



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

**LAISI BELLON CESCONETTO**

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA A MODELAGEM  
HIDROLÓGICA DE BACIAS HIDROGRÁFICAS**

JERÔNIMO MONTEIRO - ES

2021

LAISI BELLON CESCO NETTO

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA A MODELAGEM  
HIDROLÓGICA DE BACIAS HIDROGRÁFICAS**

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

Orientador: Prof. Dr. Sidney Sara Zanetti

Coorientador: Prof. Dr. Roberto Avelino  
Cecílio

JERÔNIMO MONTEIRO - ES

2021

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

---

C421a Cesconetto, Laisi Bellon, 1990-  
Aplicação de redes neurais artificiais para a modelagem hidrológica de bacias hidrográficas / Laisi Bellon Cesconetto. - 2021.  
90 f. : il.

Orientador: Sidney Sara Zanetti.

Coorientador: Roberto Avelino Cecílio.

Tese (Doutorado em Ciências Florestais) - Universidade Federal do Espírito Santo, Centro de Ciências Agrárias e Engenharias.

1. Artificial neural networks. 2. Hidrologia. I. Zanetti, Sidney Sara. II. Cecílio, Roberto Avelino. III. Universidade Federal do Espírito Santo. Centro de Ciências Agrárias e Engenharias. IV. Título.

CDU: 630\*38

---

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA A MODELAGEM  
HIDROLÓGICA DE BACIAS HIDROGRÁFICAS**

**Laisi Bellon Cesconetto**

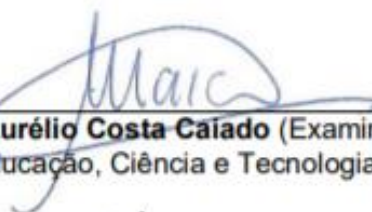
Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutora em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 30 de agosto de 2021.



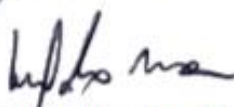
---

**Prof. Dr. Elias Fernandes de Sousa** (Examinador externo)  
Universidade Estadual do Norte Fluminense Darcy Ribeiro



---

**Prof. Dr. Marco Aurélio Costa Caiado** (Examinador externo)  
Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo



---

**Prof. Dr. Michel Castro Moreira** (Examinador externo)  
Universidade Federal de Viçosa



---

**Prof. Dr. Roberto Avelino Cecílio** (Coorientador)  
Universidade Federal do Espírito Santo



---

**Prof. Dr. Sidney Sara Zanetti** (Orientador)  
Universidade Federal do Espírito Santo

## **AGRADECIMENTOS**

Agradeço a Deus por tudo.

Aos meus pais, ao meu irmão e ao meu noivo por todo o suporte, principalmente emocional.

Ao meu orientador, Prof. Dr. Sidney Sara Zanetti, e ao meu coorientador, Prof. Dr. Roberto Avelino Cecílio, pelas orientações e ensinamentos.

Aos meus colegas de pesquisa do Laboratório pela receptividade, cafés, conversas, amizade e discussões enriquecedoras.

Aos que contribuíram para a minha formação acadêmica.

Ao programa de Pós-graduação em Ciências Florestais.

A Universidade Federal do Espírito Santo.

## RESUMO

CESCONETTO, Laisi Bellon. **Aplicação de redes neurais artificiais para a modelagem hidrológica de bacias hidrográficas**. 2021. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Sidney Sara Zanetti. Coorientador: Prof. Dr. Roberto Avelino Cecílio.

A água é um recurso natural imprescindível à manutenção da vida. É um elemento essencial para o desenvolvimento da agricultura, manutenção de ecossistemas, desenvolvimentos de florestas, dentre outros. O crescimento populacional e, conseqüentemente, o aumento na demanda hídrica, tem promovido o desenvolvimento de estudos sobre as técnicas que contribuam positivamente para o gerenciamento dos recursos hídricos. Atualmente existem muitos modelos hidrológicos, porém alguns desses modelos requerem uma grande quantidade de variáveis. Entretanto, os avanços computacionais, atrelado à inteligência artificial, tem permitido a formulação de melhores modelos para a estimativa de variáveis hidrológicas. As redes neurais artificiais (RNA's) são ferramentas eficientes, multivariadas e não lineares, e as que utilizam o método *multilayer perceptron* (MLP) tem sido as mais utilizadas na modelagem dos recursos hídricos. Assim, o objetivo deste trabalho foi desenvolver um método de simulação de vazões diárias totais por meio da utilização de RNA's e avaliar a aplicabilidade para estimar vazões de referência. Foram geradas séries sintéticas de dados diários de vazão a partir de dados diários de precipitação e outras variáveis testadas (área e o mês). O processo de escolha do modelo foi embasado em índices estatísticos. As RNA's utilizadas neste trabalho foram do tipo MLP contendo três camadas. Inicialmente, foi proposto um modelo geral para toda a região aplicada no estudo de caso (estado do Espírito Santo, região Sudeste do Brasil) e o treinamento das redes ocorreu de forma simultânea para toda a base de dados, porém sempre deixando de fora os dados de uma estação fluviométrica, representando a amostra de teste. Além disso, também foram testados modelos aplicados em agrupamentos e em pares de estações. Para o modelo geral, considerando as variáveis de entrada proposta por Vilanova, Zanetti e Cecílio (2019), observou-se que os valores de NSE e NSElog foram superiores a 0,30, com exceção dos testes feitos nas bacias hidrográficas dos Rios São Mateus, Jucu e Santa Joana, onde os resultados foram piores. Constatou que a inclusão das precipitações

acumuladas de dias anteriores, do número do mês e da área de drenagem, simultaneamente, resultou em uma melhoria mais expressiva nos resultados. Já para os modelos aplicados nos agrupamentos houve melhora apenas para o agrupamento 1. Para o modelo aplicado aos pares de estações, de forma geral, não houve melhora nos resultados. Com relação as vazões de referência, houve uma tendência de superestimativa na  $q_{7,10}$  estimada pelos modelos geral, por agrupamento e por pares, em relação a  $q_{7,10}$  estimada com os dados registrados. Entretanto, para a  $q_{90}$  notou-se uma melhora expressiva nos resultados obtidos quando o modelo foi aplicado no agrupamento 2. Já para as vazões médias, observou-se que há uma tendência de superestimativa em relação a  $q_{mid}$  dos dados registrados; entretanto os erros percentuais médios da vazão média simulada pelos modelos na região Metropolitana foram inferiores aos estimados pelo método tradicional de regionalização de vazões. Sendo assim, pode-se considerar que o modelo RNA proposto é viável na estimativa das vazões e a escolha da amplitude espacial de aplicação do método dependerá da disponibilidade de dados registrados e do objetivo do trabalho.

**Palavras chaves:** modelagem hidrológica, rede neural artificial, modelo chuva-vazão, simulação de vazão.

## ABSTRACT

CESCONETTO, Laisi Bellon. **Application of artificial neural networks for the hydrological modeling of watersheds**. 2021. Thesis (Doctor of Forest Science) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Adviser: Dr. Sidney Sara Zanetti. Co-adviser: Prof. Dr. Roberto Avelino Cecílio.

Water is an essential natural resource for the maintenance of life. It is an essential element for the development of agriculture, ecosystem maintenance, forest development, among others. Population growth and, consequently, the increase in water demand, has promoted the development of studies on techniques that positively contribute to the management of water resources. Currently there are many hydrological models, but some models model a large amount of variables. However, computational advances, coupled with artificial intelligence, have provided better models for estimating hydrological variables. Artificial neural networks (ANN's) are efficient, multivariate and nonlinear tools, and that use the multilayer perceptron method (MLP) has been the most used in the modeling of water resources. Thus, the objective of this work was to develop a method of simulation of total flows through the use of ANN and to evaluate an applicability to estimate reference flows. Synthetic flow data series were generated from source data and other variables tested (area and month). The model choice process was based on statistical indices. The RNA's used in this work were of the MLP type containing three layers. Initially, a general model was proposed for the entire region applied in the case study (Espírito Santo state, Southeast region of Brazil) and the training of networks occurred simultaneously for an entire database, but always leaving out the data of a fluviometric station, representing a test sample. In addition, models were also tested in clusters and in pairs of stations. For the general model, considering the input variables proposed by Vilanova, Zanetti and Cecílio (2019), it was observed that the values of NSE and NSElog were higher than 0.30, with the exception of the tests carried out in the hydrographic basins of the São Mateus, Jucu and Santa Joana Rivers, where the results were worse. It found that the inclusion of accumulated rainfall from previous days, the number of the month and the drainage area, simultaneously, resulted in a more expressive improvement in the results. As for the models in clusters, there was no improvement only for cluster 1. For the model applied to pairs of stations, in general, there was no improvement in the results. Regarding the reference flows, there was a tendency to overestimate the  $q_{7,10}$  evaluated by general models, by grouping and by pairs and in relation to  $q_{7,10}$  estimated



with the recorded data. However, for  $q_{90}$  there was a significant improvement in the results obtained when the model was applied in group 2. As for the average flows, it was observed that there is a tendency to overestimate the  $q_{mld}$  of the recorded data; however, the average percentage errors of the average flow simulated by the models in the Metropolitan region were lower than those estimated by the traditional method of regionalization of flows. Thus, it can be considered that the proposed ANN model is viable in the estimation of flows and the choice of the spatial amplitude of the method application will depend on the availability of recorded data and the objective of the work.

**Keywords:** hydrological modeling, artificial neural network, rainfall-runoff model, flow simulation.

## LISTA DE FIGURAS

Figura 1 – Representação de um neurônio artificial.....	22
Figura 2 – Esquema representativo da metodologia proposta.....	34
Figura 3 – Distribuição dos <i>pixels</i> centrais com dados de precipitação diária no estado do Espírito Santo.....	42
Figura 4 – Localização das estações fluviométricas e das bacias hidrográficas inseridas no estado do Espírito Santo.....	45
Figura 5 - Fluxograma de obtenção dos dados topográficos digitais (etapa 1) e delimitações das sub-bacias hidrográficas (etapa 2). ....	49
Figura 6 – Áreas de drenagem de cada estação fluviométrica utilizada neste estudo.	50
Figura 7 – Análises BoxPlot das vazões de referência das estações fluviométricas, em $L s^{-1} km^{-2}$ , e do coeficiente de escoamento superficial - C, adimensional.....	53
Figura 8 - Índices estatísticos médios dos testes das RNA's para as estações fluviométricas utilizadas, localizadas no estado do Espírito Santo: NSE, NSElog e $r^2$ (a); e RMSE, em $L s^{-1} km^{-2}$ .....	54
Figura 9 – NSE resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 + $P_{t-6}$ (b); Cenário 1 + $P_{t-6}$ e $P_{t-7}$ (c); Cenário 1 + $P_{t-6}$ , $P_{t-7}$ e $P_{t-8}$ (d); Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ e $P_{90}$ (e); e Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ , $P_{90}$ , Área e Mês (f).....	56
Figura 10 – NSElog resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 + $P_{t-6}$ (b); Cenário 1 + $P_{t-6}$ e $P_{t-7}$ (c); Cenário 1 + $P_{t-6}$ , $P_{t-7}$ e $P_{t-8}$ (d); Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ e $P_{90}$ (e); e Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ , $P_{90}$ , Área e Mês (f).....	57
Figura 11 – $R^2$ resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 + $P_{t-6}$ (b); Cenário 1 + $P_{t-6}$ e $P_{t-7}$ (c); Cenário 1 + $P_{t-6}$ , $P_{t-7}$ e $P_{t-8}$ (d); Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ e $P_{90}$ (e); e Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ , $P_{90}$ , Área e Mês (f).....	58
Figura 12 – RMSE, em $L s^{-1} km^{-2}$ , resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 + $P_{t-6}$ (b); Cenário 1 + $P_{t-6}$ e $P_{t-7}$ (c);	

