de uma única camada intermediária é suficiente para uma RNA se aproximar de qualquer função não-linear complexa, e o MLP com três camadas provou ser suficiente para prever e simular vários problemas relacionados aos recursos hídricos (SANTOS & SILVA, 2014). Vários autores

trabalharam com a configuração de apenas uma camada intermediária em estudos hidrológicos e chegaram a bons resultados no que diz respeito a aproximação de funções (MACHADO, 2005; BATISTA, 2007; SANTOS & SILVA, 2014; HONORATO, 2017).

### **2.2.7. Treinamento**

Uma das características mais importantes das RNAs é a sua capacidade de aprender por meio de exemplos. O treinamento, ou aprendizagem, consiste no procedimento para determinação dos pesos da RNA, no qual uma parcela dos dados disponíveis alimenta a RNA, alcançando resultados que demostrem a melhor aproximação da função, ou seja, está relacionado com a melhoria do desempenho da rede segundo algum critério preestabelecido (BRAGA *et al*, 2007; SANTOS & SILVA, 2014).

As RNA, geralmente, podem ser treinadas de duas formas: treinamento supervisionado e não supervisionado.

O treinamento supervisionado implica a existência de um supervisor, o qual é responsável por estimular as entradas da rede por meio de padrões de entrada e observar a saída calculada, comparando com a saída desejada. Se a diferença entre a saída obtida e a desejada estiver fora dos limites considerados satisfatórios, os pesos entre as conexões deverão ser ajustados (Figura 6). Esse processo deve ser repetido até que os erros encontrados tornem-se satisfatórios (MACHADO, 2005; BRAGA *et al*, 2007).

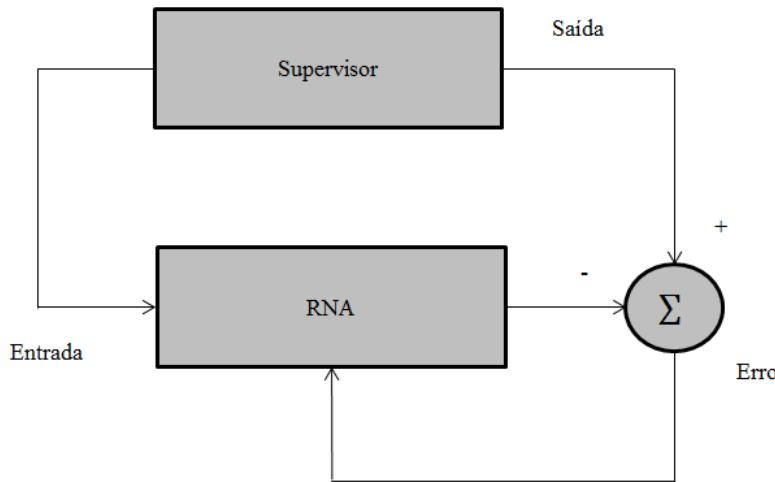


Figura 6- Aprendizado Supervisionado.

Fonte: Adaptado de Braga *et al* ( 2007).

No treinamento não-supervisionado a RNA trabalha as entradas e se organiza de modo que acabe classificando-as para os seus critérios internos previamente definidos (MACHADO, 2005).

As RNAs do tipo *Perceptron* são treinadas utilizando o método supervisionado. Segundo Braga et al.(2007), os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta e sua generalização, o algoritmo *back-propagation*.

Em geral, escreve-se o valor do vetor dos pesos  $w$  na iteração  $(n+1)$  como:

$$w(n+1) = w(n) + \Delta w(n) \quad (7)$$

Onde  $w(n)$  e  $w(n+1)$  representam os valores dos pesos nas iterações  $n$  e  $n+1$  e  $\Delta w(n)$  o valor do ajuste dos pesos após execução do algoritmo.

Para se analisar o desempenho no treinamento, é de extrema importância a definição do número de neurônios em cada camada da rede. Segundo Braga *et al.*, (2007), quanto maior o número de neurônios, maior a complexidade da rede e maior a sua abrangência em termos de soluções possíveis. Porém, em alguns casos, as redes neurais artificiais, mesmo passando pela etapa de treinamento apresentam baixos erros de calibração e elevados erros de previsão, ou seja, um superdimensionamento (*overfitting*) devido ao número excessivo de neurônios. Portanto, o procedimento

fundamental para evitar o superdimensionamento é a otimização do número de neurônios da camada intermediária, adicionando ou reduzindo o número de neurônios na camada até que se chegue a um resultado satisfatório (CERQUEIRA et al., 2001; BRAGA et al 2007).

### **2.2.7.1. Algoritmo da *backpropagation***

Segundo Machado (2005), o algoritmo *backpropagation* é, considerando uma classificação mais geral, uma adaptação dos métodos de otimização convencionais que levam em consideração a distribuição da RNA em camadas.

O modelo proposto por *Rummelhart* apresenta os neurônios dispostos em camadas, no qual os pesos entre as camadas de entrada e a primeira camada intermediária estão relacionados com as variáveis de entrada. Os pesos nas camadas seguintes estão relacionados com as variáveis modificadas pelas funções de ativação. No caso do algoritmo, além da transferência de dados de uma camada para outra e a transformação por meio das funções de ativação, têm-se a correção dos pesos baseado no erro que esse esteja causando na saída da RNA.

Para se entender o algoritmo, exemplifica-se uma rede neural com três camadas, sendo a primeira a camada de entrada, a segunda, a camada intermediária e a terceira, a camada de saída. Cada camada recebe um índice que a caracteriza ( $k$ ,  $i$  e  $j$ ), para o caso da utilização de mais de um índice. O primeiro é referente ao neurônio que está conectado, por exemplo,  $w_{ik}$  representa os pesos ligados à camada oculta, já  $w_{ji}$  representa os pesos ligados à camada de saída. Seja um neurônio  $j$  com sua saída linear  $u_j$ , e  $y_j$  a saída obtida após a aplicação de uma função de ativação sobre  $u_j$ , ou seja,  $y_j = f(u_j)$ .

Inicialmente, calcula-se o erro ( $e_j$ ) de uma função em relação à saída desejada ( $y_d^j$ ) por meio da rede ( $y_j$ ), em uma iteração n:

$$e_j(n) = y_d^j(n) - y_j(n) \quad (8)$$

A soma de todos os erros quadráticos de todos os neurônios de saída na iteração é dada pela equação (BRAGA et al., 2007):

$$E(n) = \frac{1}{2} \sum_j e_j^2(n) \quad (9)$$

Sendo a saída linear do neurônio  $j$  da camada de saída e  $i$  o índice referente à camada escondida, definida por:

$$u_j(n) = \sum_i h_i(n) w_{ij}(n) \quad (10)$$

Dessa forma, a equação (11) pode ser transcrita como:

$$e_j(n) = y_d^j(n) - f(u_j(n)) \quad (11)$$

Ou ainda,

$$E(n) = \frac{1}{2} \sum_j (y_d^j(n) - f(u_j(n)))^2 \quad (12)$$

Tratando-se da camada de saída, faz-se o ajuste do vetor dos pesos em direção contrária ao gradiente do erro, baseado no erro quadrático escrito em função da saída. Sendo assim,

$$\frac{\partial E(n)}{\partial w_{ji}} = \frac{1}{2} \frac{\partial}{\partial w_{ji}} (y_d^j(n) - f(u_j(n)))^2 \quad (13)$$

Ao aplicar a regra da cadeia na equação (13), obtém-se o seguinte desenvolvimento dessa equação:

$$\frac{\partial E(n)}{\partial w_{ji}} = \frac{1}{2} 2 (y_d^j(n) - f(u_j(n))) \frac{\partial}{\partial w_{ji}} (y_d^j(n) - f(u_j(n))) \quad (14)$$

Ou ainda, simplificando a equação:

$$\frac{\partial E(n)}{\partial w_{ji}} = (y_d^j(n) - f(u_j(n))) \frac{\partial}{\partial w_{ji}} (y_d^j(n) - f(u_j(n))) \quad (15)$$

Sabendo que a equação (11), corresponde à  $e_j(n) = y_d^j(n) - f(u_j(n))$ , substitui-se na equação (15), logo,

$$\frac{\partial E}{\partial w_{ji}} = e_j(n) \frac{\partial}{\partial w_{ji}} (y_d^j(n) - f(u_j(n))) \quad (16)$$

Aplicando novamente a regra da cadeia para obter-se a equação  $\frac{\partial}{\partial w_{ji}} (y_d^j(n) - f(u_j(n)))$ , e, sabendo que:

$$\frac{\partial E(n)}{\partial w_{ji}} = \frac{\partial E}{\partial u_j} \frac{\partial u_j}{\partial w_{ji}} \quad (17)$$

Tem-se,

$$\frac{\partial E(n)}{\partial w_{ji}} = e_j(n) \frac{\partial}{\partial u_j} (y_d^j(n) - f(u_j(n))) \frac{\partial}{\partial w_{ji}} u_j \quad (18)$$

Desta forma, a equação (18) pode ser reescrita como:

$$\frac{\partial E(n)}{\partial w_{ji}} = e_j(n) (-1) \frac{\partial}{\partial u_j} f(u_j(n)) \frac{\partial}{\partial w_{ji}} \sum_k h_k(n) w_{jk}(n) \quad (19)$$

A derivada  $\frac{\partial}{\partial u_j} f(u_j(n))$  pode ser representada por  $f'(u_j(n))$ , correspondendo à derivada da função de ativação do neurônio  $j$  ( $f(\cdot)$ ), da camada de saída, em relação ao valor de  $u_j$  no instante  $n$ , onde:

$$\frac{\partial}{\partial w_{ji}} \sum_k h_k(n) w_{jk}(n) = h_i(n) \quad (20)$$

Onde, somente o tempo em que  $k=i$ , não haverá derivada nula, desta forma, obtém-se a equação (13), para o ajuste dos pesos da camada de saída:

$$\frac{\partial E}{\partial w_{ji}}(n) = -e_j(n)f'(u_j(n))h_i(n) \quad (21)$$

Para o ajuste dos pesos da camada intermediária, calcula-se a derivada do erro  $E(n)$  em relação ao peso  $w_{ik}$ , de forma análoga:

$$\frac{\partial E}{\partial w_{ik}}(n) = \frac{1}{2} \frac{\partial}{\partial w_{ik}} \sum_j (y_d^j(n) - f(\sum_i h_i(n)w_{ji}(n)))^2 \quad (22)$$

O somatório da equação (18) pode ser reescrito como a soma dos erros de cada um dos neurônios de saída, logo:

$$\frac{\partial E}{\partial w_{ik}}(n) = \frac{\partial}{\partial w_{ik}} \frac{1}{2} (e_1^2(n) + e_2^2(n) + e_3^2(n) + \dots + e_m^2(n)) \quad (23)$$

Onde “ $m$ ” é o número de neurônios da camada de saída.

A derivada do somatório pode, conforme apresentado na equação (23), ser representada conforme a Equação:

$$\frac{\partial E}{\partial w_{ik}}(n) = \frac{1}{2} (\frac{\partial}{\partial w_{ik}} e_1^2(n) + \frac{\partial}{\partial w_{ik}} e_2^2(n) + \frac{\partial}{\partial w_{ik}} e_3^2(n) + \dots + \frac{\partial}{\partial w_{ik}} e_m^2(n)) \quad (24)$$

Tratando de um termo de  $j$  qualquer:

$$\frac{\partial e_j^2}{\partial w_{ik}}(n) = \frac{\partial}{\partial w_{ik}} (y_d^j(n) - f(u_j(n)))^2 \quad (25)$$

Ao derivar a equação (25), obtém-se:

$$\frac{\partial e_j^2}{\partial w_{ik}}(n) = (2)(-1) e_j(n)f'(u_j(n)) \frac{\partial}{\partial w_{ik}} (u_j(n)) \quad (26)$$

$$\frac{\partial e_j^2}{\partial w_{ik}}(n) = (-2) e_j(n) f'(u_j(n)) \frac{\partial}{\partial w_{ik}}(u_j(n)) \quad (27)$$

Porém, sabendo que  $u_j(n)$  corresponde ao somatório das contribuições ponderadas dos neurônios  $i$  ligados a  $j$ , a derivada  $\frac{\partial}{\partial w_{ik}}(u_j(n))$ , pode ser obtida através da equação (28):

$$\frac{\partial}{\partial w_{ik}}(u_j(n)) = \frac{\partial}{\partial w_{ik}}\left(\sum_i h_i(n)w_{ji}(n)\right) \quad (28)$$

Como somente o neurônio  $i$  da camada escondida possui o peso  $w_{ik}$  como entrada, então a equação pode ser simplificada para as equações (29) e (30)

$$\frac{\partial}{\partial w_{ik}}(u_j(n)) = \frac{\partial}{\partial w_{ik}}(h_i(n)w_{ji}(n)) \quad (29)$$

Neste caso, dado que a derivada está relacionada ao peso ligada a camada intermediária  $w_{ik}$ , o peso  $w_{ji}$  é considerado uma constante, logo:

$$\frac{\partial}{\partial w_{ik}}(u_j(n)) = w_{ji}(n) \frac{\partial}{\partial w_{ik}}(h_i(n)) \quad (30)$$

Aplicando-se a regra da cadeia, obtém-se:

$$\frac{\partial}{\partial w_{ik}}(u_j(n)) = w_{ji}(n)h_i'(u_i(n)) \frac{\partial}{\partial w_{ik}}u_i(n) \quad (31)$$