Cenário 1 + $P_{t-6}$ , $P_{t-7}$ e $P_{t-8}$ (d); Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ e $P_{90}$ (e); e Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ , $P_{90}$ , Área e Mês (f).....	59
Figura 13 – Vazões específicas ( $L s^{-1} km^{-2}$ ) diárias observadas e estimadas pelo modelo (estação fluviométrica 57830000) no ano de 2005.....	62
Figura 14 – Gráficos de dispersão das vazões específicas ( $L s^{-1} km^{-2}$ ) diárias observadas e estimadas pelo modelo (estação fluviométrica 57830000) com as seguintes variáveis de entrada: Cenário 1 (a) e Cenário 1 + $P_{t-6}$ , $P_{t-7}$ , $P_{t-8}$ , $P_{60}$ e $P_{90}$ (b).....	63
Figura 15 - Hidrógrafa contendo as vazões diárias específicas no ano de 2005 das estações fluviométricas: 57830000- Rio Itabapoana (a); 57460000 – Rio Itapemirim (b); 57230000 – Rio Jucu (c); 57130000 – Rio Santa Maria (d); 56990990 – Rio Guandu (e); 56993002 – Rio Santa Joana (f); e 55800005 – Rio São Mateus (g).....	64
Figura 16 – Resultados obtidos com a aplicação de uma rede para cada agrupamento: NSE (a); NSElog (b); $r^2$ (c); e RMSE (d), em $L s^{-1} km^{-2}$ .....	68
Figura 17 – Índices médios obtidos com a aplicação das RNA's para o modelo geral e para os modelos por agrupamento: NSE, NSElog e $r^2$ (a) e RMSE (b), em $L s^{-1} km^{-2}$ .....	69
Figura 18 – Localização dos pares das estações fluviométricas.....	71
Figura 19 – Resultados obtidos para o modelo proposto em pares de estações: NSE (a); NSElog (b); $r^2$ (c); e RMSE (d), em $L s^{-1} km^{-2}$ .....	72
Figura 20 – Índices médios obtidos com a aplicação das RNA's para os modelos geral, por agrupamento e por pares de estações: NSE, NSElog e $r^2$ (a) e RMSE (b), em $L s^{-1} km^{-2}$ .....	73
Figura 21 – Hidrógrafa contendo as vazões diárias observadas ( $q$ observada) e as estimadas, durante o ano de 2005, para as RNA's do modelo geral ( $q$ estimada 1), para os agrupamentos ( $q$ estimada 2) e para os pares ( $q$ estimada 3), da estação fluviométrica 57170000.....	75
Figura 22 – $q_{7,10}$ (a), $q_{90}$ (b), $q_{mld}$ (c) estimadas com os dados observados, com as RNA's e as vazões regionalizadas (AGERH, 2017), em $L s^{-1} km^{-2}$ , nas estações fluviométricas inseridas na área em estudo. ....	77
Figura 23 – Vazões de referências específicas médias ( $q_{7,10}$ , $q_{90}$ e $q_{mld}$ ) obtidas com os dados observados (Obs.), com as séries sintéticas resultantes do modelo geral	

(Geral), por agrupamentos (Agrup.) e por pares de estações (Pares), além das vazões regionalizadas (Reg.) (AGERH, 2017), em $L s^{-1} km^{-2}$ .....	79
Figura 24 – Representação das macrorregiões do estado do Espírito Santo.....	79
Figura 25 – Erros percentuais médios, em %, obtidos entre as séries sintéticas resultantes do modelo geral (Geral), por agrupamentos (Agrup.) e por pares de estações (Pares), e das vazões regionalizadas (Reg.) (AGERH, 2017), com as vazões de referência observadas (Obs.).....	80

## LISTA DE TABELA

Tabela 1 – Identificação, localização e área de drenagem (Ad) das estações fluviométricas existentes no estado do Espírito Santo.....	42
---	----

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	15
<b>2. OBJETIVOS</b> .....	17
<b>2.1. Objetivo geral</b> .....	17
<b>2.2. Objetivos específicos</b> .....	17
<b>3. REVISÃO DE LITERATURA</b> .....	18
<b>3.1. Modelos hidrológicos</b> .....	18
<b>3.2. Redes neurais artificiais</b> .....	21
<b>3.3. RNA's aplicadas em recursos hídricos</b> .....	24
<b>3.4. RNA's aplicadas na regionalização de dados hidroclimáticos</b> .....	32
<b>4. METODOLOGIA</b> .....	34
<b>4.1. Modelos propostos utilizando redes neurais artificiais</b> .....	34
<b>4.2. Índices estatísticos aplicados na avaliação dos modelos</b> .....	38
<b>4.3. Estudo de caso</b> .....	40
4.3.1. Caracterização da área em estudo.....	40
4.3.2. Dados utilizados .....	41
4.3.3. Análise preliminar dos dados.....	48
4.3.4. Delimitação da área de drenagem das estações fluviométricas .....	49
4.3.5. Determinação das vazões de referência e comparação dos resultados	51
<b>5. RESULTADOS E DISCUSSÃO</b> .....	53
<b>5.1. Análise preliminar dos dados fluviométricos</b> .....	53
<b>5.2. Aplicação da metodologia proposta</b> .....	54
<b>5.3. Estimativa e comparação de vazões de referência</b> .....	76
<b>6. CONCLUSÕES</b> .....	82
<b>7. REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	83

## 1. INTRODUÇÃO

A água é um recurso natural imprescindível à manutenção da vida. É um elemento essencial para o desenvolvimento da agricultura, pecuária, geração de energia, manutenção de ecossistemas, desenvolvimentos de florestas, dentre outros. O crescimento populacional e, conseqüentemente, o aumento na demanda hídrica, tem feito com que os estudos sobre as técnicas que contribuam positivamente para o gerenciamento dos recursos hídricos avancem cada vez mais.

Entre as técnicas desenvolvidas para o estudo dos recursos hídricos tem-se a modelagem hidrológica, cujo objetivo é simular a hidrologia de bacias hidrográficas. Essa simulação pode ser aplicada para prever a mudança na bacia em função de uma alteração de determinado conjunto de variáveis (clima, uso da terra, dentre outros), prevendo, dessa forma, eventos extremos, tais como inundações, e vazões baixas, que podem levar a escassez hídrica. (PFANNERSTILL; GUSE; FOHRER, 2014; ABBASPOUR et al., 2015; ANDRADE et al., 2017; ANDRADE et al., 2019).

Nesse sentido, as simulações hidrológicas têm sido bastante utilizadas no planejamento e gestão dos recursos hídricos, especialmente por intermédio dos modelos chuva-vazão (YASEEN et al., 2015). Todavia, a transformação de chuva em vazão é um dos processos mais complexos para se entender e modelar, devido à grande quantidade de variáveis que são modificadas no espaço e também no tempo (SEDKI; OUAZAR; MAZOUZI, 2009).

Existe um grande número de modelos hidrológicos destinados a simular a transformação chuva-vazão, os quais possuem características únicas e aplicações específicas, entretanto alguns desses modelos requerem o conhecimento de uma grande quantidade de variáveis de entrada (DEVIA; GANASRI; DWARAKISH, 2015; ULIANA et al., 2019), os quais são de disponibilidade restrita para a maior parte das bacias hidrográficas do Brasil. Outro problema na aplicação dos modelos hidrológicos está relacionado ao fato das informações relativas a chuva e vazão serem obtidas de estações de monitoramento que estão instaladas em bacias com extensas áreas de drenagem, apresentando, em conseqüência disso, restrições quanto ao uso desses dados em seções com áreas menores (PRUSKI et al., 2015). Além disso, a baixa qualidade nos dados registrados também é um empecilho na aplicação de muitos modelos.

Em contrapartida, nos últimos anos, os avanços computacionais, atrelado a inteligência artificial tem permitido a formulação de modelos para a estimativa de variáveis hidrológicas. Bons exemplos são modelos que utilizam as redes neurais artificiais (RNA's) (OLYAIE et al., 2015; ARAÚJO et al., 2020; BRUBACHER; DE OLIVEIRA; GUASSELLI, 2020; MENDONÇA et al., 2021; BAKHSHAEI et al., 2020; JIMENO-SÁEZ et al., 2018; YASEEN et al., 2015; .VILANOVA; ZANETTI; CECÍLIO, 2020; VILANOVA; ZANETTI, CECÍLIO, 2019; CHENG et al. 2020; WAGENA et al., 2020; HASSAN, HASSAN, 2020 ).

Segundo Favoreto et al. (2001), dentro da área da modelagem hidrológica, a previsão de séries de vazão e de precipitação é uma das áreas mais promissoras para o uso de RNA's. Segundo Maier e Dandy (2000), os modelos empíricos baseados em RNA's têm gerado resultados satisfatórios e animadores na previsão de variáveis hidrológicas

As RNA's são ferramentas eficientes, com potencial para a modelagem de fenômenos complexos, multivariados e não lineares, sem a necessidade de se fazer suposições sobre a interação das variáveis que compõem os sistemas (RIAD et al., 2004). As redes que utilizam o método *multilayer perceptron* (MLP) tem sido as mais utilizadas na modelagem dos recursos hídricos (DEBASTIANI; SILVA; RAFAELI NETO, 2016).

Muitos estudos têm sido desenvolvidos com a aplicação de RNA's. Em estudo para a bacia do Rio Itapemirim, no Espírito Santo, Vilanova, Zanetti e Cecílio (2020) estimaram séries de vazões obtendo resultados satisfatórios quando a rede foi treinada para uma bacia área de drenagem intermediária e testada em áreas de drenagem menores; porém para áreas de drenagem maiores foram obtidos resultados insatisfatórios. Vários outros estudos, com aplicação semelhante ao de Vilanova, Zanetti e Cecílio (2020) foram desenvolvidos para outras áreas (por exemplo: AICHOURI et al., 2015; YASEEN et al., 2016; JIMENO-SÁEZ et al., 2018).

Diante disso, notou-se que as RNA's possuem potencial para serem utilizadas na extrapolação de dados hidrológicos para áreas com diferentes características. Assim, o desenvolvimento de modelos por meio de RNA's, com boa capacidade de generalização dos dados climáticos e hidrológicos constitui uma ferramenta importante para o auxílio no planejamento e gestão dos recursos hídricos nas bacias que não possuem redes de monitoramento hidrológico ou com dados escassos.



## **2. OBJETIVOS**

### **2.1. Objetivo geral**

O presente estudo teve como objetivo desenvolver e testar um método geral de simulação de vazões diárias em bacias hidrográficas com diferentes características climáticas e fisiográficas, por meio da utilização de redes neurais artificiais (RNA's), considerando a capacidade de extrapolação das RNA's quando aplicadas em bacias não utilizadas em seu processo de treinamento.

### **2.2. Objetivos específicos**

- Desenvolver modelos de simulação de vazão por meio de redes neurais artificiais; e
- Após a seleção do melhor modelo de simulação, avaliar sua aplicabilidade para estimar as vazões de referência:  $Q_{7,10}$ ,  $Q_{90}$  e  $Q_{mld}$ .

### **3. REVISÃO DE LITERATURA**

#### **3.1. Modelos hidrológicos**

Um modelo é definido como a representação de uma realidade, seja ela um objeto ou um sistema, cujo principal objetivo é o auxílio para entender os processos reais e buscar respostas para diferentes incógnitas, por meio de uma linguagem de fácil entendimento e acesso (TUCCI, 2005).

Para Devia, Ganasri e Dwarakish (2015) , o modelo mais adequado é o que fornece resultados que mais se aproximam da realidade, de forma a simplificar os parâmetros e a complexidade. Segundo Rennó e Soares (2000), não existe um único modelo que seja melhor que os demais, mas existe o melhor modelo que represente determinado fenômeno, sendo esses classificados com base no tipo de variável empregada na modelagem, na relação entre essas variáveis, na representação dos dados, nas relações espaciais e de dependência temporal.

Aplicado à gestão e planejamento dos recursos hídricos, os modelos hidrológicos são representações da realidade que auxiliam no entendimento dos processos reais e na busca por resposta de variáveis que envolvam o comportamento da bacia hidrográfica (TUCCI, 2005). Além disso, possibilitam prever o comportamento da bacia sob condições diversas como, por exemplo, na simulação de cenários envolvendo alterações na cobertura vegetal e mudanças climáticas.

De acordo com Tucci (2005), os modelos hidrológicos são classificados, com relação a sua estrutura, em modelos de comportamento, otimização ou de planejamento. Os modelos de comportamento representam o comportamento de um determinado sistema, ou seja, faz previsões do possível comportamento de uma variável em decorrência de uma determinada ação; os modelos de otimização buscam encontrar a melhor solução de um sistema em nível de projeto; e os modelos de planejamento simulam cenários em escalas maiores, ou seja, trabalham na escala de região ou de bacia hidrográfica.

Dentre as diversas aplicações dos modelos, o seu uso no planejamento e gerenciamento dos recursos hídricos tem sido necessário devido as redes de monitoramento fluviométricos serem incipientes, ou inexistentes, podendo ser aplicado em: análise de consistência e preenchimento de falhas, previsão de vazão,

dimensionamento e previsão de cenários de planejamento, e simulação dos efeitos resultantes da modificação do uso do solo (ALMEIDA; SERRA, 2017; SARAIVA; FERNANDES; NAGHETTINI, 2011).

Dessa forma, o modelo hidrológico é definido como a representação matemática do fluxo de água, e de seus componentes, sobre a superfície terrestre, permitindo solucionar, estimar e simular os processos inerentes ao comportamento hidrológico em uma bacia hidrográfica (TUCCI, 2005). Entretanto, o maior desafio da hidrologia é a adaptação desses modelos de acordo com o comportamento hidrológico e a disponibilidade de dados na área de estudo (FENICIA; MCDONNELL; SAVENIJE, 2008; MACHADO; MELLO JUNIOR; WENDLAND, 2017).

Os modelos hidrológicos podem ser classificados, ainda, de acordo com o tipo de variáveis utilizadas na modelagem (estocásticos ou determinísticos), o tipo de relações entre essas variáveis (empíricos ou conceituais), a forma de representação dos dados (discretos ou contínuos), a existência ou não de relações espaciais (concentrados ou distribuídos) e a existência de dependência temporal (estacionários ou dinâmicos) (TUCCI, 2005).

Nos modelos estocásticos há ao menos uma variável com comportamento aleatório; já nos modelos determinísticos os conceitos de probabilidade são ignorados.

Um modelo hidrológico é dito discreto quando ocorre a modelagem de períodos isolados da série, normalmente buscando representar eventos de cheia ou recessão; já os modelos contínuos representam longos períodos da série, muitas vezes, contemplando épocas de comportamentos hidrológicos diferentes (WHEATER, 2007).

Modelos ditos concentrados são aqueles que não consideram a variabilidade espacial das variáveis hidrológicas envolvidas no processo modelado, sendo o tempo a principal variável; já os modelos distribuídos possuem a capacidade de representar a variabilidade espacial das características físicas da bacia hidrográfica (WHEATER, 2007).

Nos modelos estacionários, há a descrição do fenômeno em determinado momento com os parâmetros não variando no tempo; já nos modelos dinâmicos, os parâmetros podem variar no tempo, sendo, portanto, as variáveis função do tempo (MARINHO FILHO et al., 2012).

Os modelos empíricos normalmente utilizam séries de dados temporais disponíveis para identificar a estrutura do modelo e os parâmetros correspondentes a

ele, não necessitando, inicialmente, conhecer o comportamento da bacia hidrográfica. Já os modelos conceituais relacionam características do processo, embora mantenham razoável empirismo nos parâmetros das equações envolvidas (TUCCI, 2005).

Diversos estudos apontam que o uso e a cobertura do solo têm um papel fundamental na quantidade e, sobretudo, na qualidade da água. Vanzela, Hernandez e Franco (2010) correlacionaram os dados de ocupação, disponibilidade e qualidade da água e verificaram que áreas cobertas com florestas, rodovias pavimentadas e com pastagem tiveram um aumento na quantidade e melhoria na qualidade da água superficial. Já nas áreas habitadas, com agricultura e mata degradada, de modo geral, houve redução da vazão específica e da qualidade da água. Tal fato, de acordo com os autores, pode ser explicado devido a capacidade de manutenção do armazenamento de água pela vegetação, fazendo com que o escoamento de base contribua predominantemente para as alterações nas vazões específicas.

De acordo com Villela e Mattos (1975) a área de drenagem de uma bacia hidrográfica é o elemento básico para o cálculo da maioria das características físicas que a representam. É um elemento fundamental para definir a potencialidade hídrica com grande importância na resposta hidrológica, uma vez que quanto maior a área, menos pronunciados serão os picos de enchentes, pois maior será o tempo para que toda a bacia contribua simultaneamente com a vazão em seu exutório (TUCCI, 2005).

O fator de forma representa a relação entre a largura média e o comprimento axial da bacia, e indica a tendência de ocorrência de inundações, uma vez que em bacias com fator de forma baixo há uma menor possibilidade de uma chuva intensa cobrir toda a sua extensão do que em uma bacia com mesma área e fator de forma maior. Além disso, para Villela e Mattos (1975) em bacias com fator de forma maior a contribuição dos afluentes atinge o rio principal em vários pontos, afastando da condição ideal da bacia circular, em que a concentração do deflúvio ocorre em um só ponto.

A declividade de uma bacia está diretamente relacionada a sua topografia e tem influência direta na resposta hidrológica, já que a velocidade de escoamento superficial depende, em grande parte, da declividade da bacia hidrográfica, principalmente nas bacias com menores áreas de drenagem (BORSATO; MARTONI, 2004). Além disso, de acordo com Villela e Mattos (1975) a topografia também exerce

influência sobre os fatores meteorológicos como a temperatura, a precipitação e a evapotranspiração, entre outros, que variam em função da altitude da bacia.

A aplicação dos modelos hidrológicos conceituais tem gerado bons resultados. Entretanto, esse tipo de modelo exige algoritmos complexos, grande quantidade de parâmetros e dados (meteorológicos, solo, vegetação e topografia) e a necessidade de ir a campo para a realização de levantamentos. Sendo assim, uma alternativa é a utilização dos modelos empíricos, os quais relacionam entradas e saídas através de funções matemáticas e estatísticas, como é o caso dos modelos que relacionam a chuva (entrada) e a vazão (saída) (JAIN; KUMAR, 2007; NOURANI; KISI; KOMASI, 2011; VERTESSY et al., 1993; VILANOVA; ZANETTI,; CECÍLIO, 2019; VILANOVA; ZANETTI; CECÍLIO, 2020).

Os modelos empíricos baseados em Rede Neural Artificial (RNA) têm gerado resultados satisfatórios e animadores na previsão de variáveis hidrológicas (MAIER; DANDY, 2000; YASEEN et al., 2015, VILANOVA; ZANETTI; CECÍLIO, 2019; VILANOVA; ZANETTI; CECÍLIO, 2020), além de outras técnicas de inteligência artificial. Segundo Özçelik et al., (2010) as RNA's têm recebido atenção especial devido a sua metodologia ser passível de comparação com a modelagem estatística, podendo ser utilizada sem necessidade de uma suposição restritiva de um modelo estatístico específico.

### **3.2. Redes neurais artificiais**

As Redes Neurais Artificiais (RNA's) são técnicas computacionais que apresentam um modelo matemático, cujo funcionamento é inspirado no sistema nervoso biológico dos organismos inteligentes, adquirindo o conhecimento através da experiência (HAYKIN, 2001). A RNA pode ser entendida como um conjunto de nós, ditos neurônios, que são organizados em camadas sucessivas de forma análoga ao cérebro humano (ARAÚJO; DANTAS NETO; SOUZA FILHO, 2015).

A primeira ideia básica da rede neural foi desenvolvida por McCulloch e Pitts, os quais unificaram os estudos na neurofisiologia e da lógica matemática, desenvolvendo um neurônio artificial com os conceitos de peso e função de ativação. Nessa primeira ideia, o neurônio biológico foi representado como uma unidade de processamento

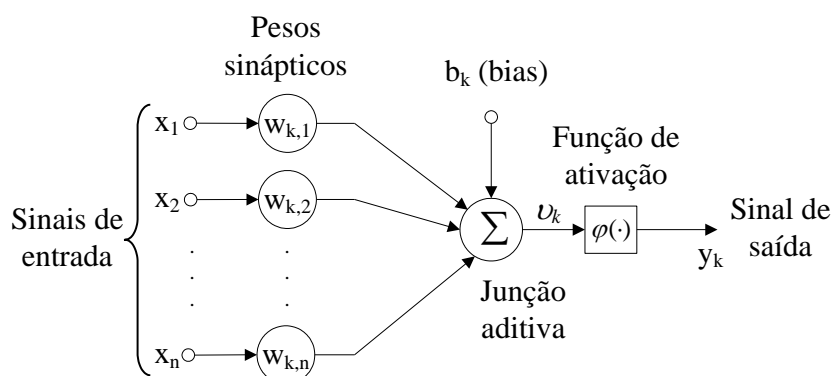
binária, constatando que estas unidades são capazes de executar operações lógicas (MCCULLOCH; PITTS, 1990).

Em 1949, Hebb apresentou a hipótese acerca da maneira com que a força das sinapses no cérebro se comporta em função de uma mudança, sugerindo que as conexões que são ativadas simultaneamente tendem a se fortalecer (HEBB, 1949).

Um dos tipos de RNA's mais utilizadas atualmente foi arquitetada em 1950 por Frank Rosenblatt e denominada de *perceptron*, a qual possui uma camada que consegue aprender e identificar os padrões de acordo com as regras de Hebb (HAYKIN, 2001; VILANOVA; ZANETTI; CECÍLIO, 2019; VILANOVA; ZANETTI; CECÍLIO, 2020). No ano de 1986 lançou-se o algoritmo de treinamento *backpropagation*, o qual permite o ajuste da RNA com mais de uma camada (RUMELHART; HINTON; WILLIAMS, 1986).

O neurônio artificial possui os elementos básicos (SILVA; SPATTI; FLAUZINO, 2010), conforme apresentados na Figura 1.

Figura 1 – Representação de um neurônio artificial.



Fonte: HAYKIN (2001).

Onde,  $x_n$  são as entradas,  $w_{k,n}$  são os pesos, sendo  $k$  igual ao número do neurônio,  $\Sigma$  é a junção aditiva (soma todos os sinais de entrada),  $b_k$  é o limiar (bias) do neurônio,  $u_k$  é a resultante entre o combinador linear e o limiar,  $\varphi(\cdot)$  é a função de ativação (restringe a amplitude de saída e adiciona não-linearidade ao modelo) e  $y_k$  é o resultado obtido.

Matematicamente o neurônio apresentado na Figura 1 pode ser representado por:

$$v_k = \sum_{i=1}^n w_{k,i} x_i + b_k \quad (1)$$

$$y_k = \varphi(v_k) \quad (2)$$

As funções de ativação utilizadas em RNA's são divididas em dois grupos: funções parcialmente diferenciáveis (degrau, degrau bipolar e rampa simétrica) e totalmente diferenciáveis (hiperbólica, gaussiana e logística).

As ligações entre os neurônios de uma RNA, ou seja, a sua arquitetura, estão relacionados ao algoritmo de aprendizado utilizado para treinar a rede. De forma geral, há três classes de arquiteturas mais usuais: *feedforward* com camada única, *feedforward* com múltiplas camadas e as redes recorrentes.

As redes do tipo *feedforward* com camada única, conhecidas como perceptron de Rosenblatt, é a forma mais simples de uma rede neural. Elas possuem uma camada de entrada, a qual recebe os estímulos externos, ou seja, recebe os dados de entrada, e os enviam para o restante da rede, e uma camada de saída, que é responsável pelo processamento de informações.

O fluxo da informação segue apenas uma direção, de forma que a camada de saída não exerça influência sobre os nós da camada de entrada. Além disso, os neurônios de uma mesma camada não são conectados entre si.

Normalmente, este tipo de rede é utilizado apenas para classificação de padrões linearmente separáveis. O perceptron realiza a classificação binária; isto é, prevê se a entrada pertence a uma determinada categoria de interesse ou não.

Já as redes do tipo *feedforward* com múltiplas camadas consistem em um conjunto de unidades de entradas, as quais constituem a camada de entrada, possui uma ou mais unidades ocultas, seguida de uma camada de saída. A camada oculta, ou intermediária, é responsável pela maior parte dos processamentos de dados. Já a camada de saída é responsável por um processamento menor dos dados, quando comparada com a camada intermediária e, também, onde são gerados os resultados. Além disso, o seu comportamento é reflexo do processamento na camada oculta e dos pesos entre as unidades ocultas e de saída. O fluxo da informação segue apenas

em um sentido camada por camada (da camada de entrada para camada de saída) (AZEVEDO; BRASIL; OLIVEIRA, 2000).

Entre as redes do tipo *feedforward* com múltiplas camadas, pode-se citar as redes *perceptrons* de múltiplas camadas (MLP).