Sabendo que  $u_i(n)$  corresponde ao somatório ponderado das entradas conectadas dos neurônios  $i$  conectados ao neurônio  $j$ , a derivada  $\frac{\partial}{\partial w_{ik}}(u_j(n))$  se torna somente  $x_k(n)$ , pois todos os outros termos são constantes, com exceção  $w_{ik}x_k(n)$ . Logo:

$$\frac{\partial(u_j(n))}{\partial w_{ik}} = w_{ji}(n)h_i'(u_i(n))x_k(n) \quad (32)$$

Substituindo a equação (32) em (27), obtém-se:

$$\frac{\partial e_j^2}{\partial w_{ik}}(n) = (-2) e_j(n) f'(u_j(n)) w_{ji}(n) h_i'(u_i(n)) x_k(n) \quad (33)$$

Aplicando no somatório da equação (24), obtém-se:

$$\begin{aligned} \frac{\partial E}{\partial w_{ik}}(n) &= \frac{1}{2} ((-2) e_1(n) f'(u_1(n)) w_{1i}(n) h_i'(u_i(n)) x_k(n) + \\ &(-2) e_2(n) f'(u_2(n)) w_{2i}(n) h_i'(u_i(n)) x_k(n) + \\ &(-2) e_3(n) f'(u_3(n)) w_{3i}(n) h_i'(u_i(n)) x_k(n) + \dots + \\ &(-2) e_m(n) f'(u_m(n)) w_{mi}(n) h_i'(u_i(n)) x_k(n)) \end{aligned} \quad (34)$$

Colocando o termo  $(-2) h_i'(u_i(n)) x_k(n)$  em evidência, a equação fica da seguinte forma:

$$\begin{aligned} \frac{\partial E}{\partial w_{ik}}(n) &= \\ &\frac{1}{2} ((-2) h_i'(u_i(n)) x_k(n)) [(e_1(n) f'(u_1(n)) w_{1i}(n)) + \\ &(e_2(n) f'(u_2(n)) w_{2i}(n)) + (e_3(n) f'(u_3(n)) w_{3i}(n)) + \\ &(e_4(n) f'(u_4(n)) w_{4i}(n)) + \dots + (e_m(n) f'(u_m(n)) w_{mi}(n))] \end{aligned} \quad (35)$$

Dessa forma, escreve-se as somas das parcelas individuais como um somatório:

$$\frac{\partial E}{\partial w_{ik}}(n) = -h_i'(u_i(n)) x_k(n) \sum_j e_j(n) f'(u_j(n)) w_{ji}(n) \quad (36)$$

Como o ajuste deve ser feito na direção contrária ao gradiente, tem-se que  $\Delta w \propto -\nabla E$ . Sendo assim, a equação (37) apresenta o ajuste a se aplicado nos pesos da primeira camada que conectam a entrada  $k$  aos neurônios  $i$ :

$$\Delta w_{ik}(n) = \eta h_i'(u_i(n))x_k(n) \sum_j e_j(n)f'(u_j(n))w_{ji}(n) \quad (37)$$

Onde:  $\eta$  é a constante de proporcionalidade correspondente à taxa de aprendizado;

$h_i'(u_i(n))$ , é a derivada da função de ativação do neurônio  $i$  e a soma ponderada de suas entradas;

$x_k(n)$ , corresponde às entradas das redes;

$\sum_j e_j(n)f'(u_j(n))w_{ji}(n)$ , corresponde a uma medida do erro do neurônio  $i$  da camada escondida.

#### 2.2.7.2. Algoritmo de Levenberg-Marquardt

O algoritmo de Levenberg- Marquardt (LM) baseia-se no método clássico de Newton a fim de encontrar uma solução ótima para o problema de minimização. Ele otimiza o método de Newton acrescentando uma taxa de aprendizado variável e tornando o processo mais eficiente (BRAGA et al, 2007).

O algoritmo LM utiliza o mesmo algoritmo *backpropagation* na determinação das primeiras e segundas derivadas desta mesma função, onde as técnicas de otimização não lineares de segunda ordem são mais rápidas e mais confiáveis (MACHADO, 2005; SANTOS e SILVA, 2014). Porém, segundo Braga et al., (2005), o algoritmo de treinamento LM demanda uma grande quantidade de memória e uma elevada complexidade computacional, limitando seu uso em redes muitos grandes.

Para ajustar os pesos de uma rede o algoritmo LM pode ser escrito da seguinte forma (Equação x):

$$\Delta w_{ji}(n) = -[\nabla^2 E(w_{ji}(n)) + \mu I]^{-1} + \nabla E(w_{ji}(n)) \quad (38)$$

Onde,

$\nabla^2 E(w_{ji}(n))$ , é uma matriz hessiana;

$\nabla E(w_{ji}(n))$ , é o gradiente;

$\mu$ , é um escalar que controla o processo de aprendizagem.

### **2.2.7.3. Verificação**

A validação das RNAs é similar a outros modelos hidrológicos. A eficiência dos modelos pode ser aferida utilizando parâmetros estatísticos para descrever o grau ou a similaridade entre os dados observados e os dados previstos no modelo.

Comumente, os dados disponíveis são divididos em conjuntos, uma parcela de dados utilizada na etapa do treinamento da rede e a outra parcela utilizada na verificação. O treinamento é então aplicado com o objetivo de ajustar seus pesos e para que a rede possa aprender a generalizar respostas dos dados de entrada desconhecidos. Já a verificação é aplicada para que o modelo possa replicar os resultados com os dados que não foram utilizados na etapa do treinamento. Uma vez que o treinamento e a verificação são aplicados, pode-se chamar a rede de generalizada quando o mapeamento de entrada e saída apresenta uma boa simulação dos resultados para o conjunto de dados disponível (HAYKIN, 2009).

### **2.3.8. Aplicações**

As RNAs podem ser aplicadas em estudos das mais diversas áreas do conhecimento, devido a essa ferramenta necessitar apenas de um conjunto de dados. Segundo Braga et al., (2007), as RNAs podem ser aplicadas nos estudos de previsão, classificação, aproximação, categorização e otimização.

No que diz respeito à simulação, a aplicação para essa finalidade envolve a construção de modelos a partir de dados observados em um dado intervalo de tempo. Neste caso, a utilização das RNAs é uma alternativa atraente, pois utiliza apenas valores de entrada e saída do sistema em intervalos de tempo regulares sem considerar variáveis físicas.

Nos problemas de classificação a rede aprende a classificar um padrão desconhecido e várias classes (BRAGA et al, 2007). Nesse caso, o treinamento é realizado por um supervisor, para que apresente padrões e suas classes e, assim, possa apresentar resultados satisfatórios.

No tocante aos problemas de aproximação, os dados de entrada e saída são apresentados para que a rede possa realizar o treinamento supervisionado, para que assim ela seja mapeada.

Já para os problemas de categorização, utilizam um treinamento não-supervisionado e, ao invés de classificar os dados em padrões, ele categoriza os dados.

Para problemas de otimização, têm-se o objetivo de minimizar ou maximizar uma função de custo, porém faz-se necessário que essa função seja conhecida para a caracterização do problema.

Muitos estudos hidrológicos utilizam as RNAs como metodologia, a exemplo do estudo de previsão de vazões, utilizando dados de vazão (BALLINI, 2000; SANTOS, 2001; MACHADO, 2005; BRAVO et al., 2008; BATISTA, 2009; SOUSA e SOUSA, 2010; FERREIRA et al., 2011; SILVA et al., 2016). Além disso, pode ser utilizada associada a outros modelos, chamado de modelo híbridos, para previsões de vazões, a partir de dados de vazão, como foi utilizado por Honorato (2017) e Santos e Silva (2014) na bacia de Sobradinho e por Honorato et al (2017) na estação 73015 do rio Keer, na Inglaterra.

As redes neurais também podem ser aplicadas na previsão de secas (GUEDES, 2011; LIMA, 2015; AMORIM et al., 2017); no preenchimento de falhas de precipitação, tanto mensal como diária, a partir de dados de precipitação (OIKAWA et AL, 2013; WANDERLEY et al, 2014; CORREIA et al., 2016; GIMENEZ, 2017;). Pode, também, ser aplicada na estimativa de evapotranspiração, a partir de dados de precipitação (SOBRINHO et al., 2011; ZANETTI et al., 2008; FERRAZ, 2013).

### **2.3.9. Vantagens e Desvantagens**

Algumas características oferecem benefícios pela utilização das RNAs. Segundo Haykin (2009), as RNAs oferecem os seguintes recursos úteis:

- Não linearidade: um neurônio artificial pode ser linear ou não-linear. A não-linearidade é distribuída em toda rede e, se o mecanismo responsável pela geração do sinal de entrada for inherentemente não-linear, a não-linearidade torna-se uma propriedade muito importante;
- Adaptabilidade: as RNAs possuem a capacidade de adaptar os pesos sinápticos a modificações do meio circundante. Além disso, quando está operando em um ambiente onde as estatísticas mudam com o tempo, uma

rede neural pode ser projetada para alterar seus pesos sinápticos em tempo real;

- Resposta a evidências: uma RNA pode se projetada para fornecer informações, não apenas a respeito de qual padrão específico selecionar, mas também informações sobre a crença para tomada de decisão, com a possibilidade de rejeição de padrões ambíguos;
- Informação contextual: O conhecimento é representado pela estrutura e situação de ativação de uma RNA. Todo neurônio na rede é potencialmente influenciado pela atividade global de todos os outros neurônios da rede;
- Tolerância: Para assegurar que uma RNA seja de fato tolerante a falhas, faz-se necessário adotar medidas corretivas no projeto do algoritmo no treinamento;
- Análise neurobiológica: o projeto de uma RNA é motivado pela analogia com o cérebro humano, sendo essa uma prova de que o processamento é tolerante a falhas, rápido e poderoso.

Nos estudos hidrológicos têm-se uma grande dificuldade em entender os processos que envolvem o fenômeno em sistema, dificultando assim a escolha de qual modelo matemático deve-se aplicar. Dessa forma, as RNAs surgem como uma alternativa atrativa para a modelagem. Porém, assim como os outros diversos modelos matemáticos, as RNAs possuem suas desvantagens. Segundo Honorato (2017), pode-se destacar as seguintes desvantagens:

- Dependem da quantidade e qualidade de dados disponíveis, onde nem sempre é possível ter acesso a longos registros de dados completo e de boa qualidade;
- Não fornecem informação física a respeito do sistema, não sendo possível analisar os efeitos das mudanças físicas, como uso do solo;
- Não existe uma metodologia padrão para definir a arquitetura da rede, funções de ativação e o algoritmo de treinamento, onde dependem da experiência do usuário (ASCE TASK COMMITTEE, 2000).

### 3. METODOLOGIA

#### 3.1. Descrição Geral

Este Trabalho teve com objetivo avaliar o desempenho das Redes Neurais Artificiais na previsão de vazões médias diárias em rios, utilizando como entrada, vazões passadas para de previsão de vazões futuras diárias (1, 3 e 5 dias à frente), utilizando Redes Neurais Artificiais em bacias hidrográficas com diferentes áreas de drenagem, a fim de comparar a resposta do modelo à essa variação espacial.

Inicialmente, foram utilizadas as séries de vazões diárias para estabelecer o modelo de previsão baseado nas Redes Neurais Artificiais em três bacias hidrográficas.

Posteriormente, realizou-se a avaliação do desempenho do modelo por meio de três parâmetros estatísticos. O fluxograma abaixo (Figura 7) apresenta a esquematização de como será realizada a metodologia do trabalho.

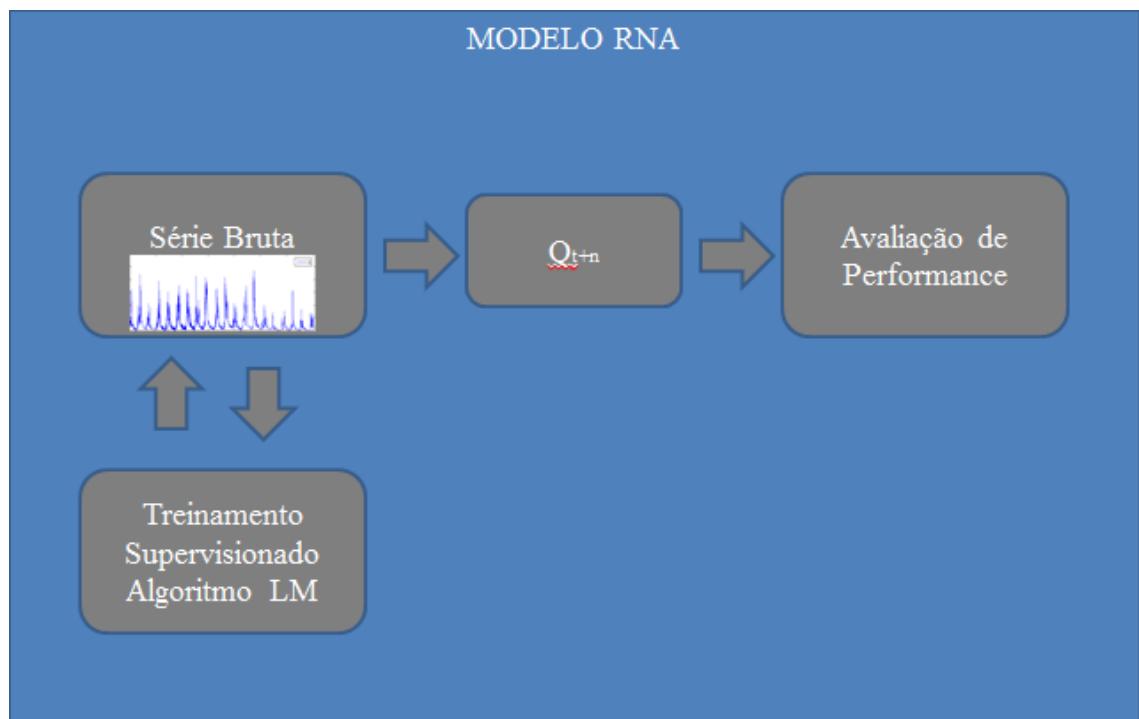


Figura 7- Esquematização da metodologia utilizada para modelos RNA.