As redes MLP, ou *Multilayer Perceptron*, surgiram como uma forma de superar a limitação da rede com uma única camada de não solucionar problemas que não fossem linearmente separáveis. Em 1986, Rumelhart, Hintont e Willians (1986) demonstraram que era possível treinar com eficiência redes com camadas intermediárias, treinadas com o algoritmo *backpropagation*, resultando nas redes MLP.

Durante o treinamento da RNA há o ajuste dos pesos, cujo objetivo é reduzir os erros na saída da rede. Dessa forma, deve-se dispor da amostra das respectivas saídas desejadas para que os pesos e limiares sejam ajustados de forma contínua pelo algoritmo de aprendizado, caracterizando, assim, um treinamento supervisionado. Segundo Haykin (2001), o treinamento da rede é finalizado quando é atingido um índice de desempenho estabelecido satisfatório, ou quando o número pré-definido de iterações é finalizado.

De acordo com Fernandes; Portugal e Navaux (1996) uma RNA do tipo MLP possui muita semelhança com os modelos estatísticos como, por exemplo, os pesos, os conjuntos de treinamento, as entradas, as saídas, o sinal de entrada e o sinal de saída são semelhantes aos parâmetros, a amostra, as variáveis exógenas, as variáveis endógenas, o valor das variáveis exógenas e o valor estimado, respectivamente, que são utilizados nos modelos estatísticos.

Maier e Dandy (2001) também observaram a semelhança entre as RNA's e os modelos estatísticos, porém destacam que o principal objetivo destes é desenvolver uma metodologia universal; já os praticantes de redes neurais visam a precisão da predição dos modelos, fazendo com que os modelos baseados nas RNA's sejam aplicados em problemas mais complexos.

### **3.3. RNA's aplicadas em recursos hídricos**

A RNA é um modelo empírico que possui a capacidade de modelar sistemas não lineares complexos e com grande quantidade de dados, tendo sido útil para solucionar



problemas onde as relações dos processos físicos não são completamente compreendidas, como é o caso do comportamento hidrológico de uma bacia hidrográfica.

Favoreto et al. (2001) afirmam que, dentro da área da modelagem hidrológica, a previsão de séries de vazão e de precipitação é uma das áreas mais promissoras para o uso de RNA's.

Segundo Zhang, Patuwo e Hu (1998), além da não linearidade, as RNA's possuem outras características que chamam a atenção para o seu uso. Entre essas características, encontra-se o fato de, pelo menos em um primeiro momento, não requererem informações prévias sobre o que se deseja estimar, uma vez que fornecida uma série de dados, o modelo irá tentar capturar as relações funcionais existentes nesses dados. Uma outra característica importante é a capacidade de generalização da rede, em que, após a fase de aprendizagem (treinamento), de posse do conhecimento das características dos dados, a rede consegue inferir informações nos dados restantes.

Diversos são os exemplos de trabalhos desenvolvidos que utilizaram RNA's para previsões hidrológicas de variáveis de recursos hídricos, incluindo precipitação, vazão, nível de água (cota) e parâmetros de qualidade da água (MAIER; DANDY, 2000; SAHOO; RAY; CARLO, 2006; SINGH et al., 2009; KALIN; ISIK; LOCKABY, 2010; PALANI et al., 2011; GAZZAZ et al., 2012; ISIK et al., 2013; AMIRI; SUDHEER; FOHRER, 2012; REZAEIAN-ZADEH; TABARI; ABGHARI, 2013; VILANOVA; ZANETTI,; CECÍLIO, 2019; VILANOVA; ZANETTI; CECÍLIO, 2020; ULIANA et al., 2018; SALAME et al., 2019; MENDONÇA et al., 2021).

Maier e Dandy (2000) revisaram 43 estudos, publicados até o ano de 1998, que tiveram a aplicação de RNA's na área dos recursos hídricos, e verificaram que já se havia dado um grande passo com relação aos estudos envolvendo redes, mas que ainda era necessário avançar, uma vez que, na maioria dos estudos, esse tipo de modelagem foi aplicado apenas em locais em que outros métodos não tiveram resultados satisfatórios.

Yaseen et al. (2015) fizeram uma vasta revisão dos trabalhos publicados durante o período de 2000 a 2015 e constataram que o uso de inteligência artificial tem gerado resultados satisfatórios e promissores em simulações hidrológicas. Dos estudos

revisados pelos autores, os quais utilizaram RNA's, a maioria deles utilizaram os modelos chuva-vazão na predição de vazões e redes do tipo MLP.

Muitos outros estudos foram desenvolvidos com a utilização de RNA's no tratamento de variáveis temporais complexas, como no caso de variáveis hidrológicas chuva e vazão (GHUMMAN et al., 2011; HUO et al., 2012).

Araújo, Dantas Neto e Souza Filho (2015) estimaram vazões na bacia hidrográfica do açude Orós, localizada no estado do Ceará, a partir de uma série de 87 anos de dados hidrometeorológicos. Os autores utilizaram função de ativação sigmoide e uma rede com três nós na camada de entrada, seis neurônios na camada intermediária e um neurônio na camada de saída, e concluíram que o resultado da estimativa da vazão através do uso das RNA's foi satisfatório.

Aichouri et al. (2015) utilizaram uma MLP para prever o escoamento da bacia de drenagem do rio Seybouse, na Argélia, com base em dados diários de chuva e vazão coletados em estações presentes na bacia. De acordo com os autores, mesmo que a área em estudo apresente irregularidades nos regimes de chuva e vazão, o uso de RNA forneceu bons resultados na modelagem chuva-vazão, apresentando, ainda, resultados melhores que o uso da regressão.

Yassen et al. (2016) utilizaram uma rede neural do tipo *feedforward* com uma camada oculta, onde os pesos de entrada foram selecionados aleatoriamente, para estimar a vazão mensal no rio Tigre, no Iraque, e alcançaram resultados satisfatórios.

Debastiani, Silva e Rafaeli Neto (2016) analisaram a eficácia de MLP dos tipos *closed-loop* e *open-loop* para a modelagem de um sistema hidrológico e avaliaram a influência de variáveis hidroclimáticas para a modelagem hidrológica. Nesse estudo, foram utilizados dados diários de precipitação, vazão e evapotranspiração de referência ( $ET_0$ ). Foram testadas combinações com essas variáveis para estimar a vazão, bem como transformações e deslocamentos temporais das variáveis. Os autores concluíram que, de maneira geral, o uso de RNA apresentou bons resultados, e que a estimativa da série histórica de vazão em *closed-loop* a partir de uma MLP treinada em *open-loop* apresentou uma maior eficácia. Além disso, a utilização dos dados de todas as estações pluviométricas simultaneamente gerou melhores resultados (DEBASTIANI; SILVA; RAFAELI NETO, 2016).

Vilanova, Zanetti e Cecílio (2019) utilizaram RNA's do tipo MLP para simular a vazão na bacia hidrográfica do Rio Itapemirim e constatou que os resultados gerados

pelo modelo acompanharam a tendência dos dados de vazão observados, e que não houve ganho significativo com a inclusão da evapotranspiração no modelo.

Vilanova, Zanetti e Cecílio (2020) estimaram séries de vazões utilizando o modelo chuva-vazão e obtiveram resultados satisfatórios quando RNA foi treinada com os dados de uma seção de área intermediária e testada em áreas com seções menores.

Mendonça et al. (2021) simularam a conversão de chuva em vazão para uma sub-bacia hidrográfica localizada no estado do Pará através das arquiteturas MLP e NARX (modelo não-linear auto regressivo com entradas exógenas) e obtiveram resultados satisfatórios.

Araújo et al. (2020) realizaram a previsão de vazões para a bacia do Orós, localizada no Ceará, utilizando RNA e a técnica de reamostragem dos k-vizinhos e constataram que todas as variáveis comparativas o modelo neuronal apresentou melhores valores, indicando que este representa de forma mais eficiente o comportamento das vazões para o reservatório.

Jimeno-Sáez et al. (2018) elaboraram um estudo comparativo entre o modelo hidrológico SWAT (Soil and Water Assessment Tool) e RNA's para estimar a vazão diária de duas bacias da Espanha com condições climáticas distintas: climas Atlântico e Mediterrâneo. A RNA foi modelada utilizando a precipitação diária, a precipitação diária de dias anteriores, a precipitação total de dias anteriores e a temperatura média diária, tendo-se constatado que todas as variáveis de precipitação foram importantes para estimar a vazão diária. Além disso, comparando os dois modelos, SWAT e RNA, o estudo mostrou que o modelo de RNA estimou os valores muito altos de vazões com maior precisão em todos os cenários analisados (JIMENO-SÁEZ et al., 2018)

Pradhan, Tingsanchali e Shrestha (2020) compararam os modelos hidrológicos Swat e três tipos de rede neural artificial na simulação da vazão diária em três bacias hidrográficas com diferentes condições climáticas: bacia do Rio West-Seti, localizada no Nepal, bacia do rio Sre Pok, no Camboja, e bacia do rio Hari Rod, localizada no Afeganistão. Os autores constataram que o desempenho dos modelos de RNA foi considerado muito bom, com valores de  $r^2$  e NSE superiores a 0,95 para os períodos de treinamento e validação nas bacias localizadas no Nepal e no Camboja. Além disso, concluíram que o modelo RNA teve maior desempenho na simulação de altas vazões, comparado ao SWAT.

A maior preocupação em utilizar RNA's é a seleção das variáveis com as melhores combinações de entrada, para que o modelo gere melhores resultados e que possam fazer boas estimativas. Nesse sentido, são necessárias decisões que envolvam a escolha da rede, número de camadas, algoritmo a ser utilizado no treinamento, função de ativação e forma de padronização dos dados (MAIER; DANDY, 2001).

No Quadro 1 é apresentada uma revisão de alguns estudos desenvolvidos no Brasil e no mundo com a aplicação de RNA's em modelos chuva-vazão. Verificou-se que a maioria dos modelos chuva-vazão utilizaram a rede do tipo MLP e a função de ativação sigmóide.

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

(continua)

<b>Autores</b>	<b>Área de estudo</b>	<b>Escala temporal</b>	<b>Período ou tamanho da série</b>	<b>Variáveis de entrada</b>	<b>Neurônios na camada oculta</b>	<b>Função de ativação</b>	<b>Algoritmo utilizado no treinamento</b>	<b>Tipo de rede utilizada *</b>	<b>Número de iterações</b>
FLORES; FERREIRA, 2018	Rio Preto - RJ	Horária	26.280 medições	Vazão a montante, cota e precipitação	1 a 30	Tangente hiperbólica	Bayesiana	MLP	500
DIAS; CATALDI; FERREIRA, 2017	BH Rio Grande - MG	Diária	1996 a 2003	Vazão e precipitação	1 a 6	Tangente sigmoidal	Levenberg-Marquardt	MLP	100
VILANOVA et al., 2019	BH Rio Itapemirim - ES	Diária	1980 a 2013	Precipitação e evapotranspiração	30	Sigmóide tangente hiperbólica	Levenberg-Marquardt	MLP	Não fixou o número de iterações
SOARES; TEIVE, 2015	Rio Itajai - SC	Diária	2005 a 2014	Cota e precipitação	3 a 10	Sigmóide tangente hiperbólica, sigmóide logística e base radial	<i>Backpropagation</i> , Levenberg-Marquardt e Bayesiana	MLP e RBF	30
CELESTE; MENEZES; FONTES, 2014	Rio Japarutuba - SE	Mensal	1969 a 1979	Vazão	Não informado	Sigmóide	<i>Backpropagation</i>	NSRBN	Não informado
DANANDEH MEHR et al., 2014	Rio Oruh, Turquia	Mensal	348 medições	Vazão	1 a 10	Sigmóide	Levenberg-Marquardt	MLP, GRNN e RBF	Não informado
KASHANI et al., 2014	Rio Navroo - Irã	Horária	1995 a 2005	Vazão e precipitação	1	Sigmóide	Levenberg-Marquardt e Broyden-Fletcher-Goldfarb-Shanno	MLP e FOV	Não informado

(continua)

<b>Autores</b>	<b>Área de estudo</b>	<b>Escala temporal</b>	<b>Período ou tamanho da série</b>	<b>Variáveis de entrada</b>	<b>Neurônios na camada oculta</b>	<b>Função de ativação</b>	<b>Algoritmo utilizado no treinamento</b>	<b>Tipo de rede utilizada *</b>	<b>Número de iterações</b>
JAJARMIZADE; HARUN; SALARPOUR, 2013	BH Roodan, Irã	Diária	1988 a 2008	Vazão e precipitação	Não informado	Sigmóide e sigmoide linear	<i>Backpropagation</i> e Levenberg-Marquardt	MLP	Não informado
REZAEIANZAD; TABARI; ABGHARI, 2012	Idenak Watershed, Irã	Mensal	1968 a 2004	Vazão e precipitação	2 a 15	Sigmóide	Gradiente conjugado escalonado	MLP	Não informado
CRUZ; RODRIGUES; VERSIONE, 2010	Rio das Velhas - MG	Diária	1978 a 1996	Vazão, precipitação e evapotranspiração	Não informado	Sigmóide	<i>Backpropagation</i>	MLP	Não informado
	Rio Abaeté - MG		1970 a 2005			Sigmóide			
ZADEH <i>et al.</i> , 2010	BH Khosrow Shirin, Irã	Diária	2002 a 2007	Vazão e precipitação	6	Sigmóide tangente hiperbólica e sigmóide logarítmica	Levenberg-Marquardt	MLP	50
SOUSA; SOUSA, 2010	Rio Piancó - PB	Mensal	1964 a 2003	Vazão e precipitação	5, 10 e 15	Sigmóide tangente hiperbólica e sigmóide logarítmica	Levenberg-Marquardt	MLP	6
BATISTA, 2009	Rio Grande - MG	Mensal	1990 a 2007	Vazão	10,20 e 30	Sigmóide logística	<i>Backpropagation</i>	MLP	10
CIGIZOGLU, 2009	Mediterrâneo - Turquia	Diária	1970 a 1989	Vazão	4	Não informado	<i>Backpropagation</i>	MLP	Não informado
KENTAL, 2009	Rio Guvenc - Turquia	Mensal	1987 a 2001	Vazão e precipitação	Não informado	Sigmóide	Levenberg-Marquardt	MLP	2000

(conclusão)

<b>Autores</b>	<b>Área de estudo</b>	<b>Escala temporal</b>	<b>Período ou tamanho da série</b>	<b>Variáveis de entrada</b>	<b>Neurônios na camada oculta</b>	<b>Função de ativação</b>	<b>Algoritmo utilizado no treinamento</b>	<b>Tipo de rede utilizada *</b>	<b>Número de iterações</b>
FIGUEIREDO <i>et al.</i> , 2007	Rio Iguaçu - PR	Diária e semanal	1996 a 2001	Vazão e precipitação	1 a 25	Não informado	Levenberg-Marquardt e Bayesiano	MLP	30
BAZARTSEREN; HILDEBRAND; HOLZ, 2003	Rios Oder e Rhine - Alemanha	Horária	Não informado	Cota	Variável	Não informado	Levenberg-Marquardt	MLP	Não informado

\* Multi-layer perceptrons (MLP), Volterra (VOL); rede neural generalizada (GRNN); função de base radial (RBF), nonlinear sigmoidal regression blocks network (NSRBN).

### **3.4. RNA's aplicadas na regionalização de dados hidroclimáticos**

Um dos maiores problemas enfrentados no gerenciamento dos recursos hídricos, principalmente em países em desenvolvimento, é a escassez de dados hidroclimáticos. Nesse sentido, a regionalização é uma ferramenta cada vez mais utilizada para suprir a carência de informações hidrológicas a partir da transferência de variáveis, funções ou parâmetros de um local para outro, que tenha o comportamento hidrológico semelhante (PRUSKI et al., 2013).

De acordo com Gasques et al. (2018), as características fisiográficas e climáticas dentro de uma bacia são consideradas uniformes, sendo, dessa forma, adotadas como variáveis para a determinação da vazão através da modelagem.

Segundo Tucci (2002) a rede de monitoramento hidrológica brasileira foi instalada em bacias hidrográficas com grandes áreas de drenagem, existindo uma carência ou inexistência de dados para bacias menores. Nesse sentido, há atualmente uma demanda para aplicação dos métodos de regionalização para bacias em que não há redes de monitoramento adequadas, implicando muitas vezes na extrapolação dos modelos, quando aplicados em áreas menores que as das bacias utilizadas nos estudos de regionalização (SARAIVA; FERNANDES; NAGHETTINI, 2011).

Entretanto, o uso da regionalização de vazões em bacias de menores áreas tem gerado incertezas na tomada de decisão, devido a extrapolação dos resultados gerados (TUCCI, 2002). Breuer et al. (2009) e Isik et al. (2013) destacam que a previsão de dados em bacias hidrográficas com ausência de dados medidos é uma tarefa desafiadora, independentemente do tipo de modelo utilizado.

O uso de RNA's aplicadas a regionalização constitui uma alternativa potencial na obtenção de variáveis climáticas em substituição aos métodos tradicionais (LI; MCCLENDON; HOOGENBOOM, 2004). Para Sárkozy (1999), as RNA's podem ser usadas como ferramenta de interpolação, pois devido a sua capacidade de aprendizado para diversos parâmetros de entrada, é capaz de resolver problemas complexos.

Heuvelmans, Muys e Feyen (2006) regionalizaram os parâmetros do modelo hidrológico SWAT através da regressão linear e de RNA's para simular a vazão diária em bacias belgas. Os autores constataram que as vazões estimadas tiveram maior acurácia com os parâmetros que foram regionalizados por meio de redes.



Noori e Kalin (2016) desenvolveram um modelo híbrido associando as RNA's com o modelo SWAT para estimar a vazão diária em 29 bacias hidrográficas em Atlanta, nos Estados Unidos. Para os autores, a combinação desses dois modelos enriquece o processo da modelagem, excluindo a necessidade de calibração e análises de sensibilidade no ajuste dos parâmetros do modelo SWAT, diminuindo o número de entradas na rede. Além disso, os autores destacam que mesmo que duas bacias hidrográficas tenham características distintas e a transferência de dados por modelos hidrológicos não fosse viável, o acoplamento dos dois modelos, SWAT e RNA, utiliza a informação de todas as bacias hidrográficas, fazendo com que o modelo desenvolvido se adeque as características dessas bacias, podendo, portanto, ser considerado uma abordagem de regionalização.

Isik et al. (2013) desenvolveram um modelo baseado em RNA, conservação do solo e no método do número da curva para estimar a vazão em bacias não monitoradas. A rede desenvolvida foi treinada, validada e testada usando os dados de vazões de 10 bacias pequenas no oeste da Geórgia, nos Estados Unidos, sendo que durante as etapas de treinamento, validação e teste não foram utilizadas todas as bacias simultaneamente. Os autores concluíram que o modelo de RNA conseguiu prever com alta precisão os valores de vazões nas bacias que não foram utilizadas em todo o processo.

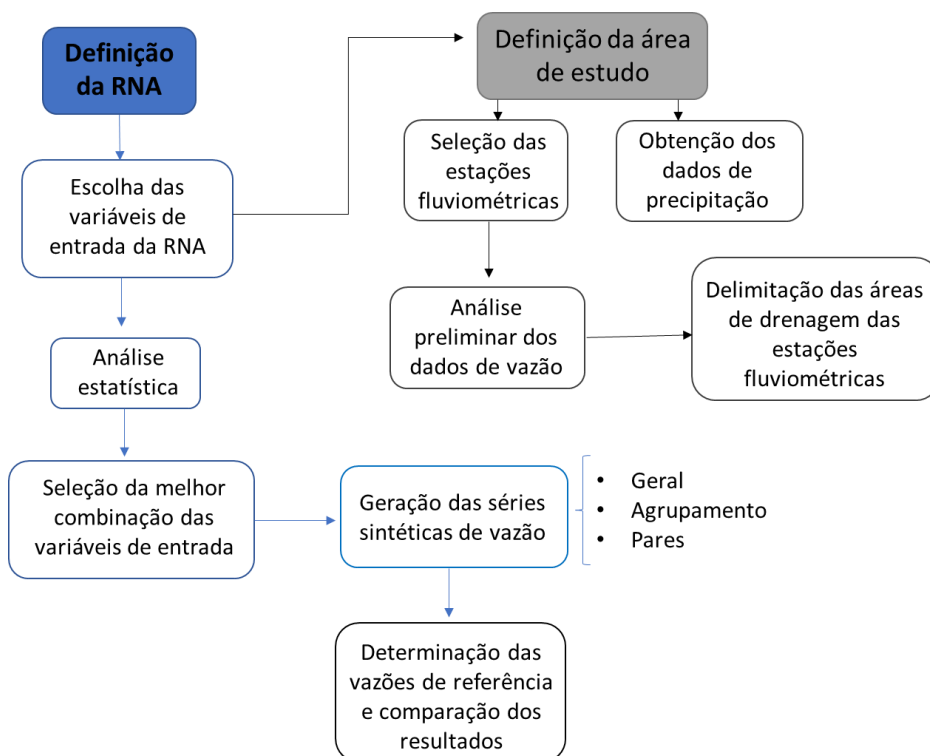
Diante do exposto, nota-se que o uso de RNA's no processo de regionalização de dados hidrológicos em bacias não monitoradas tem apresentado resultados satisfatórios e representa uma alternativa promissora nesse tipo de aplicação, podendo contribuir para uma melhor gestão dos recursos hídricos.

## 4. METODOLOGIA

O presente estudo consistiu na geração de séries sintéticas de dados diários de vazão em bacias hidrográficas utilizando modelos baseados em RNA's, a partir de dados diários de precipitação e outras variáveis testadas. Para a aplicação e teste dos modelos propostos (RNA's), foi realizado um estudo de caso utilizando dados de chuva e vazão existentes em bacias localizadas no estado do Espírito Santo, no período de 1980 a 2016, conforme descrito no item 4.3.

A Figura 2 apresenta um esquema representativo da metodologia utilizada no desenvolvimento do presente trabalho.

Figura 2 – Esquema representativo da metodologia proposta.



Fonte: a autora.

### 4.1. Modelos propostos utilizando redes neurais artificiais

#### 4.1.1. Arquitetura da RNA

Para a geração de séries sintéticas de dados de vazão foram utilizadas RNAs do tipo *multiLayer perceptron*, contendo três camadas. A primeira camada corresponde

aos dados de entrada, a segunda camada é a intermediária (oculta) e a terceira camada corresponde aos dados de saída. Todos os neurônios da rede foram configurados com base no modelo apresentado por (HAYKIN, 2001) – Figura 1.

A escolha do tipo de RNA utilizado neste trabalho ocorreu após uma ampla pesquisa na literatura dos tipos de redes que são utilizados em modelos chuva-vazão, conforme apresentado no Quadro 1, na qual se constatou que as redes do tipo *multiLayer perceptron* são as mais utilizadas, devido aos melhores resultados.

Para o treinamento das RNA's utilizou-se o algoritmo de *Levenberg-Marquardt*, uma vez que a maior parte dos estudos (Quadro 1) o utilizaram, obtendo resultados satisfatórios. Cada rede foi treinada 10 vezes, sendo escolhida a que apresentou o maior coeficiente de eficiência de Nash e Sutcliffe aplicado aos logaritmos (NSElog – Equação 7), calculado com a amostra de teste.

Como critério para encerrar cada treinamento, foi utilizado o método de treinamento com parada antecipada (HAYKIN, 2001), que possibilita identificar o início do excesso de treinamento (*overfitting*) usando a validação cruzada. Para tanto, os dados de treinamento foram subdivididos em dois subconjuntos, sendo um para o treinamento (85%) e outro para a validação (15%). Após cada iteração, a seção de treinamento era interrompida, visando realizar a validação cruzada. Enquanto o RMSE (Equação 5) do subconjunto de validação se apresentava menor que o seu valor na iteração anterior, o treinamento da rede era continuado; caso contrário, o treinamento era finalizado, uma vez que, segundo Haykin (2001), após esse momento, a rede pode assimilar o ruído contido nos dados, ocasionando perda na capacidade de generalização (extrapolação).

Com relação a função de ativação, nas RNA de múltiplas camadas, o cálculo do gradiente de cada neurônio do *perceptron* requer o conhecimento da derivada desta função. Para que haja esta derivação, é necessário que a função de ativação seja contínua e que atenda a condição de diferenciabilidade. Um tipo de função não-linear que atenda a essas condições, normalmente utilizada nos *perceptrons* de múltiplas camadas, é a função *sigmoide* (HAYKIN, 2001).