Fonte: Elaboração própria.

### 3.2. Área de Estudo

As áreas de estudo deste trabalho foram: a área de drenagem da bacia de Sobradinho (Bacia 1- Figura 8), a área de drenagem da bacia de Três Marias (Bacia 2- Figura 9) e o Rio Keer (Bacia 3-Figura 10).

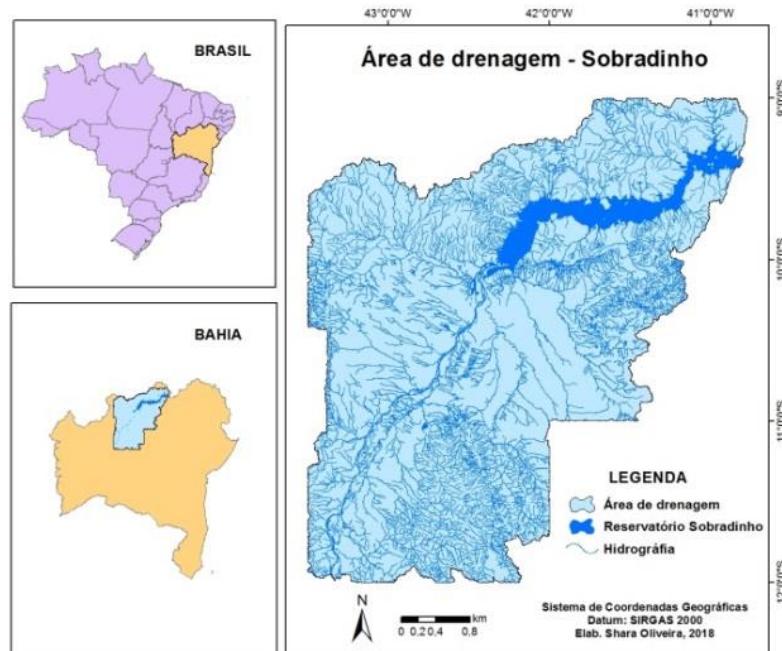


Figura 8- Área de drenagem da bacia de Sobradinho.

Fonte: INPE, 2011.

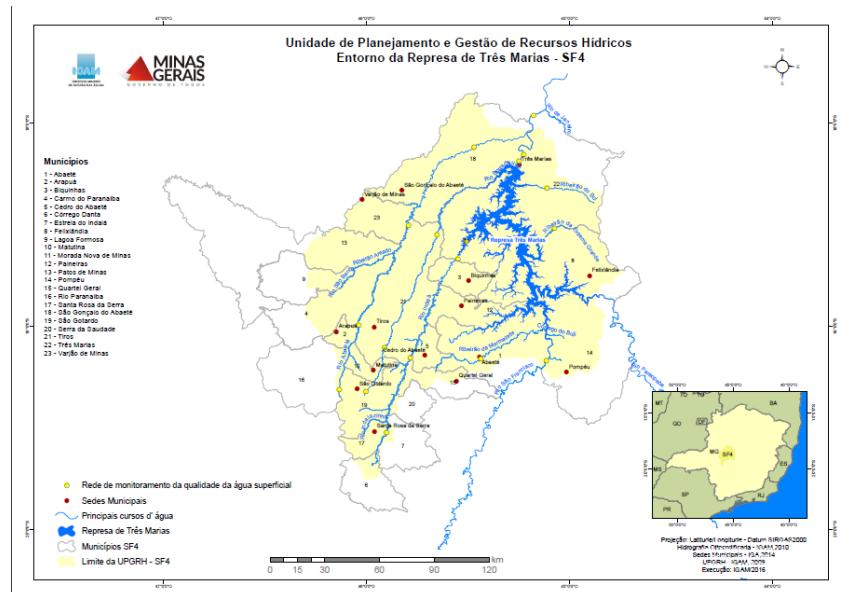


Figura 9- Área de drenagem da bacia de Três Marias.

Fonte: CBHSF, 2018.

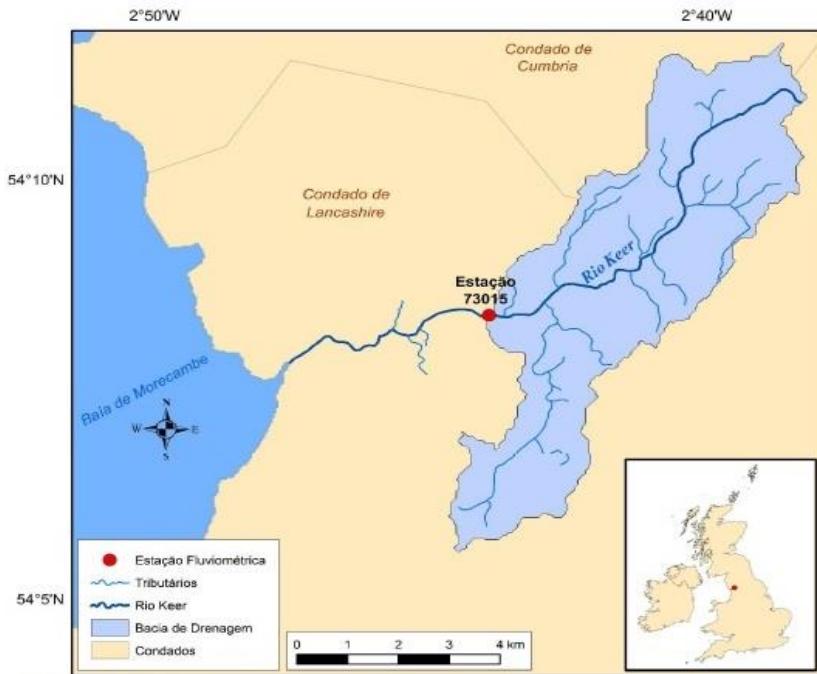


Figura 10- Área de drenagem Do Rio Keer.

Fonte: Honorato et al (2017).

O reservatório de Sobradinho encontra-se inserido na bacia do Rio São Francisco, alimentando uma usina hidrelétrica com uma capacidade instalada de 1.050 MW que drena uma área de 498.968 Km<sup>2</sup> (SANTOS e SILVA, 2014). O lago foi construído em 1973, pela Companhia Hidroelétrica de São Francisco (CHESF), cujo lago formado em 1979, tem uma superfície de 4.214 Km<sup>2</sup> e é considerado um dos maiores lagos artificiais do mundo (PEREIRA, 2004).

Já o reservatório de Três Marias, de propriedade da Companhia Energética de Minas Gerais – CEMIG, localiza-se na região do Alto São Francisco em uma zona climática tropical, alimentando uma usina hidrelétrica com uma potência instalada de 396 MW tendo uma área de drenagem de 50.732 Km<sup>2</sup> (ONS, 2009).

A bacia do São Francisco possui aproximadamente 2.700 km de extensão e descarrega em média 2.810 m<sup>3</sup>/s no oceano. Sua bacia drena uma área total de 638.219 Km<sup>2</sup>, sendo dividida em quatro regiões fisiográficas, as quais são: Alto São Francisco, correspondendo à região compreendida entre a nascente do rio principal, na serra Canastra, Estado de Minas Gerais, e a confluência com Rio Jequitaí; Médio São Francisco, sendo o trecho de maior extensão com 1.152 Km, entre a confluência do Rio Jequitaí com o São Francisco e a barragem da usina hidrelétrica de Sobradinho, na divisa entre os Estados de Pernambuco e Bahia; Submédio São Francisco, com 568 km,

correspondendo ao trecho entre a barragem de Sobradinho e a cidade de Belo Monte, em Alagoas; e o Baixo São Francisco, correspondendo ao trecho a jusante de Belo Monte até a foz do oceano Atlântico, na divisa dos Estados de Sergipe e Alagoas (CBHSF, 2014).

No tocante ao clima, na bacia do São Francisco tem-se a ocorrência dos climas úmido, subúmido – seco, semi- árido e árido, caracterizando-se pela ocorrência de temperatura de mediana a elevada durante quase todo ano, com uma temperatura média anual variando de 18° a 27° (PEREIRA, 2004; MMA, 2006).

A terceira área de estudo é o Rio Keer, pequeno rio localizado no noroeste da Inglaterra, utilizando as vazões medidas na estação 73015 que drena uma área de 48 Km<sup>2</sup>. A área é coberta por gramíneas (78,6%), florestas (12,7%), cultivos agrícolas (7,6%) e área urbana (2,4%). A estação foi inaugurada em 1971 com um reservatório plano medindo o fluxo natural do rio. A responsável pela medição da estação é a Agência Ambiental Cumbria e Lancashire (NRFA, 2018).

### **3.3. Modelos de Previsão baseados em RNA**

#### **3.3.1. Tipo de Rede**

Nesse estudo foi adotado uma Rede Neural Artificial do tipo *Perceptron Multicamadas* (MLP) com três camadas, sendo a primeira camada de entrada, uma camada intermediária, com função de ativação sigmoide; e uma camada de saída, com função de ativação linear. Para aplicação da RNA foi utilizado o programa computacional MATLAB 8.5. Este modelo foi adotado devido à grande maioria dos estudos apresentarem bons resultados nas aproximações utilizando funções não lineares em diferentes problemas na área de recursos hídricos (SOUSA e SOUSA; 2010; FERREIRA et al, 2011; SANTOS e SILVA, 2014; HONORATO, 2017).

#### **3.3.2. Padronização e Preparação dos dados**

Após a definição do tipo de rede utilizada, fez-se necessário a padronização dos dados com a normalização em um intervalo de [-1, 1], para que os dados possam ser utilizados pelas funções de ativação.

Em seguida, fez-se necessário a separação dos dados para serem utilizados nas etapas de treinamento de verificação. O subconjunto de treinamento foi utilizado no processo de aprendizagem da rede. Já o conjunto de verificação foi utilizado para aferir se a rede conseguiu generalizar os resultados da aprendizagem.

A quantidade de pontos de vazão para cada etapa foi definido de acordo com a quantidade de pontos de vazão de cada bacia hidrográfica. Para o caso da bacia de Sobradinho, foram utilizados 17.000 pontos de vazão, correspondendo à 47 anos de dados, para o treinamento e 3.000, correspondendo à 8 anos, para a verificação. Já para o caso da bacia de Três Marias, foram utilizadas 5.500, correspondendo à 15 anos, para o treinamento e 1.500, correspondendo à 4 anos, para verificação. Para o caso do Rio Keer, foram utilizadas 4.000 pontos de vazão, correspondendo à 11 anos, para a primeira etapa e 1.000, correspondendo à 3 anos, para a verificação.

### **3.3.3. Arquitetura**

A arquitetura adotada foi uma estrutura não recorrente, ou seja, estática, sendo uma rede com três camadas. A primeira camada de entrada dos dados, uma camada intermediária e uma camada de saída, como já citado anteriormente.

Partindo do princípio que há uma relação de dependência entre as ocorrências passadas e as ocorrências futuras, utilizou-se na camada de entrada valores de vazão ocorridos em tempos passados para previsão de vazões futuras.

A rede foi iniciada com três neurônios de entrada e foram testados valores com incrementos de três em três até atingir doze neurônios. Similarmente, para a determinação do número de neurônios na camada intermediária, utilizou-se o mesmo processo, até que o incremento chegasse a quinze. Para a camada de saída, foi utilizado apenas um neurônio, pois o objetivo é a previsão de um valor de vazão futuro. Após todo o processo, verificou-se qual o melhor tipo de arquitetura a ser utilizada no modelo. Esse processo foi realizado para as três áreas de estudo desse trabalho.

### **3.3.4. Função de Ativação**

A função de ativação, similarmente a arquitetura, foi determinada baseada em tentativas. Para cada caso desse trabalho, foram consideradas duas situações de função. No caso da bacia de Sobradinho, foi utilizada a função tangente sigmoide para as duas camadas. Já para o caso da bacia de Três Marias, foi utilizada a função sigmóide seguida da linear. Para o Rio Keer, foi utilizada a função sigmoide seguida da linear.

Para cada área e cada tipo de arquitetura foram testadas as várias situações e foram escolhidas as que apresentaram os melhores resultados.

### **3.3.5. Treinamento e Verificação**

O treinamento é a etapa do modelo RNA em que se têm a capacidade de aprender por meio de exemplos, utilizando o algoritmo e uma função objetiva para que se ajustem os pesos e assim se obtenha a generalização dos resultados.