Nesse sentido, utilizou-se neste trabalho, na camada intermediária da rede, a função tangente hiperbólica-sigmóide (*tansig*), a qual pode assumir valores entre -1 e +1 (Equação 3).

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (3)$$

De forma compatível com a saída da função de ativação utilizada, os dados foram padronizados linearmente entre -1 e +1, utilizando-se a Equação 4.

$$X_{\text{norm}} = 2 \left( \frac{X_o - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \right) - 1 \quad (4)$$

em que,  $X_{\text{norm}}$  e  $X_o$  são os valores padronizado e observado;  $X_{\text{min}}$  e  $X_{\text{max}}$  são os valores mínimo e máximo contidos nos dados observados, respectivamente.

Na camada de saída de RNA's tipo MLP geralmente se utiliza neurônios lineares, ou seja, não se utiliza função de ativação. Entretanto, neste estudo, de forma inovadora, optou-se por utilizar a função de ativação tansig também na camada de saída da rede. Como esta função possui intervalo compatível com a padronização de dados adotada [-1, +1], esta configuração faz com que a menor vazão específica estimada pela rede não seja inferior à vazão específica mínima existente no banco de dados, assim como a maior vazão específica estimada não seja superior à máxima observada. Este procedimento representa uma condição de contorno, impedindo que a RNA estime vazões mínimas negativas ou estime vazões máximas muito altas (discrepantes).

Todo o processo de criação, treinamentos e simulações das RNA's foi realizado a partir de *scripts* implementados no programa MATLAB (R2016a), utilizando o *Neural Network Toolbox* (versão 9.0).

#### 4.1.2. Variáveis de entrada da RNA

Os dados de entrada das redes, utilizados neste trabalho, foram resultantes de vários testes com diferentes combinações de variáveis de entrada, com o objetivo de identificar a combinação que proporciona os melhores resultados na estimativa da vazão diária específica.

Nas variáveis de entrada das redes foram utilizados dados da precipitação diária ( $P_t$ ), precipitação do  $i$ -ésimo dia anterior dia anterior à vazão diária estimada ( $P_{t-1}$ ).

i), precipitação acumulada nos últimos  $i$ -ésimos dias ( $P_i$ ), área de drenagem e o número de mês, de acordo com o calendário civil.

A escolha do conjunto inicial de variáveis de entrada do modelo chuva-vazão foi baseada no estudo apresentado por Vilanova, Zanetti e Cecílio (2019) a qual concluiu em seu trabalho que o conjunto de variáveis  $P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5}$  e  $P_{30}$  gerou as melhores estimativas das vazões superficiais para a bacia do Rio Itapemirim, localizada no Espírito Santo. Esse conjunto de variáveis foi nomeado neste trabalho como Cenário 1. A partir desse cenário, foram adicionadas individualmente outras variáveis, iniciando com as precipitações de dias anteriores e, em seguida, com as precipitações acumuladas de 60 ( $P_{60}$ ) e 90 dias ( $P_{90}$ )

Após a seleção da(s) melhor(es) combinação(es) de variáveis de entrada do modelo chuva-vazão, foram feitos testes adicionais incluindo, individualmente, a área de drenagem de cada estação fluviométrica e o número do mês (1, 2, ..., 12), de acordo com o calendário civil, na tentativa de melhorar a eficiência do modelo.

A inclusão da área de drenagem é justificada pelo fato de ser uma característica fisiográfica de bacias hidrográficas, muito utilizada nos métodos tradicionais de regionalização de vazões. Já o número do mês (1 a 12), tem a finalidade de representar o padrão hidrológico das regiões (sazonalidade), permitindo identificar as estações secas, com baixos índices pluviométricos e menores vazões superficiais menores, e as estações chuvosas, com altos índices pluviométricos e vazões superficiais mais elevadas (ALVARES et al., 2013; DEO; ŞAHIN, 2016; REIS et al., 2021).

Após a análise dos índices estatísticos resultantes para cada conjunto de variáveis, definiu-se que conjunto de variáveis apresentou o melhor desempenho, sendo então nomeado de Cenário 2.

#### **4.1.3. Definição da abrangência espacial do (s) modelo (s).**

Inicialmente, obteve-se um único modelo para toda a região aplicada no estudo de caso, o qual foi nomeado de Modelo Geral.

O treinamento das redes ocorreu de forma simultânea para toda a base de dados, porém sempre deixando de fora os dados de uma estação fluviométrica, representando a amostra de teste do modelo. Ou seja, cada rede foi treinada  $N$  vezes, utilizando os dados de  $N-1$  estações fluviométricas. O objetivo desta técnica (*leave-*

*one-out*) é testar a eficiência do modelo ao estimar vazões em uma bacia cujos dados não foram utilizados no processo de treinamento. Essa técnica permite comprovar a capacidade de generalização do modelo de forma não tendenciosa.

Para o caso de o modelo geral não ter apresentado resultados satisfatórios para toda a área de estudo, também foi proposto modelos de RNA's treinados e testados para a base de dados dividida em agrupamentos. Neste caso, a base de dados foi separada em quatro grupos de acordo com a divisão das bacias hidrográficas e das características físicas e climáticas na área do estudo de caso.

Por fim, o último modelo proposto, nomeado de pares, foi a utilização de apenas duas estações fluviométricas que estivessem localizadas no mesmo curso d'água, sendo que a estação a jusante foi utilizada para o treino do modelo e a estação a montante para o teste do modelo.

As eficiências dos modelos propostos foram avaliadas através dos índices estatísticos e tanto para o modelo proposto para os grupos, quanto para o proposto para os pares de estações, a combinação das variáveis de entrada dos modelos utilizada foi a que resultou nos melhores resultados para o modelo geral (Cenário 2).

#### **4.2. Índices estatísticos aplicados na avaliação dos modelos**

De acordo com Razavi e Coulibaly (2013), uma das etapas mais importantes durante o processo da simulação de séries de dados de vazão é a avaliação da metodologia empregada. Essa avaliação ocorre através das medidas matemáticas chamadas de índices estatísticos, os quais são utilizados pelos hidrólogos para avaliar o grau de proximidade entre os dados observados e simulados.

Neste estudo, o processo da escolha do melhor modelo foi embasado nos seguintes índices estatísticos: coeficiente de determinação -  $R^2$ , que é dado pelo quadrado do coeficiente de correlação entre os dados estimados e os observados, raiz do quadrado médio do erro - RMSE (Equação 5), coeficiente de eficiência de Nash e Sutcliffe - NSE (Equação 6) (NASH; SUTCHIFFE, 1970) e o coeficiente de eficiência de Nash e Sutcliffe aplicado aos logaritmos – NSELog (Equação 7).

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

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

$$NSE_{log} = 1 - \frac{\sum_{i=1}^n (\ln E_i - \ln O_i)^2}{\sum_{i=1}^n (\ln O_i - \ln \bar{O})^2} \quad (7)$$

Onde  $O_i$  e  $E_i$  são as vazões observada e estimada ( $L s^{-1} km^{-2}$ ) respectivamente,  $n$  é o número de observações, e  $\bar{O}$  e  $\bar{E}$  são as vazões observada e estimada médias ( $L s^{-1} km^{-2}$ ) respectivamente.

Os valores de  $R^2$  variam de 0 a 1, e quanto mais próximo de um significa que menor é a variância do erro. Para valores diários de vazão, segundo Moriasi et al. (2015), valores de  $R^2$  superiores a 0,85 são classificados como muito bom, valores menores ou iguais a 0,85 e maiores que 0,75 são classificados como bons, valores menores ou iguais a 0,75 e maiores que 0,60 são considerados satisfatórios e valores iguais ou inferiores a 0,60 são classificados como insatisfatórios.

O índice RMSE representa a magnitude do erro típico e pode variar de 0 ao infinito, sendo que quanto mais próximo de zero, menor é o erro e, conseqüentemente, melhor é o desempenho do modelo. Entretanto, RMSE tende a dar um maior peso a valores mais altos, uma vez que erros mais altos são maiores em valores absolutos quando comparados a erros em valores baixos.

O índice NSE (NASH; SUTCHIFFE, 1970) indica quanto os dados estimados por um determinado modelo se distanciam em relação ao comportamento médio dos dados observados, ou seja, este índice permite verificar o ajuste dos picos e a dinâmica das vazões, sendo, portanto, mais sensível a valores extremos (KRAUSE; BOYLE; BÄSE, 2005). Neste trabalho, considerando que os dados foram estimados na escala diária, foi utilizada a classificação qualitativa proposta por Noori e Kalin (2016). Esses autores propuseram que o valor de NSE maior ou igual a 0,70 é classificado como muito bom, valores maiores ou iguais a 0,50 e menores que 0,70 são bons, maiores ou iguais a 0,30 e menores que 0,50 são considerados satisfatórios e valores inferiores a 0,30 são insatisfatórios (NOORI; KALIN, 2016).

Já o NSElog, por utilizar logaritmo, valoriza mais as vazões baixas que o índice NSE, tornando-se menos sensível a vazões de cheias. Assim como ocorre no NSE, quanto maior a eficiência, ou seja, maior o valor do índice, melhores serão as previsões. Este índice é limitado em 1 e também foram utilizados valores considerados no trabalho de Noori e Kalin (2016).

### **4.3. Estudo de caso**

#### **4.3.1. Caracterização da área em estudo**

A área em estudo compreende o estado do Espírito Santo, localizado na região Sudeste do Brasil. O estado possui uma área de 46,052,64 km<sup>2</sup> e está localizado entre as coordenadas geográficas 17°53'29" e 21°18'03" de latitude Sul e 39°41'18" e 41°52'45" de longitude Oeste.

De acordo com a classificação de Köppen, os climas predominantes na área em estudo são Cwa (clima subtropical de inverno seco e verão quente), Cwb (clima subtropical de altitude, com inverno seco e verão ameno), Am (clima tropical úmido ou sub-úmido) e Aw (clima tropical com invernos secos) (ALVARES et al., 2013). Possui uma ampla variação espacial na precipitação média anual, variando de valores inferiores a 1100 mm, nas regiões Norte e Centro-Oeste do estado, a valores superiores a 1500 mm, nas regiões Sudeste e Sul (INSTITUTO CAPIXABA DE PESQUISA, ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL – INCAPER).

O estado está inserido no bioma Mata Atlântica e possui uma ampla composição florística. Possui Floresta Ombrófila Densa nas encostas voltadas para o mar; Floresta Ombrófila Aberta Submontanha; Floresta Estacional Semidecidual das Terras Baixas; Floresta Estacional Semidecidual Submontana, com ocorrência na região do Caparaó; e vegetação secundária com tratos antrópicos prevalecendo a sucessão natural (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE, 2012).

Entre as regiões hidrográficas brasileiras, o estado encontra-se inserido nas regiões do Atlântico Leste e Atlântico Sudeste, contando com as bacias hidrográficas dos rios São Mateus, Itaúnas, Doce, Riacho, Reis Magos, Jucu, Itapemirim, Itabapoana, Benevente, Novo e Guarapari (AGERH, 2018).

Com relação ao relevo, o estado possui três regiões com diferentes padrões de relevo: a litorânea, os tabuleiros e as regiões de montanhas; as quais apresentam uma



ampla variação de altitude, indo desde o nível mar até altitudes da ordem de 2.897 metros no Caparaó (CAMPANILI; PROCHNOW, 2006).

Politicamente o estado do Espírito Santo encontra-se dividido em quatro macrorregiões: Sul, Metropolitana, Central e Norte.