Foram utilizados no treinamento do modelo de previsão diária das Bacias de Sobradinho, Três Marias e do Rio Keer 17.000, 5500 e 4.000 valores de vazão, correspondendo à 85%, 78% e 80%, respectivamente. Essa quantidade de dados foi definida baseada na porcentagem entre 75% à 90% dos dados disponíveis, baseando-se na quantidade de dados utilizada por Honorato (2017), que utilizou 75% dos dados disponíveis do reservatório de Sobradinho e Honorato et al (2017), que utilizaram 90% dos dados disponíveis. Nessa etapa, a rede aprende a relação entre as vazões passadas e futuras e prevê uma vazão futura de acordo com o horizonte definido. Nesse trabalho, foram previstas vazões com horizonte de 1, 3 e 5 dias, para cada bacia.

O algoritmo de treinamento utilizado foi o de Levenberg- Marquardt com  $\mu=0,001$ .

### **3.3.6. Critérios de parada**

Na etapa de treinamento, fez- se necessário criar uma parada ao processo, para que não ocorra infinitamente. Esta parada foi relacionada aos seguintes critérios:

- Utilizou-se o erro médio quadrático como avaliador de performance, onde quando ele atingia valores menor que  $1 \times 10^{-5} \text{ m}^3/\text{s}$  o processo de aprendizagem era parado a fim de evitar o superdimensionamento;

- Epochs: Epochs ou Épocas representa o número de atualizações ocorridas nos pesos e viéses (MACHADO, 2005). À medida que o numero cresce, o erro diminui torna-se e possível o mapeamento de funções complexas. Porém, chega-se a um ponto onde o erro do processo é menor, mas os pesos encontrados não representam o problema, resultado no superdimensionamento.

Para cada horizonte de previsão (1, 3 e 5 dias) e para cada área de estudo, procedimento acima foi aplicado para determinar os parâmetros e para se ter a previsão de vazão resultante.

### 3.3.7. Avaliação da Performance

Para avaliação da similaridade dos dados observados e os dados previstos, além da análise gráfica, foram utilizados três parâmetros estatísticos. Foram eles o erro quadrático médio (RMSE) (Equação 39), o erro médio absoluto (MARE) (Equação 40) e o coeficiente de eficiência (CE) (Equação 41).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (39)$$

$$MARE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\hat{y}_i} \quad (40)$$

$$CE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{\sum_{i=1}^n (y_i - \bar{y}_i)} \quad (41)$$

Onde,  $y_i$  corresponde aos valores observados;

$\hat{y}_i$ , são os valores gerados pela rede;

$\bar{y}_i$ , corresponde a média dos valores observados;

$n$ , tamanho da amostra.

#### 4. RESULTADOS

Após análise realizada no *MatLab*, os resultados obtidos neste trabalho (Tabela 1) apresentam a influência da escala espacial e, também, do uso e ocupação do solo, no comportamento da vazão prevista para os horizontes de 1,3 e 5 dias da vazão afluente ao reservatório de Sobradinho e Três Marias e a vazão do curso do Rio keer. O desempenho do modelo RNA foi analisado com base no erro quadrático médio (RMSE), no erro absoluto (MARE) e na eficiência do modelo (CE), após a execução do programa MATLAB 2015. Os resultados foram associados à arquitetura adotada para caso, assim com as funções de ativação utilizadas. Desse modo, foi possível apresentar a avaliação do efeito da escala espacial e do uso e ocupação do solo na previsão de vazões diárias e a influência do horizonte de previsão no desempenho do modelo.

Neste trabalho foram utilizados dados de vazão diária na entrada do reservatório de Sobradinho e Três Marias, fornecidos pelo Operador Nacional do Sistema (ONS, 2018). Para as vazões diárias do reservatório de Sobradinho foram utilizados 18.500 pontos de vazões correspondendo ao período de 01/02/1931 à 25/08/1981 (Figura 11) (Tabela 2). Já para o reservatório de Três Marias, foram utilizadas 7.060 pontos de vazões correspondendo ao período 01/01/1999 à 30/04/2018 (Figura 12) (Tabela 2). Para o Rio Keer, foram utilizados 5.000 pontos de vazões diárias correspondendo ao período de 24/11/2001 à 03/08/2015 (Figura 13) (Tabela 2).

Tabela 1-Tabela resumo de cada um dos modelos diários referentes aos reservatórios de Sobradinho e Três Marias e a estação 73015 do rio Keer. TS representa a função Tangente Sigmóide, já TL representa a função de ativação linear. O índice n representa o número de neurônios na camada de entrada, m o número de neurônios na camada intermediária e k os de saída.

Fonte: Elaboração própria.

Bacia/Resultados	Área (Km <sup>2</sup> )	Função de Ativação	Dias à Frente	Arquitetura			Entrada	Saída	Treinamento			Verificação		
				n	m	k			RMSE (m <sup>3</sup> /s)	CE	MARE	RMSE (m <sup>3</sup> /s)	CE	MARE
Sobradinho	498968	TS-TS	1	9	3	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-8</sub>	Q <sub>t+1</sub>	51,064	0,999	0,997	125,656	0,997	0,012
			3	9	3	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-8</sub>	Q <sub>t+3</sub>	177,925	0,991	0,041	157,397	0,991	0,034
			5	9	3	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-8</sub>	Q <sub>t+5</sub>	324,091	0,972	0,075	397,667	0,978	0,006
Três Marias	50372	TS-PL	1	9	9	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-8</sub>	Q <sub>t+1</sub>	172,958	0,934	0,004	63,622	0,957	0,348
			3	9	9	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-8</sub>	Q <sub>t+3</sub>	270,922	0,839	0,261	139,985	0,795	0,421
			5	9	9	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-8</sub>	Q <sub>t+5</sub>	338,085	0,750	0,240	207,576	0,554	0,908
Keer	48	TS-PL	1	3	8	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-2</sub>	Q <sub>t+1</sub>	1,001	0,407	0,499	0,587	0,301	0,484
			3	3	8	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-2</sub>	Q <sub>t+3</sub>	1,148	0,220	1,037	0,651	0,137	1,005
			5	3	8	1	Q <sub>t</sub> , Q <sub>t-1</sub> ..., Q <sub>t-2</sub>	Q <sub>t+5</sub>	1,210	0,129	1,410	0,646	0,153	1,343

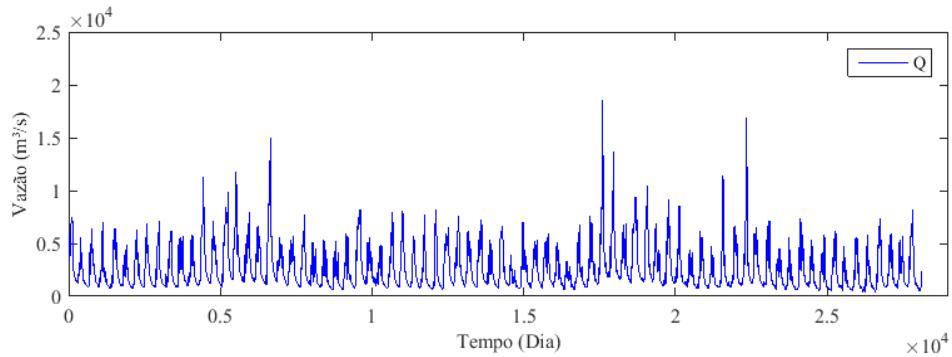


Figura 11 - Série de Vazões diárias afluentes do reservatório de Sobradinho.

Fonte: elaboração própria.

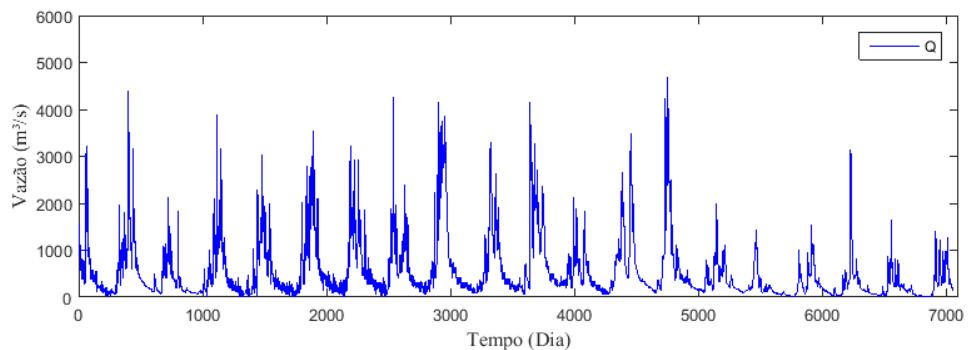


Figura 12-Série de Vazões diárias afluentes do reservatório de Três Marias.

Fonte: elaboração própria.

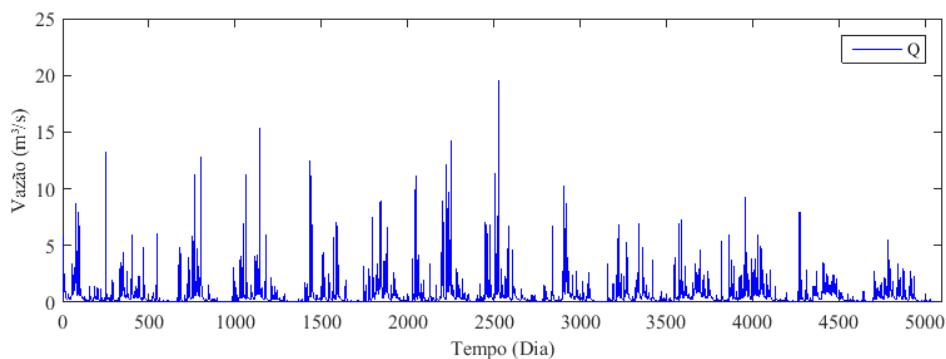


Figura 13-Série de Vazões diárias afluentes à estação 73015 do Rio Keer.

Fonte: elaboração própria.

Estatística Descritiva	Diárias			Unidades
	Três Marias	Sobradinho	Rio Keer	
Máxima	4696,2	18525,0	19,5	m <sup>3</sup> /s
Mínima	2,1	405,0	0,0	m <sup>3</sup> /s
Média	542,4	2676,2	0,7	m <sup>3</sup> /s
Média Harmônica	175,3	1677,6	0,2	m <sup>3</sup> /s
Mediana	304,9	1871,0	0,3	m <sup>3</sup> /s
Moda	100,0	1381,0	0,1	m <sup>3</sup> /s
Amplitude	4694,1	18120,0	19,5	m <sup>3</sup> /s
Desvio Padrão	634,0	2058,3	1,2	m <sup>3</sup> /s
Desvio Médio Absoluto	437,6	1600,0	0,6	m <sup>3</sup> /s
Variância	401990,1	4236431,9	1,4	(m <sup>3</sup> /s) <sup>2</sup>
Primeiro Quartil	156,6	1175,0	0,1	m <sup>3</sup> /s
Terceiro Quartil	665,1	3692,0	0,7	m <sup>3</sup> /s
Amplitude Inter-Quartis	508,5	2517,0	0,5	m <sup>3</sup> /s
Coeficiente de Variação	2,1	1,1	3,9	-
Coeficiente de Assimetria	2,4	1,8	5,6	
Coeficiente de Curtose	6,6	4,9	45,3	

Tabela 2- Estatística para as bacias de Sobradinho, Três Marias e do Rio Keer.

Fonte: Elaboração própria.

As figuras de 14 a 19, apresentam os resultados do treinamento do modelo e a previsão de vazão para um horizonte de 1 dia, 3 dias e 5 dias para o bacia de Sobradinho. Já para a bacia de Três Marias, os resultados foram apresentados nas figuras, 20, 21, 22, 23, 24 e 25 e da estação 73015 do rio Keer, nas figuras de 26 à 31.

Ao analisar o desempenho de cada área de estudo, baseado nos parâmetros estatísticos RMSE, MARE e CE, observou-se que a bacia de Sobradinho, maior área, apresenta os melhores resultados estatísticos e melhor homogeneidade nos gráficos que as demais, ou seja, uma maior semelhança entre os dados disponíveis e a previsão, pois a bacia tem uma resposta lenta ao processo chuva-vazão, ou seja, a água leva um tempo maior para percorrer os canais de drenagem que os demais casos (Tabela 4). Ao passo que a área de drenagem diminui, os resultados apresentaram uma maior dificuldade em correlacionar vazões passadas à vazões futuras, resultando em parâmetros estatísticos com menor eficiência (CE), ou seja, com resultados distantes de 1 e com números de MARE e RMSE maiores, comparando-se os três casos (Tabela 1). Segundo Honorato et al (2017) em sua conclusão na previsão de vazão para o Rio Keer, à resposta da bacia

pequena a um evento chuvoso é rápida, tanto para a chuva de um dia, como para uma chuva de mais de um dia.

Além disso, a bacia com maior área tem uma variedade de uso do solo maior que as outras bacias, considerando cada tipo de vegetação, área urbana e outros tipos de uso do solo.

Ao observar os gráficos, nota-se que para a área de Sobradinho, os resultados apresentam-se mais homogêneos que as demais áreas, ou seja, uma maior semelhança entre os dados disponíveis e a previsão realizada, principalmente na previsão para o horizonte de um dia, corroborando com os resultados estatísticos obtidos na Tabela 2 (Figuras 14 à 19).

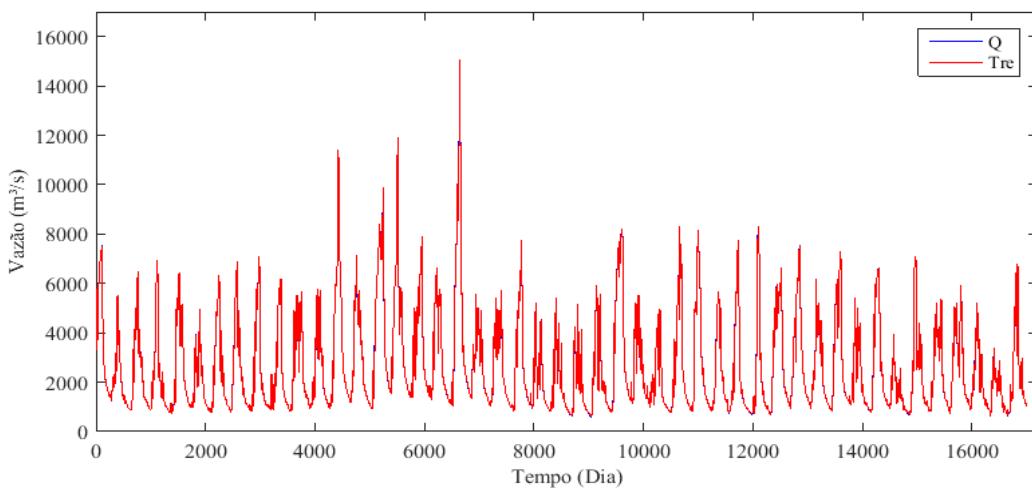


Figura 14- Treinamento (Tre) para previsão de 1 dia à frente, referente à bacia de Sobradinho, gerado pelo modelo RNA comparada com a vazão observada (Q).

Fonte: elaboração própria.

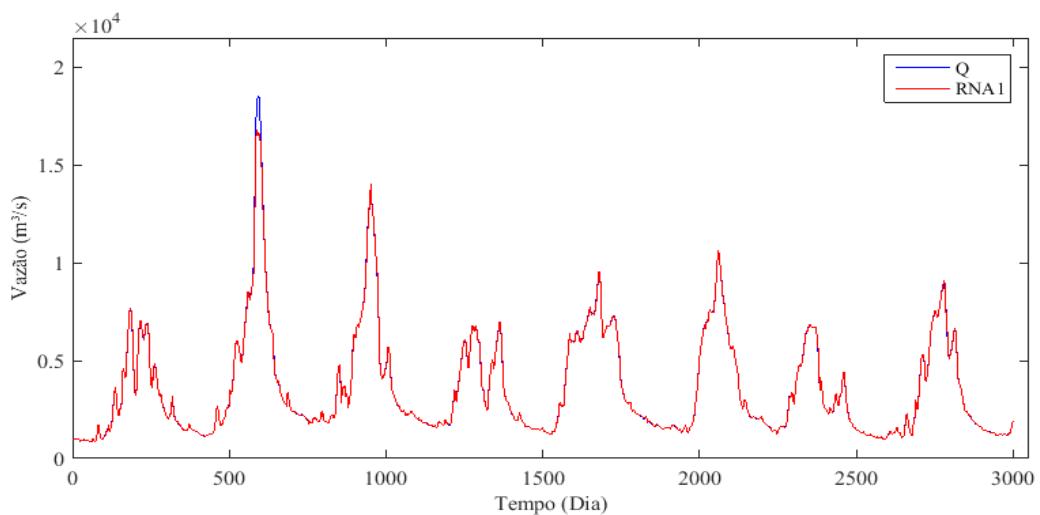


Figura 15- Previsão (RNA1) de 1 dia à frente, referente à bacia de Sobradinho, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

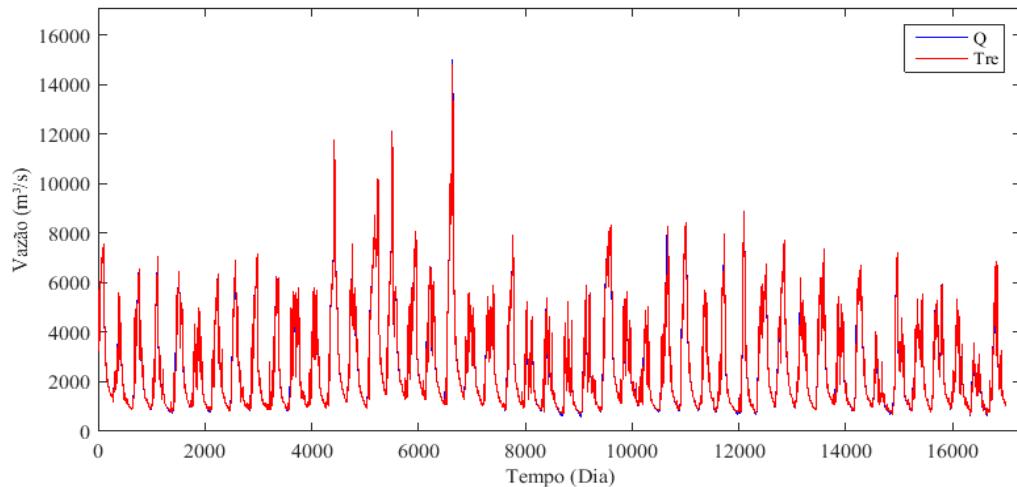


Figura 16- Treinamento (Tre) para previsão de 3 dias à frente, referente à bacia de Sobradinho, gerado pelo modelo RNA comparada com a vazão observada (Q).

Fonte: elaboração própria.

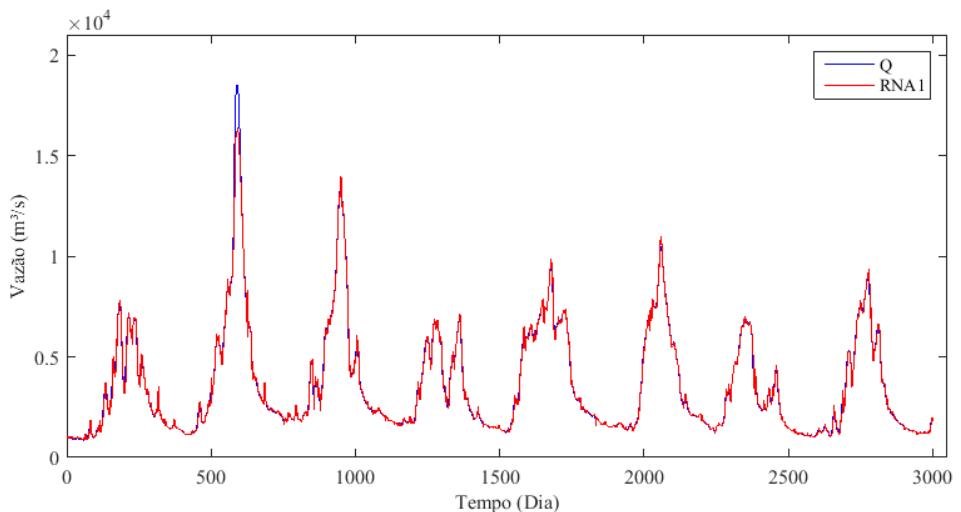


Figura 17- Previsão (RNA1) de 3 dias à frente, referente à bacia de Sobradinho, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

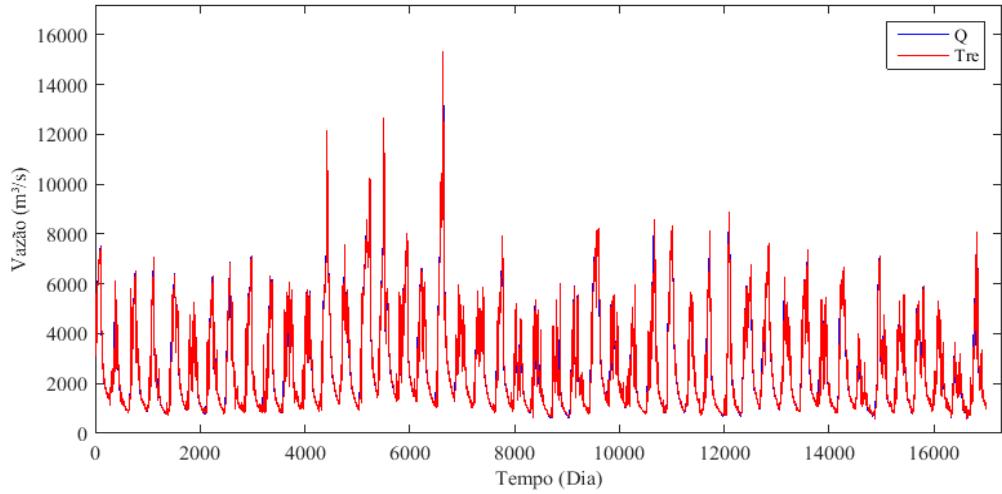


Figura 18- Treinamento (Tre) para previsão de 5 dias à frente, referente à bacia de Sobradinho, gerado pelo modelo RNA comparada com a vazão observada (Q).

Fonte: elaboração própria.

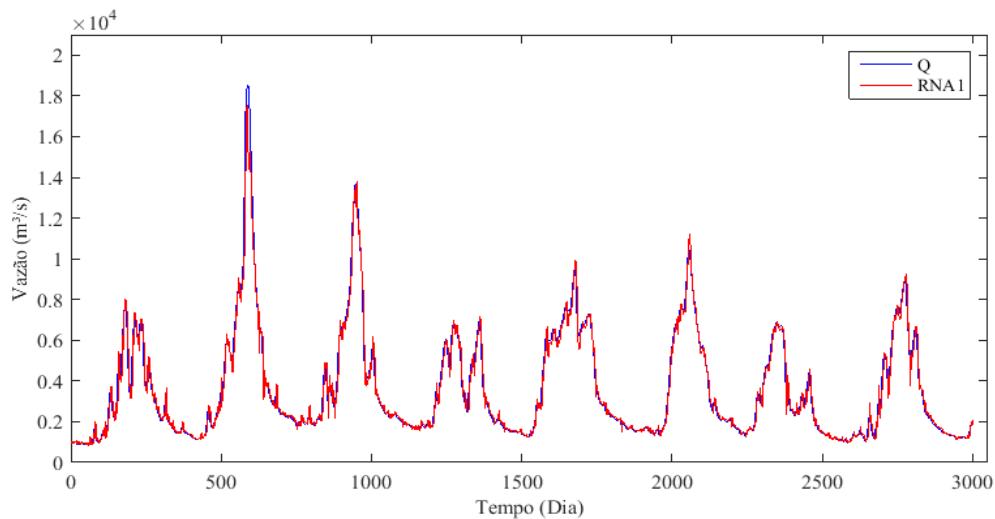


Figura 19- Previsão (RNA1) de 5 dias à frente, referente à bacia de Sobradinho, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

Para a previsão de Três Marias, observou-se um bom desempenho na previsão para o horizonte de 1 dia. Porém, ao passo que se aumenta o horizonte de previsão nesta sub-bacia, os dados apresentam-se com menor homogeneidade, ou seja, com baixo desempenho (Figuras 20 à 25).

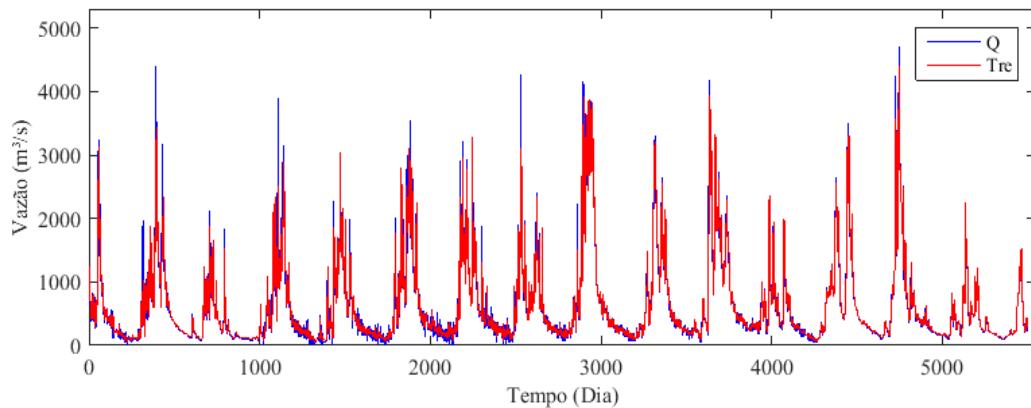


Figura 20- Treinamento (Tre) para previsão de 1 dia à frente, referente à bacia de Três Marias, gerado pelo modelo RNA comparada com a vazão observada (Q).

Fonte: elaboração própria.