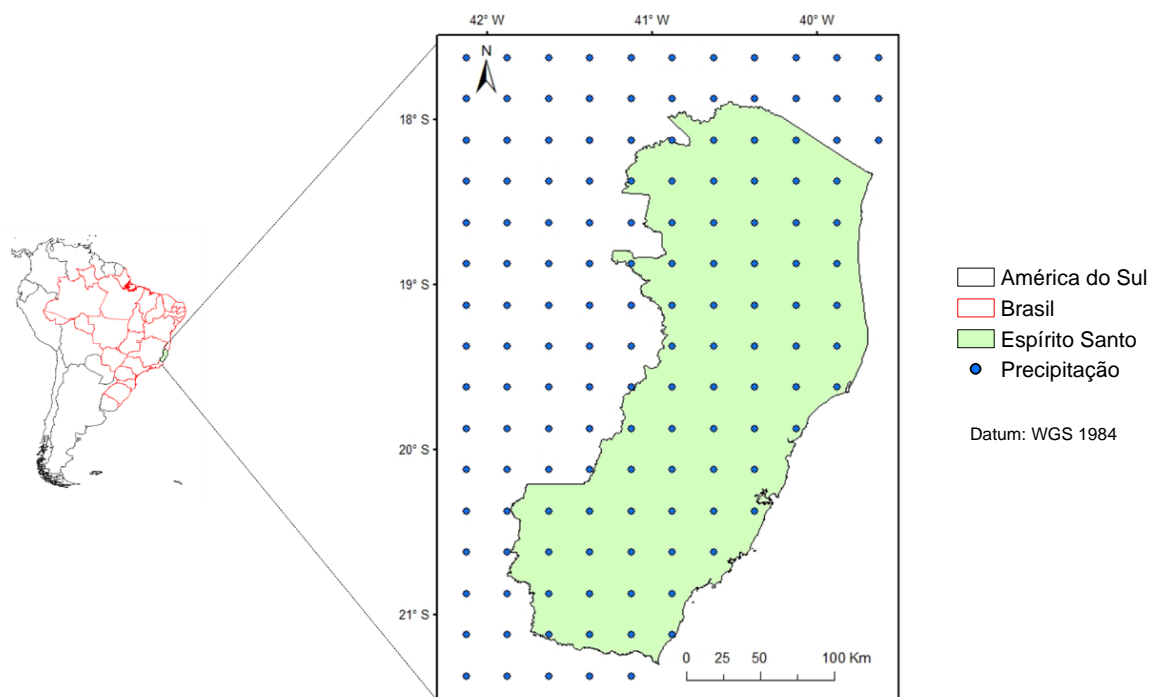
#### **4.3.2. Dados utilizados**

Neste estudo foram utilizados os dados de precipitação diária do período de 1 de janeiro de 1980 a 31 de dezembro de 2016, disponibilizados por Xavier, King e Scanlon (2015), os quais desenvolveram grids com resolução de  $0,25^\circ \times 0,25^\circ$  (27,78 km), contendo informações diárias de dados meteorológicos para todo o território brasileiro. Essas informações foram calculadas com base nos dados extraídos de estações automáticas e convencionais disponíveis no Brasil. A escolha do período de dados, para a realização deste trabalho, está diretamente relacionada ao fato da última série de dados das normais climatológicas do Brasil ser de 1981 a 2010 (DINIZ; RAMOS; REBELLO, 2018), e pela confiabilidade no trabalho desenvolvido por Xavier, King e Scanlon (2015).

Os dados de precipitação estão disponibilizados no formado NetCDF e para a visualização da localização dessas informações no território brasileiro, através de pixels, utilizou-se o software ArcGis 10.3. O próximo passo foi selecionar os pixels que estavam localizados na área de estudo com a identificação de suas respectivas coordenadas geográficas (Figura 3). Em seguida, executou-se o *script* (códigos em Python) no *software* Spyder para a extração das informações do centroide de cada um desses pixels.

Após a extração, os dados de precipitação foram disponibilizados em planilhas eletrônicas, contendo as seguintes informações: latitude, longitude, dia, mês, ano e as precipitações diárias referentes a cada pixel.

Figura 3 – Distribuição dos *pixels* centrais com dados de precipitação diária no estado do Espírito Santo



Fonte: a autora. Base de dados obtida de Xavier, King e Scanlon (2015).

As informações de precipitação diária extraídas do estudo de Xavier et al. (2016) são pontuais, e, assim, foi necessário realizar a espacialização destes dados para toda a área de estudo.

As espacializações foram realizadas através do polígono de Thiessen, por meio do software ArcGIS, onde determinou-se a precipitação média diária para cada seção de interesse deste estudo. As delimitações das seções de interesse da área de estudos serão abordadas no Item 4.3.3.

Além dos dados de precipitação diária, também foram utilizados os dados de vazão diária obtidos das estações fluviométricas, existentes na área de estudo, junto ao Sistema Nacional de Informações Sobre Recursos Hídricos (SNIRH), gerenciado pela Agência Nacional de Águas (ANA).

Atualmente existem mais de 270 estações de medição de vazão em solo capixaba, porém, foram selecionadas apenas as estações com no mínimo 20 anos de dados registrados, compreendidos entre o período de 1980 e 2016.

O código, a localização e a área de drenagem das estações fluviométricas estão disponíveis na Tabela 1. Já na Figura 4 está a localização espacial das mesmas. No Quadro 2 encontram-se o percentual anual de falhas de dados das estações selecionadas.

Tabela 1 – Identificação, localização e área de drenagem (Ad) das estações fluviométricas existentes no estado do Espírito Santo.

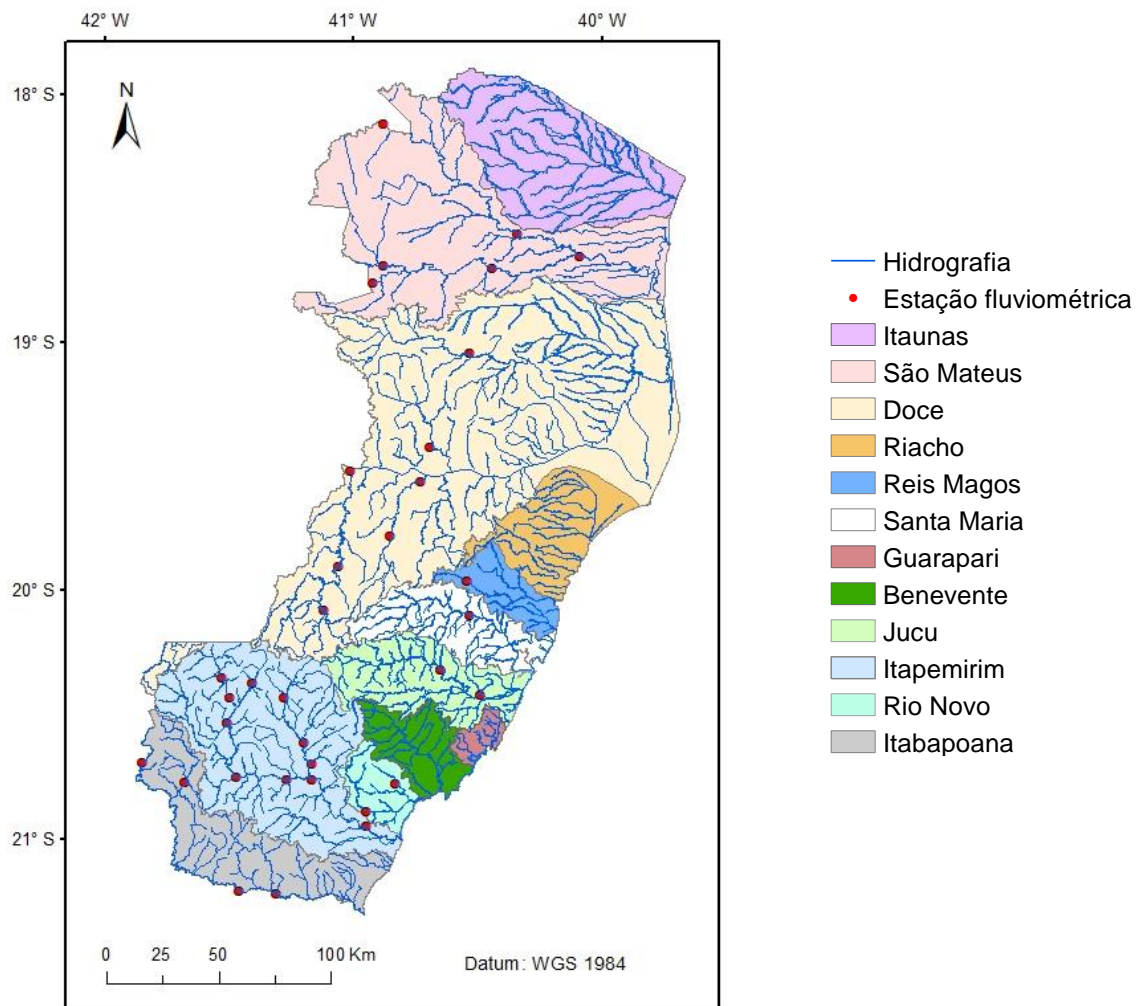
<b>Código</b>	<b>Nome da estação</b>	<b>Rio</b>	<b>Latitude (S)</b>	<b>Longitude (W)</b>	<b>Ad (km<sup>2</sup>)</b>
57830000	Ponte do Itabapoana	Rio Itabapoana	21,2°	41,5°	2720
57930000	Santa Cruz	Rio Itabapoana	21,2°	41,3°	3620
57580000	Usina Paineiras	Rio Itapemirim	21,0°	41,0°	5170
57250000	Matilde	Rio Benevente	20,5°	40,8°	206
57300000	Pau d'alho	Rio Novo	20,9°	41,0°	304
57555000	Coutinho	Rio Itapemirim	20,8°	41,2°	4510
57740000	Guaçuí	Rio do Veado	20,8°	41,7°	408
57320000	Iconha montante	Rio Iconha	20,8°	40,3°	152
57450000	Rive	Rio Itapemirim	20,8°	41,5°	2180
57460000	Pacotuba	Rio Itapemirim	20,8°	41,3°	2720
57550000	Usina São Miguel	Rio Castelo	20,7°	41,2°	1420
57720000	Dores do Rio Preto	Rio Preto	20,7°	41,9°	222
57490000	Castelo	Rio Castelo	20,6°	41,2°	972
57420000	Ibitirama	Rio Braço Norte Direito	20,5°	41,7°	337
57400000	Itaici	Rio Braço Norte Esquerdo	20,5°	41,5°	1010
57350000	Usina Fortaleza	Rio Braço Norte Esquerdo	20,4°	41,4°	205
57230000	Fazenda Jucuruaba	Rio Jucu	20,4°	40,5°	1690
57360000	Iúna	Rio Pardo	20,4°	41,5°	412
57370000	Terra Corrida montante	Rio Pardo	20,4°	41,5°	566
57476500	Fazenda Lajinha	Rio Castelo	20,4°	41,3°	410
57170000	Córrego do Galo	Rio Jucu - Braço Norte	20,3°	40,7°	980
56990990	Afonso Cláudio Montante	Rio Guandu	20,1°	41,1°	435

57130000	Santa Leopoldina	Rio Santa Maria da Vitória	20,1°	40,5°	929
57040008	Valsugana Velha Montante	Rio Timbui	20,0°	40,5°	88
56991500	Laranja da Terra	Rio Guandu	19,9°	41,1°	1330
56993002	Itaguaçu - Jusante	Rio Santa Joana	19,8°	40,9°	481
56993551	Jusante Córrego da Piaba	Rio Santa Joana	19,6°	40,8°	893
56992000	Baixo Guandu	Rio Guandu	19,5°	41,0°	2130
56995500	Ponte do Pancas	Rio Pancas	19,4°	40,7°	920
56998400	Barra de São Gabriel	Rio São José	19,0°	40,5°	1070
55900000	Barra de São Francisco	Rio São Francisco	18,8°	40,9°	214
55920000	Córrego da Boa Esperança	Rio São Mateus / Braço Sul	18,7°	40,4°	4190
55895000	Barra do Rio Preto	Rio São Mateus / Braço Sul	18,7°	40,9°	2500
55960000	Boca da vala	Rio São Mateus	18,7°	40,1°	12000
55850000	São João da Cachoeira Grande	Rio São Mateus / Braço Norte	18,6°	40,3°	6930
55800005	Fazenda São Mateus	Rio São Mateus / Braço Norte	18,1°	40,9°	4170

---

Fonte: a autora. Base de dados obtida junto a ANA.

Figura 4 – Localização das estações fluviométricas e das bacias hidrográficas inseridas no estado do Espírito Santo.



Fonte: a autora. Base de dados obtida junto a ANA.

Quadro 2 – Percentual anual (%) de falhas de dados nas estações fluviométricas selecionadas no presente estudo.