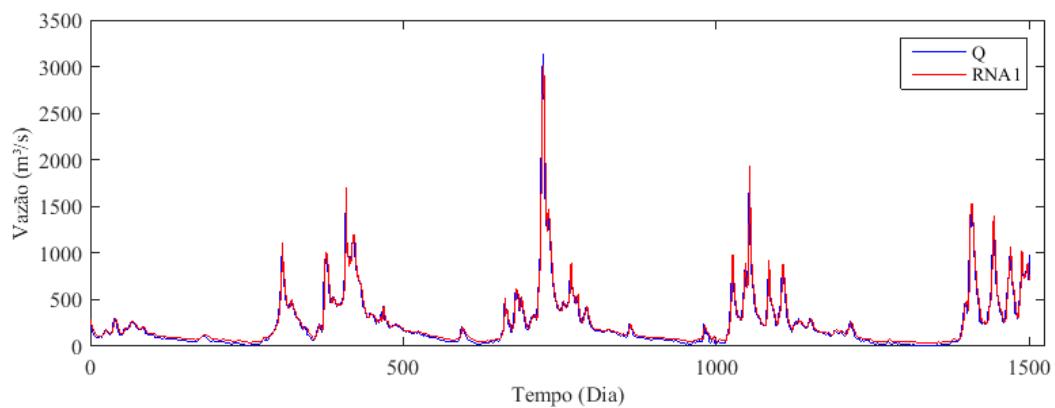


Figura 21- Previsão (RNA1) de 1 dia à frente, referente à bacia de Três Marias, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

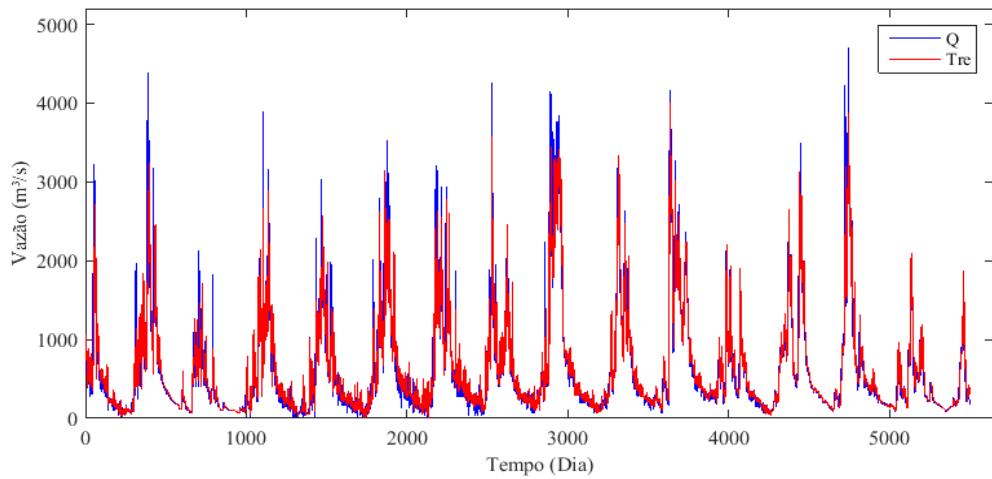


Figura 22- Treinamento (Tre) para previsão de 3 dias à frente, referente à bacia de Três Marias, gerado pelo modelo RNA comparada com a vazão observada (Q).

Fonte: elaboração própria.

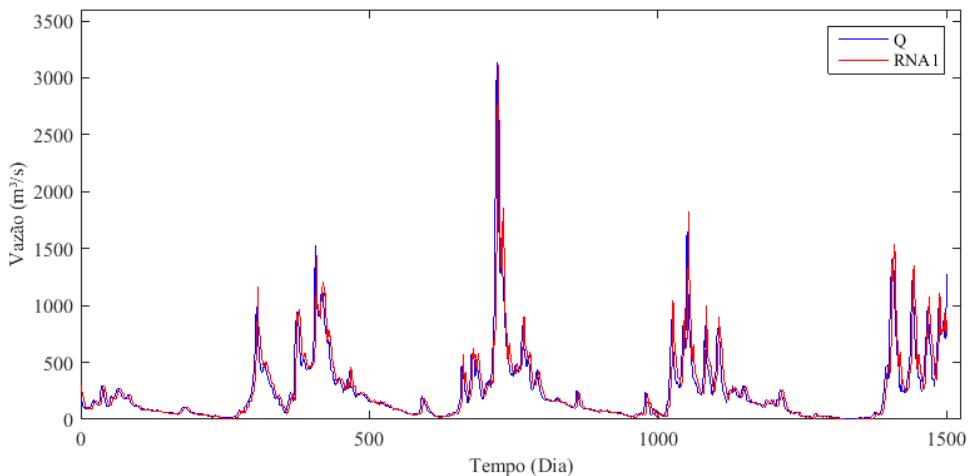


Figura 23- Previsão (RNA1) de 3 dias à frente, referente à bacia de Três Marias, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

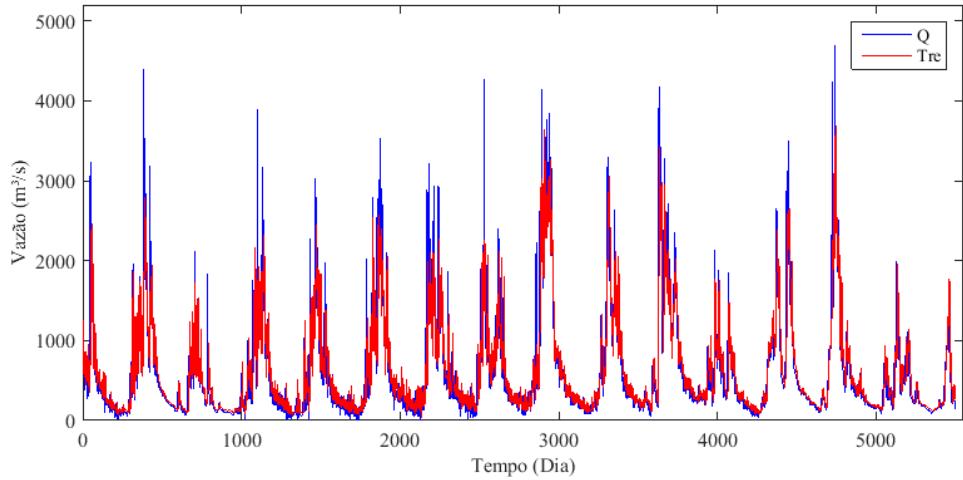


Figura 24- Treinamento (Tre) para previsão de 5 dias à frente, referente à bacia de Três Marias, gerado pelo modelo RNA comparada com a vazão observada (Q).

Fonte: elaboração própria.

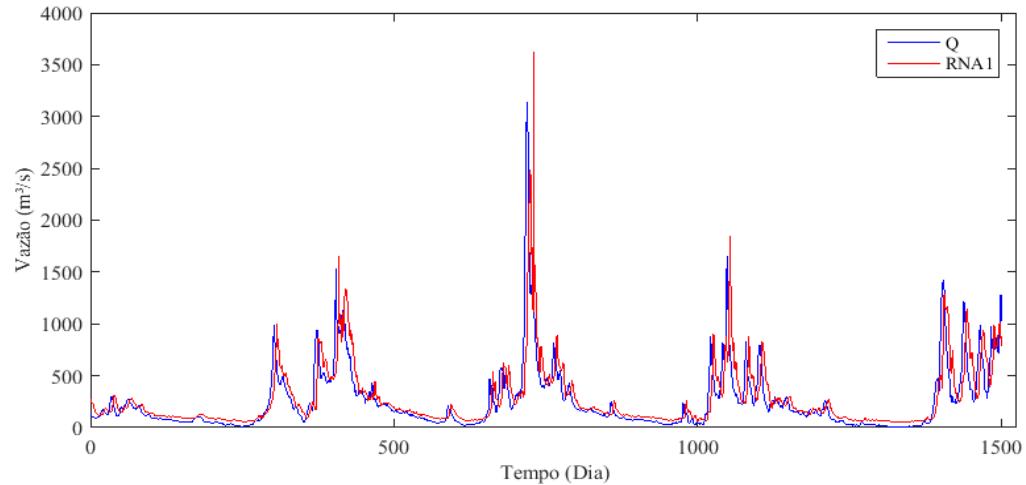


Figura 25- Previsão (RNA1) de 5 dias à frente, referente à bacia de Três Marias, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

Em relação à estação 73015 do rio Keer, observa-se um desempenho inferior às demais bacias, devido a sua baixa homogeneidade apresentada nas figuras de 26 à 31. Porém, o resultado para o horizonte de 1º dia apresenta-se com melhor desempenho que os horizontes para o 3º e 5º dia. Este resultado corrobora com Honorato et al (2017), que apresentou em seu trabalho a previsão de vazão em uma bacia pequena utilizando modelos híbridos.

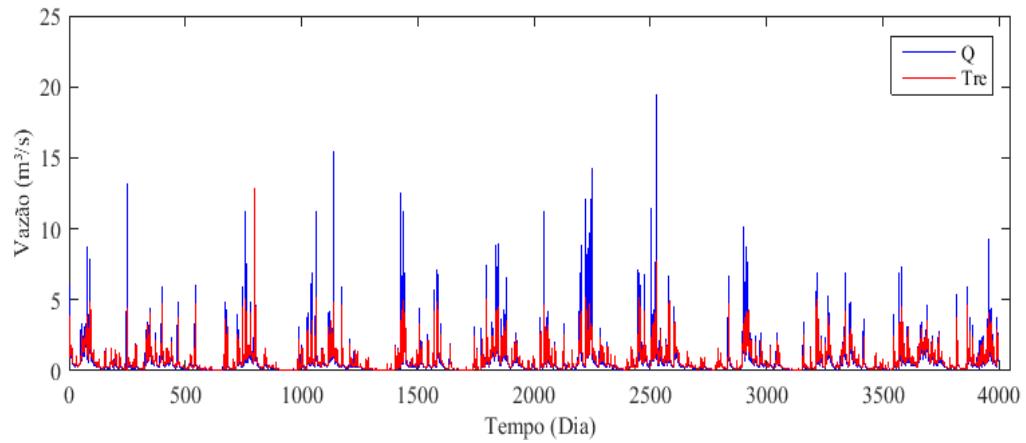


Figura 26- Treinamento (Tre) para previsão de 1 dia à frente, referente ao estação 73015 do Rio Keer, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

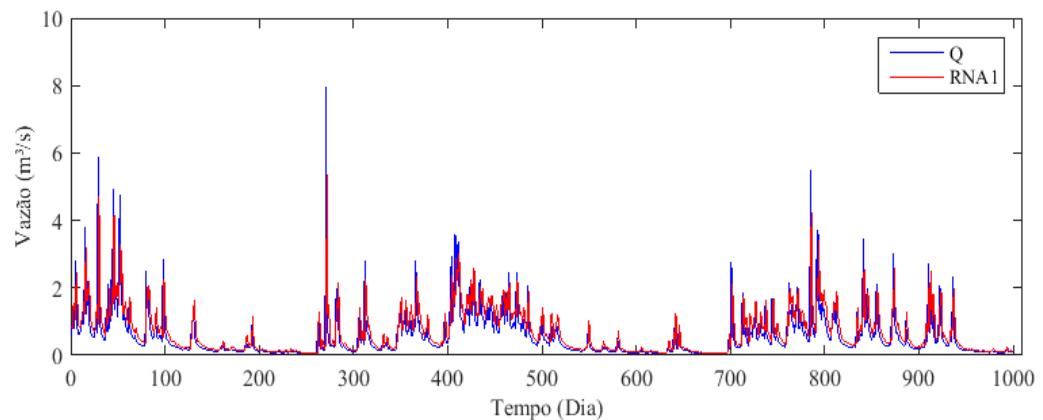


Figura 27- Previsão (RNA1) de 1 dia à frente, referente ao estação 73015 do Rio Keer, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

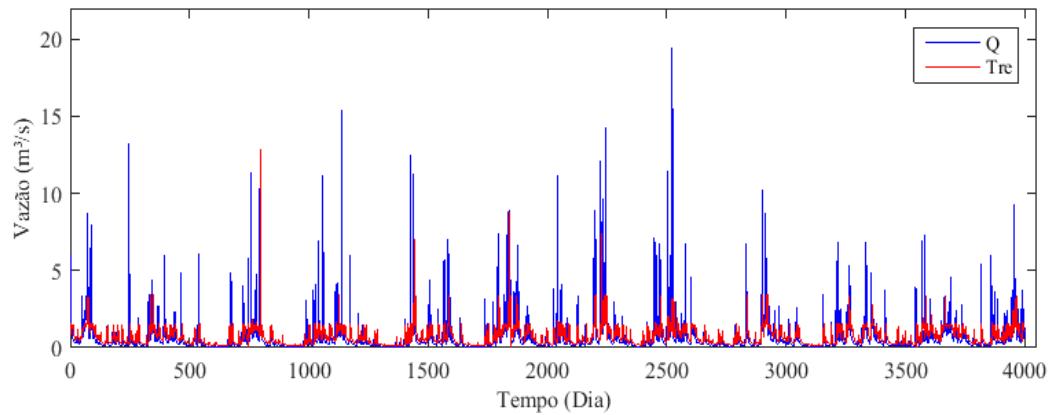


Figura 28- Treinamento (Tre) para previsão de 3 dias à frente, referente ao estação 73015 do Rio Keer, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

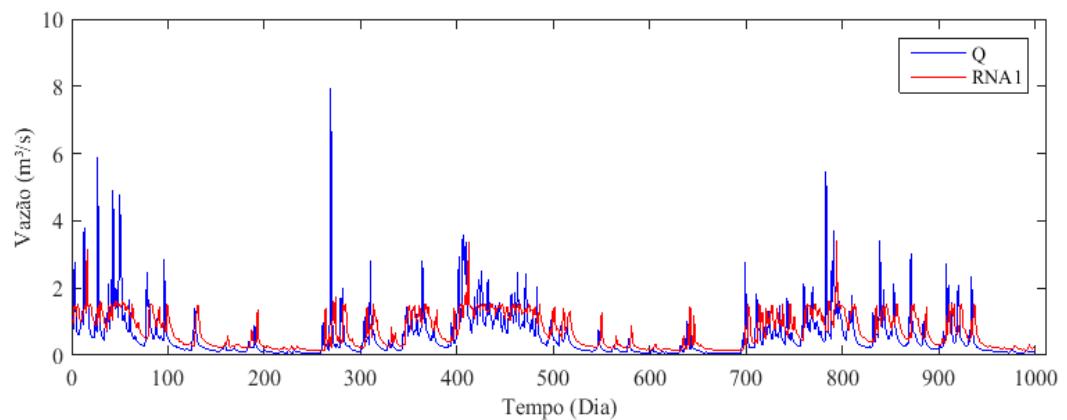


Figura 29- Previsão (RNA1) de 3 dias à frente, referente ao estação 73015 do Rio Keer, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

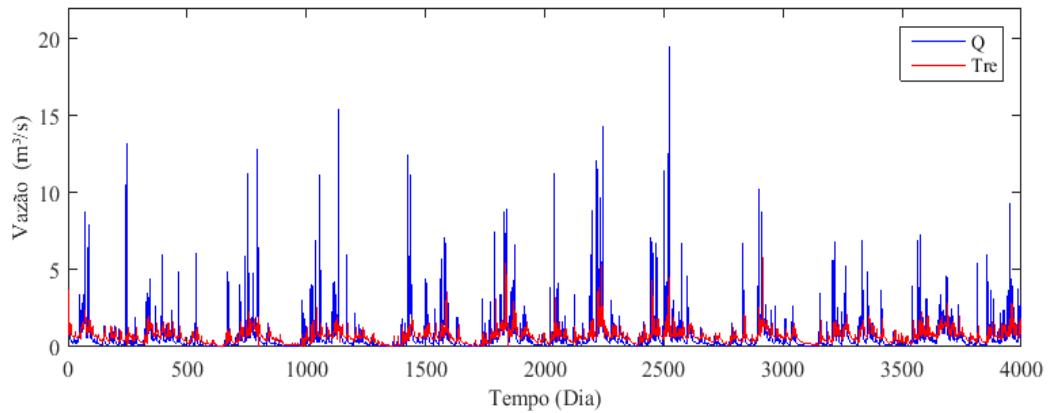


Figura 30- Treinamento (Tre) para previsão de 5 dias à frente, referente ao estação 73015 do Rio Keer, gerado pelo modelo RNA comparado com a vazão observada (Q).

Fonte: elaboração própria.

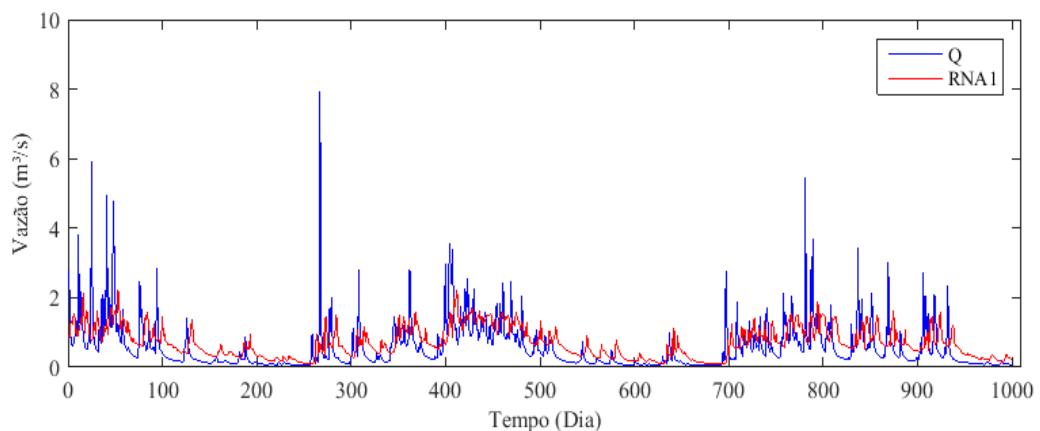


Figura 31- Previsão (RNA1) de 5 dias à frente, referente ao estação 73015 do Rio Keer, gerado pelo modelo RNA comparado com a vazão obserada (Q).

Fonte: elaboração própria.

Comparando os resultados do erro quadrático médio (Tabela 1) RMSE, do modelo entre os três casos, principal objetivo deste trabalho, observou-se que Sobradinho, com maior área de drenagem, apresentou o erro quadrático médio maior, com 125,65663 m³/s a previsão para o horizonte de 1 dia, que Três Marias, com 63,622 m³/s para o mesmo horizonte, com afluentes de uma área de drenagem 10 vezes menor. Já para o Rio Keer, o RSME apresentado foi o menor entre os três casos, com 0,5870 m³/s na previsão para o horizonte de 1 dia, concordando com Honorato et al (2017) que realizou a previsão para o Rio Keer utilizando RNA apenas para um horizonte de 1 e 3 dias.

No que diz respeito à eficiência do modelo, parâmetro CE, observa-se que Sobradinho apresentou resultados mais próximos de 1 do que Três Marias e o Rio Keer, com 0,9993 para o horizonte de um dia em Sobradinho, e 0,9347 e 0,4072 para Três Marias e o rio Keer, respectivamente, na etapa de treinamento. Na etapa de verificação, para o melhor resultado, foi observado o mesmo comportamento onde Sobradinho apresentou 0,9979, Três Marias 0,9571 e o rio Keer 0,3010. Essa diminuição da eficiência do modelo nas três bacias ocorreu devido à forma como cada Sub-bacia responde ao processo de transformação de Chuva em vazão.

Ao se tratar do erro médio absoluto, MARE, observou-se que Sobradinho apresentou os menores resultados em relação ao reservatório de Três Marias e a estação 73015 do rio Keer, para cada horizonte de previsão com 0,01206 para o horizonte de 1 dia; 0,03442 para o horizonte de 3 dias e 0,0065 para o 5º dia na verificação. Já o rio Keer, apresentou os maiores valores chegando a 0,4841 no horizonte de 1 dia, sendo 23 vezes maior que Sobradinho; 1,0054 3 dias à frente, sendo 29 vezes maior e 1,3437 no 5º dia à frente, sendo 207 vezes maior que Sobradinho.

Levando em consideração o melhor horizonte para previsão, os três casos alcançaram os melhores resultados no 1 dia de previsão. Isso ocorreu devido à relação da vazão do dia anterior e da previsão ser alta. Já as previsões para 3 e 5 dias a frente, apresentaram resultados com menor desempenho devido a correlação entre a vazão do dia anterior e do 5º diminuir ao passo que se aumenta o horizonte de previsão, apresentando oscilações em torno dos valores observados.

Ao analisar os resultados estatísticos (Tabela 1) segundo o melhor dia de previsão, observou-se que o erro quadrático médio (RSME), nos três casos analisados, aumentou consideravelmente ao passo que se aumenta a previsão diária, chegando a ser 3 vezes maior, do 1º ao 5º dia, o erro na previsão de Sobradinho, aumentando de 125,6566 ( $m^3/s$ ) no 1º dia para 397,667 ( $m^3/s$ ) no 5º. No rio Keer foi observado um aumento de 0,5870 no 1º dia para 0,6460 no 5º, ou seja, um aumento de 9,1% na etapa de verificação.

No que refere ao erro médio absoluto (MARE), observou-se o mesmo comportamento do RSME, onde, ao passo que o horizonte de previsão aumentou, o erro aumentou de 0,01206 para 0,0065 e em Sobradinho e 0,34805 para 0,90799 em Três Marias, ou seja, um aumento de 2% do primeiro ao quinto dia. Para o rio Keer, houve um aumento de 0,48416 para 1,3437, ou seja, um aumento de 64% no erro.

Já para o coeficiente de eficiência (CE), observou-se uma diminuição da eficiência das previsões (etapa de verificação) ao passo que se aumenta o horizonte de previsão, diminuindo do 1° (0,9979) ao 5° (0,97864) dia em 2% para Sobradinho; do 1° (0,95715) ao 5° (0,55414) dia 42% em Três Marias e do 1° (0,301) ao 5° (0,15327) dia, ou seja, 49% para o rio Keer. Este comportamento também foi observado por Honorato (2017) em suas previsões diárias para o reservatório de Sobradinho.

Além da análise realizada por meio dos parâmetros citados, é possível, também, relacionar a diminuição do desempenho, ao passo que a bacia diminui sua área de drenagem, devido ao uso e ocupação do solo. Pois, mesmo sabendo que a bacia de Três Marias e Sobradinho são Sub-bacias do Rio São Francisco, seria necessário realizar uma análise de uso e ocupação para relacionar a variabilidade do solo e o comportamento da vazão dessas bacias. No que diz respeito ao Rio Keer, baseado em sua menor área, sua variabilidade do uso do solo é menor do que as outras bacias. Dessa forma, ao analisar o comportamento da vazão em rios, seria mais fácil obter boas previsões em bacias maiores devido a maior variedade de informações implícitas nos dados do que em bacias menores.

## 5. CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

O objetivo geral desse trabalho foi o de avaliar o efeito da escala espacial na previsão de vazões diárias por meio das Redes Neurais Artificiais utilizando como entrada vazões passadas, assim como, avaliar a influência do horizonte de previsão no desempenho do modelo RNA. Portanto, ao analisar o que foi exposto, é possível concluir que as Redes Neurais Artificiais, em previsões diárias, apresentam melhor desempenho em horizontes de previsão pequenos, à exemplo do horizonte de um dia.

No tocante a influência da escala espacial, conclui-se que, devido a resposta às precipitações rápidas em pequenas bacias, gerando vazões máximas e cheias de picos, como do rio Keer, a relação de vazões passadas e futuras torna-se reduzida ao se comparar com a relação de vazões em bacias com áreas de drenagem maiores, como foi exposto o desempenho do modelo RNA nas sub-bacias que geram escoamento nos reservatórios de Sobradinho e Três Marias. Além disso, é possível que haja uma melhor previsão em áreas de drenagem maiores devido à quantidade de informações de uso e ocupação do solo que estão implícitas nos dados de vazões disponíveis e o clima de cada bacia. Sendo assim, conclui-se que os modelos clássicos de RNAs possuem dificuldades em prever vazões máximas e prever vazões para horizontes mais longos e em menores áreas de drenagem.

Portanto, recomenda-se a investigação do desempenho do modelo RNA, em diferentes escalas espaciais, para previsões mensais e anuais. Ainda, recomenda-se a pesquisa na eficiência do modelo em bacias com clima, uso e ocupação distintas, porém com áreas de drenagem com pouca diferença em sua dimensão, a fim de avaliar a eficiência nas diferentes previsões. Além disso, recomenda-se também, utilizar a abordagem similar a este trabalho, porém utilizando outros modelos, a fim de verificar qual modelo responde melhor à vazões máximas em pequenas bacias.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AMARAL, K. J. **Estuário do rio Macaé: Modelagem Computacional como Ferramenta para o Gerenciamento Integrado de Recursos Hídricos.** Dissertação (Mestrado em Ciências em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro- RJ, 2003.
- AMORIM, J. F.; SARMENTO, F. J. **Previsão de Seca na Bacia Hidrográfica do Açude Epitácio Pessoa/PB com Base em Redes Neurais Artificiais.** Congresso Brasileiro de Gestão Ambiental e Sustentabilidade, v. 5, p. 1554-1564, 2017.
- ANDRADE, M. A.; MELLO, C. R. DE; BESKOW, S. **Simulação hidrológica em uma bacia hidrográfica representativa dos Latossolos na região Alto Rio Grande-MG.** Revista Brasileira de Engenharia Agrícola e Ambiental-MG. v. 17, n. 1, p. 69–76, 2013.
- ASCE TASK COMMITTEE. **Artificial Neural Networks in Hydrology.II: Hydrologic Applications.** Journal of Hydrologic Engineering, v. 5, n. 2, p. 124-132, 2000b.
- BALLINI, R. **Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais e Redes Neurais Nebulosas.** Tese (Doutorado em Engenharia Elétrica)- Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação. Campinas-SP, 2000.
- BATISTA, A. L. F. **Modelos de Séries Temporais e Redes Neurais Artificiais na Previsão de Vazão.** Dissertação (Mestrado em Modelagem de Sistemas Biológicos)- Universidade Federal de Lavras- MG. Lavras- MG, 2009.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais – Teoria e Aplicações.** 2<sup>a</sup> edição. Editora LTC, 2007.
- BRAVO, J. M.; PEDROLLO, O. C.; COLLISCHONN, W.; PAZ, A. R.; UVÖ, C. B. **Previsões de Curto Prazo de Vazão Afluente ao Reservatório de Furnas Utilizando Redes Neurais.** Revista Brasileira de Recursos Hídricos, v. 13, n.2, p. 77-88, 2008.
- CERQUEIRA, E. O. DE et al. **Redes neurais e suas aplicações em calibração multivariada.** Química Nova, v. 24, n. 6, p. 864–873, dez. 2001.
- CHENG, C.; CHAU, K.; SUN, Y.; LIN, J. **Long-term prediction of discharges in Manwan Reservoir using artificial neural network models.** Advances in neural networks-ISNN 2005,p. 975-975, 2005.
- CBHSF. **Comitê de Bacia Hidrográfica do Rio São Francisco.** Três Marias-MG. Disponível em: < <http://cbhsaofrancisco.org.br/2017/comites-de-afluentes/cbh-do-entorno-da-represa-de-tres-marias-minas-gerais/> > Acesso em 15 de outubro de 2018.
- CORREIA, T. P.; DOHLER, R. E.; DAMBROZ, C. S; BINOTI, H. B. **Aplicação de Redes Neurais Artificiais no Preenchimento de Falhas de Precipitação Mensal**

**Região Serrana do Espírito Santo.** São Paulo, UNESP, Geociências, v. 35, n. 4, p. 560-567, 2016.

**CRUZ, M. F. M.; RODRIGUES, L. D.; VERSIANI, B. R. Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais.** Revista Brasileira de Recursos Hídricos, V. 15, n. 1, p. 121-132, 2010.

**DEBASTIANI, A. B.; SILVA, R. D.; NETO, S. L. R. Eficácia da arquitetura MLP em modo closed-loop para simulação de um Sistema Hidrológico.** Revista Brasileira de Recursos Hídricos, v. 21, n. 4, p. 821-831, 2016.

**FERRAZ, R. C. Sistema Web e Mobile para Estimativa de Evapotranspiração de Referência Utilizando Redes Neurais Artificiais.** Tese (Doutorado em Engenharia Agrícola). Universidade Federal de Santa Maria, Santa Maria-RS, 2013.

**FERREIRA, J. C.; PAIS, M. S.; YAMANAKA, K.; CARRIJO, G. A.; TEIXEIRA, M. B.; SILVA, R. T.; RABELO, C. G. Previsão de Vazão da Bacia do Ribeiro João Leite Utilizando Redes Neurais Artificiais.** Irriga, Botucatu. v. 16, n. 3, p. 339-350, 2011.

**GIMENEZ, D. F. S.; NERY, J. T. Aplicação das Redes Neurais Artificiais no Preenchimento de Dados Diários de Chuva no Estado de São Paulo.** XVII Simpósio Brasileiro de Geografia Física Aplicada.v. 1, p. 1746-1755, 2017.

**GLEICK, P.H.** *Water in crisis. A guide to the world's freshwater resources.* Oxford University Press. 473 pp. 1993.

**GONÇALVES, E. B. Análise de Risco de Crédito com o Uso de Modelos de Regressão Logística, Redes Neurais Artificiais e Algoritmos Genéticos.** Dissertação (Mestrado em Administração). Universidade de São Paulo, São Paulo-SP, 2005.

**GOMES, B. F. M. L; SOUSA, S. S. O; CUNICO, C. Caracterização de Variáveis Fisiográficas da Bacia Hidrográfica do Rio Paraíba-PB: Subsídios para a identificação das unidades ambientais naturais.** XVII Simpósio Brasileiro de Geografia Física Aplicada v. 1, p. 839-843, 2017.

**GUEDES, R. V. D. S. Previsão de Seca na Bacia Hidrográfica do açude Epitácio Pessoa com Base em Redes Neurais Artificiais.** Dissertação de Mestrado (Mestrado em Meteorologia)- Universidade Federal de Campina Grande, Campina Grande-PB, 2011.

**HAYKIN, S. Neural networks- A comprehensive Foudation.** IEEE Press, New York, 1994.

**HAYKIN, S. Redes Neurais – Princípios e Práticas.** 2<sup>a</sup>edição. Editora Bookman, 2001.

**HAYKIN, S. Neural networks and learning machines.** 3<sup>o</sup>ed. New York: Prentice Hall, 2009.

HONORATO, A. G. S. M. **Previsão de Vazões diárias e Mensais Utilizando Modelos Híbridos de Transformadas Wavelet e Redes Neurais Artificiais.** Monografia. João Pessoa-PB, 2017.

HONORATO, A. G. S. M.; SILVA, G. B. L.; SANTOS, C. A. G. **Previsão de Vazão Diário em uma Bacia Pequena Utilizando Modelos Híbridos de Transformadas Wavelet e Redes Neurais Artificiais.** XXII Simpósio Brasileiro de Recursos Hídricos. Florianópolis-SC, 2017.

HEBB, D. O. **The Organization of Behavior – A Neuropsychological Theory.** Editora Wiley& Sons, 1949.

IMRIE, C. E.; DURUCAN, S.; KORRE, A. **River flow prediction using artificial neural networks: generalisation beyond the calibration range.** Journal of Hydrology, v. 233, n. 1,p. 138-153, 2000.

INPE. **Instituto Nacional de Pesquisas Espaciais. TOPODATA – Banco de Dados Geomorfométricos.** São Jose dos Campos-SP, 2011. Disponível em: <<http://www.webmapit.com.br/inpe/topodata/>> Acesso em 15 de Outubro de 2018.

LORENZI, A. **Aplicação de Redes Neurais Artificiais para Estimativa da Resistência à Compressão do Concreto a Partir da Velocidade de Propagação do Pulso Ultra-Sônico.** Tese (Doutorado em Engenharia Civil)- Universidade Federal do Rio Grande do Sul, Porto Alegre-RS, 2010.

LORENZI, A.; SILVA, B. V.; BARBOSA, M. P.; SILVA FILHO, L. C. P. **Artificial Neural Networks Application to Predict Bond Steel-concrete in Pull-out Tests.** IbraconStructuresandMaterialsJournal, v. 10, n. 5, p. 1051-1075, 2017.

LOU, R. F. **Modelagem Hidrológica Chuva-Vazão e Hidrodinâmica Aplicada na Bacia Experimental do Rio Piabanha/RJ.** Dissertação (Mestrado em Engenharia Civil)- Universidade Federal do Rio de Janeiro, Rio de Janeiro-RJ, 2010.

MACHADO,F. W. **Modelagem Chuva-Vazão Mensal Utilizado Redes Neurais Artificiais.** Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental)- Universidade Federal do Paraná, Curitiba-PB, 2005.

MCCULLOCH, W. S.; PITTS, W.A **Logical Calculus of the Ideas Immanent in Nervous Activity.** Bulletin of Mathematical Biophysics, v. 5, p. 115-133, 1943.

NRFA – NATIONAL RIVER FLOW ARCHIVE. 73015 - Keer at High Keer Weir. Disponível em: <http://nrfa.ceh.ac.uk/data/station/spatial/73015>. Acesso em: 26/09/2018.

OIKAWA, R. T.; ISHIKI, H. M. **Modelos Estatísticos e de Redes Neurais Artificiais Utilizados na Predição de Precipitação.** IX Fórum Ambiental de Alta Paulista, v. 9, n. 8, p. 19-34, 2013.

OPERADOR NACIONAL DO SISTEMA (ONS). **Séries Históricas de Vazões.** Disponível em: <[http://www.ons.org.br/operacao/vazoes\\_naturais.aspx](http://www.ons.org.br/operacao/vazoes_naturais.aspx)>. Acesso em: Setembro/2018.

**OPERADOR NACIONAL DO SISTEMA (ONS). Previsão de Vazões Diárias ao Reservatório de Três Marias Usando a Técnica de Redes Neurais.** Relatório. Rio de Janeiro-RJ, 2009.

**PALOSCHI, R. A. ; CECHIM JÚNIOR, C.; JOHAM, J. A. Geotecnologias e Redes Neurais Artificiais para o mapeamento da cultura de cana-de-açucar por meio de serie temporal de EVI no Estado do Paraná.** XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 2015.

**RENNÓ, C. D. Construção de um Sistema de Análise e Simulação Hidrológica: Aplicação a Bacias Hidrográficas.** Tese (Doutorado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos-SP, 2003.

**RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagation errors.** Nature, v. 323, n. 6088, p. 533-538, 1986.

**SANTOS, C. A. G.; SILVA, G. B. L. Daily streamflow forecasting using a wavelet transform and artificial neural network hybrid models.** Hydrological Sciences Journal, v.59, n. 2, p. 312-324, 2014.

**SANTOS, C. C. Modelagem de Bacias Urbanas com Redes Neurais Artificiais.** Dissertação (Mestrado em Engenharia). Universidade São Paulo. São Paulo-SP, 2001.

**SOBRINHO, T. A.; RODRIGUES, D. B. B.; OLIVEIRA, P. T. S.; REBUCCI, L. C. S.; PERTUSSATTI, C. A. Estimativa da Evapotranspiração de Referência Através de Redes Neurais Artificiais.** Revista de Meteorologia, v. 26, n. 2, p. 197- 203, 2011.

**SOUSA, W. S.; SOUSA, F. A. S. 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, 2010.

**TAFNER, M. A.; XEREZ, M.; FILHO, I. W. R. Redes Neurais Artificiais – Introdução e Princípios de Neurocomputação.** Editora EKO/Editora da FURB, 1996.

**TUNDISI, J. G. Recursos hídricos no future: Problemas e Soluções.** Estudos Avançados, São Carlos-SP. V. 22, N 63. 2008.

**TUCCI, C. E. M. Modelos Hidrológicos.** Editora Universidade /UFRGS/Associação Brasileirade Recursos Hídricos, 1998.

**WANDERLEY, H. S.; AMORIM, R. F. C.; CARVALHO, F. O. Interpolação Espacial de Dados Médios Mensais Pluviométricos com Redes Neurais Artificiais.** Revista Brasileira de Meteorologia, v. 29, n. 3, p. 389-396, 2014.

**ZANETTI, S. S.; SOUSA, E. F.; CARVALHO, D. F.; BERNARDO, S. Estimativa de Evapotranspiração de Referência no Estado do Rio de Janeiro usando Redes Neurais Artificiais.** Revista Brasileira de Engenharia Agrícola e Ambiental. V. 12, n. 2, p. 174- 180, 2008.

## ANEXO 1

Rotina do utilizada pelo programa *Matlab* na previsão de vazões

```

clear all;

load keer_diaria.txt          % leitura da serie temporal
x = keer_diaria;
nx=length(x);    % função utilizada para saber o comprimento do
vetor(qtd de dados)
x=x';
y = x;

%Construção dos neurônio de entrada e target com todos os pontos da
serie %

lt=3;% Diz respeito ao dia de previsão. Ex.: prevê o 3 dia
nne =3;                      %numero de neurônios de entrada -
nnint=8;                      % numero de neurônio na camada
hidden
nns = 1;                      %numero de neurônios de saída -

ix = nx-nns+1;
iy = ix-(lt+nne)+ 1;

        % Padrão de organização dos dados%
for k=1:nns % matriz dos neurônios de saída
    t(k,:) = x(nne+lt+(k-1):ix);
    ix=ix+1;
end

for k=1:nne      p(k,:)= y(k:iy);
    iy = iy+1;
end
%riokeer
%treinamento=4000
%verificação=1000
%tresmarias
%treinamento=5500
%verificação=1500
%sobradinho
%treinamento=17000
%verificação=3000

npt = 4000;%Número de valores de vazão utilizada para treinamento da
rede
npv = 1000;% Número de valores de vazão utilizada para verificação da
rede
%nps = 8000;

% Normalização dos dados no intervalo [-1 1]
% Função abaixo utilizada pra normalização dos dados
[p,pmin,pmax,t,tmin,tmax]=premnmx(p,t);

% Seleção dos conjuntos utilizados para treinamento e simulação
posterior

```

```

ptre=p(:,1:npt);%todas as linhas, coluna de 1 à 660 (para o caso mais
geral)
ttre=t(:,1:npt);%todas as linhas, coluna de 1à 660
pver=p(:, npt:npt+npv);% Todas as linhas, colunas de 660 À numero
total de dados
tver=t(:, npt:npt+npv);% Todas as linhas, colunas de 660 À numero
total de dados

% Geração da rede neural com uma camada hidden
net=newff(minmax(ptre),[nnint,1],{'tansig','purelin'},'trainlm');
% Definição dos parâmetros de treinamento5

net.trainparam.goal=0.00001;% TOLERENCIA
net.trainparam.epochs=600;% NUMERO DE ITERAÇÕES (EPOCH)

net=init(net); % inicialização da rede
%net recebe init net
[net,tr]=train(net,ptre,ttre); % treinamento da rede

outtre=sim(net,ptre);
outver=sim(net,pver);

ttre=postmnmx(ttre,tmin,tmax); % transforma para escala original
outtre=postmnmx(outtre,tmin,tmax);
tver=postmnmx(tver,tmin,tmax);
outver=postmnmx(outver,tmin,tmax);

erro(1)=sqrt(((ttre-outtre)*(ttre-outtre)')/length(ttre)); % RMSE
erro(2)=sqrt(((tver-outver)*(tver-outver)')/length(tver));

erro(3)= 1 -(((ttre-outtre)*(ttre-outtre)')/((ttre-mean(ttre))*(ttre-
mean(ttre))')); %CE
erro(4)= 1 -((tver-outver)*(tver-outver)')/((tver-mean(tver))*(tver-
mean(tver))');

erro(5)= sum(abs(ttre-outtre)./ttre)/length(ttre); %MARE
erro(6)= sum(abs(tver-outver)./tver)/length(tver);

restre(:,1) = ttre';
restre(:,2) = outtre';
resver(:,1) = tver';
resver(:,2) = outver';

% plota os valores de saída fornecidos pela rede apos o treinamento
% e os valores de saída utilizados para treinamento

figure
plot(ttre,'b-')
hold on
plot(outtre,'r-');
legend('Q','Tre');

figure
plot(tver,'b-')
hold on
plot(outver,'r-');
legend('Q','RNA1');

```