Ano / Código	1980	1981	1982	1983	1984	1985	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	
57930000																																					5,5	
57830000																																					11,5	
57880000																																						
57300000																																						
57320000																																					3,3	
57740000																																						
57460000					47,8							16,7	3,6																							67,1		
57555000												89,0	62,8					46,3																			67,1	
57450000																																						
57550000																																						
57720000																																					0,3	8,5
57490000						0,3																															2,2	
57250000																																						
57420000																																					6,3	3,8
57400000																																					0,3	
57370000																																						
57476500					45,1																																0,5	
57230000											25,2	32,9																										
57350000																																					0,5	
57360000																																						
57170000																																						
57130000																																						
56990990										8,5	67,1																											
57040008																																				0,8	12,8	
56991500									8,5																													
56993002				12,1					8,5	67,1		68,5	29,5	28,5		0,3	9,8				9,0	6,6																
56993551									8,5	67,1						4,1																					20,0	28,4
56992000									8,5																											1,4	0,3	
56995500									8,5	67,1																												27,0
56998400									8,5	67,1																												
55800005		11,5											15,0	2,7	80,8		81,1	25,2	55,1								10,7										5,2	
55900000																																						



### 4.3.3. Análise preliminar dos dados

Após a seleção das estações fluviométricas, tendo como base o período de registro de dados de vazão, procedeu-se com uma análise preliminar desses registros. Essa análise teve como objetivo identificar as estações fluviométricas que pudessem ter um comportamento hidrológico inconsistente quando comparado com estações próximas, podendo influenciar negativamente na modelagem hidrológica.

Inicialmente foi feita uma análise visual das hidrógrafas correspondentes a cada estação fluviométrica, contendo dados consistidos e dados não consistidos. As hidrógrafas são gráficos que possibilitam a verificação do comportamento das vazões diárias ao longo do tempo. Em seguida, foi feita a identificação de “*outlier*” das vazões específicas de referência ( $q_{mld}$ ,  $q_{90}$  e  $q_{7,10}$ ) e do escoamento superficial por meio de gráficos Boxplot (NIST/SEMATECH, 2013).

O Boxplot, ou diagrama de caixas, é uma ferramenta gráfica que permite a visualização da distribuição e os valores discrepantes (*outliers*) de um conjunto de dados. Neste tipo de gráfico, o limite de detecção de *outliers* é construído através do intervalo interquartil, dado pela distância entre o primeiro e o terceiro quartil.

A vazão específica é dada pela relação entre a vazão e a área da bacia hidrográfica, sendo um indicador direto que representa produção de água na bacia hidrográfica.

O coeficiente de escoamento superficial (C) (Equação 8) é definido como a razão entre o volume de água escoado superficialmente na seção de deságue e o volume de água precipitado na área de drenagem (RODRIGUEZ, 2008).

$$C = \frac{V_{T(\text{escoado})}}{V_{T(\text{precipitado})}} \quad (8)$$

Onde C é o coeficiente de escoamento superficial, adimensional,  $V_{T(\text{escoado})}$  é o volume médio anual que escoa na seção de deságue,  $m^3$ , e  $V_{T(\text{precipitado})}$  é o volume médio anual que precipita na área de drenagem,  $m^3$ .

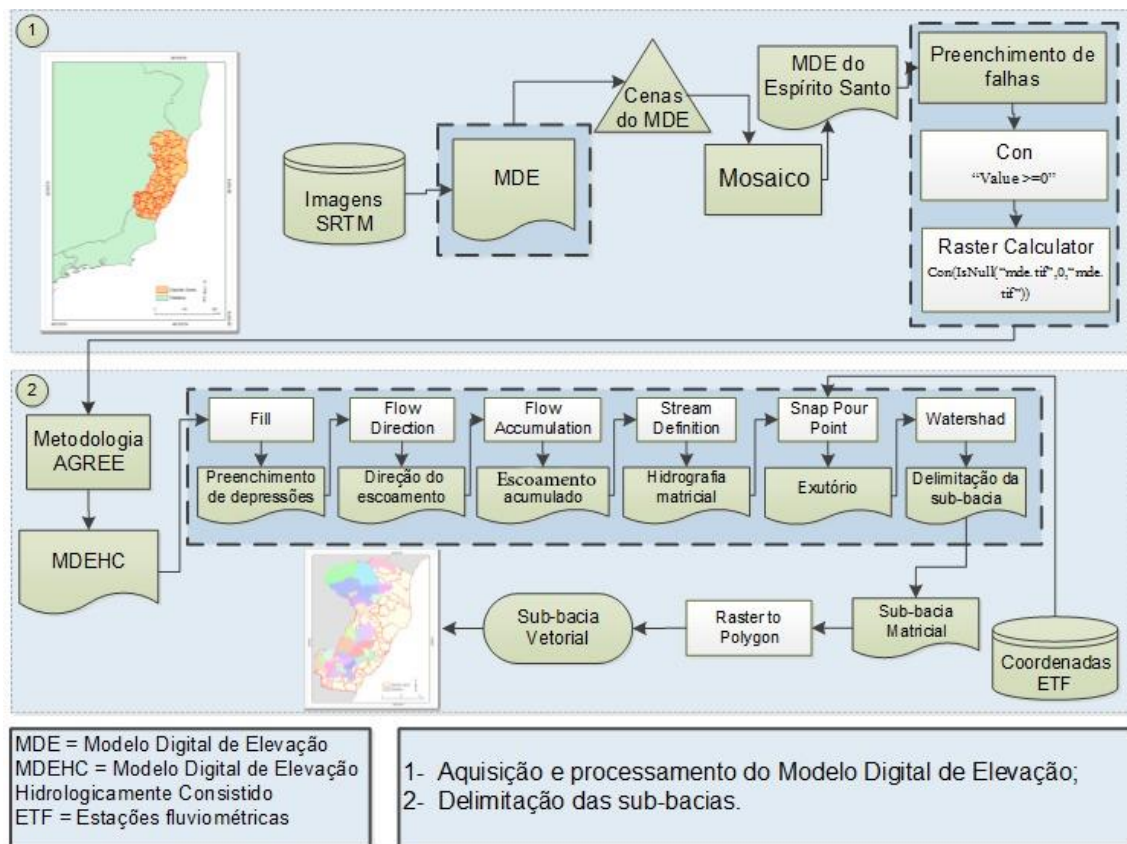
O volume que escoa na seção de deságue foi calculado pelo produto da vazão média de longa duração e do número de segundos existentes no ano (RODRIGUEZ, 2008).



#### 4.3.4. Delimitação da área de drenagem das estações fluviométricas

As delimitações das áreas de drenagem das estações fluviométricas foram feitas de acordo com a metodologia apresentada por Ferraz et al.(2021) a qual está apresentada na Figura 5, através do programa computacional ArcGIS 10.3.

Figura 5 - Fluxograma de obtenção dos dados topográficos digitais (etapa 1) e delimitações das sub-bacias hidrográficas (etapa 2).

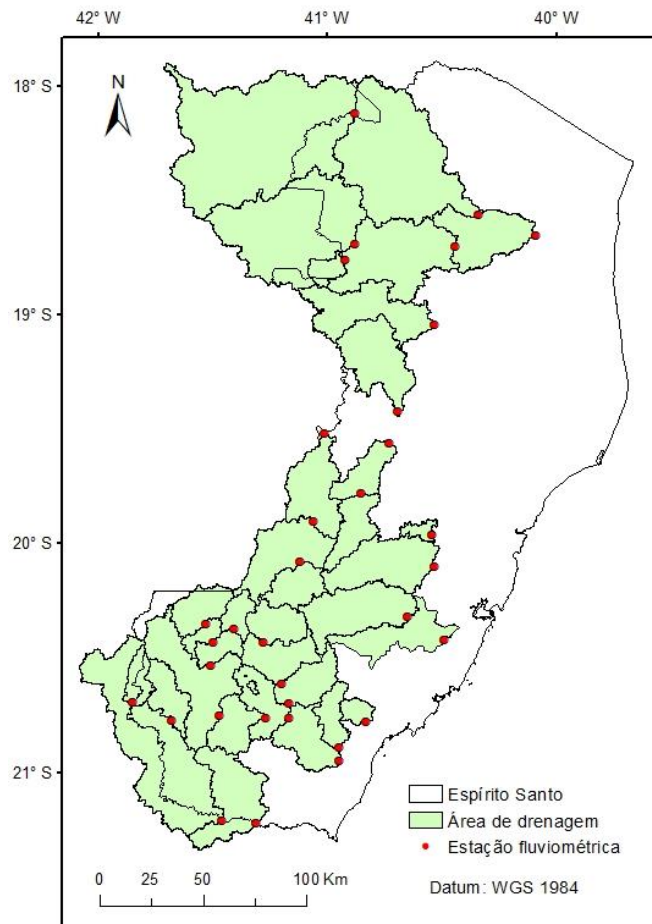


Fonte: FERRAZ, 2018.

No processo de aquisição e processamento do Modelo Digital de Elevação (MDE), o MDE foi adquirido gratuitamente do United States Geological Survey (USGS), proveniente do Space Shuttle Radar Topographic Mission (SRTM), com resolução espacial de 30 metros. Após a união de todas as cenas SRTM, foi realizado o preenchimento de falhas (*sinks*) do MDE, de forma que a aplicação dos procedimentos de delimitação das áreas de interesse não fosse prejudicada.

Na segunda etapa, aplicou-se o algoritmo AGREE (HELLWEGER, 1997), disponível no pacote *Arc Hydro Tools* do programa ArcGIS 10.3, para recondicionar o MDE. Este recondicionamento teve como objetivo melhorar a representatividade do terreno através do ajuste da elevação da superfície do MDE, de modo a coincidir com uma cobertura vetorial. Após a obtenção do Modelo Digital de Elevação Hidrologicamente Consistido (MDEHC), foram aplicados os seguintes comandos: *fill*, *flow direction*, *flow accumulation*, *stream definition*, *snap pour point* e *watershed*, conforme ilustrado no passo 2 do fluxograma (Figura 5). A partir disso, delimitaram-se as áreas de drenagem rasterizadas, que posteriormente foram convertidas para vetores aplicando suavização em seus contornos (Figura 6).

Figura 6 – Áreas de drenagem de cada estação fluviométrica utilizada neste estudo.



Fonte: a autora.

#### 4.3.5. Determinação das vazões de referência e comparação dos resultados

Os modelos propostos (RNA's) foram aplicados e testados inicialmente a partir da comparação entre os dados diários observados das estações fluviométricas e das séries sintéticas de vazões simuladas, conforme descrito no item 4.2. Para complementar essa avaliação, vazões de referência foram calculadas e também comparadas.

As vazões de referência representam o limite superior de utilização da água em um curso d'água. De acordo com Pruski, Silva e Koetz. (2006), a vazão mínima, caracterizada pela magnitude, duração e frequência, é utilizada para inúmeros fins, dentre eles para a concessão de uso da água para uma determinada finalidade.

Dessa forma, a vazão mínima média com sete dias de duração e período de retorno de 10 anos ( $Q_{7,10}$ ) e a vazão mínima com permanência em 90% do tempo ( $Q_{90}$ ) foram adotadas em função de serem as referências para emissões de outorgas de direito do uso de d'água superficial em rios com domínio da união e do estado do Espírito Santo, ou seja, da ANA e da Agência Estadual de Recursos Hídricos (AGERH) (Instrução Normativa Nº 13, de 9 de dezembro de 2009, do Instituto Estadual de Meio Ambiente e Recursos Hídricos – IEMA), respectivamente. A  $Q_{mid}$  foi também adotada por ser a vazão de referência utilizada na regularização de vazão e em estudos sobre a disponibilidade hídrica de bacias.

A obtenção das vazões de referência ocorreu através do Sistema Computacional para Análises Hidrológicas – SisCAH 1.0 (SOUSA et al., 2009). Essas vazões foram obtidas tanto para os dados observados nas estações fluviométricas, quanto para as séries sintéticas geradas pelos modelos. Antes do cálculo destas vazões, foram descartados os anos das séries históricas observadas que tiveram mais de 5% de falhas.

Para testar a eficiência dos modelos, as vazões de referência obtidas a partir dos dados observados de cada estação fluviométrica foram comparadas com as vazões de referência obtidas a partir das séries sintéticas geradas para o mesmo local, utilizando a respectiva estação que foi deixada de fora na etapa de treinamento das RNA's. Essa comparação ocorreu através do erro percentual (E) (Equação 9). Assim, foi possível averiguar a capacidade dos modelos quando aplicados em locais onde supostamente há ausência / falhas de dados.

$$E = \left( \frac{Q_{est} - Q_{obs}}{Q_{obs}} \right) \times 100 \quad (9)$$

onde,  $Q_{obs}$  são as vazões observadas e  $Q_{est}$  são as vazões estimadas, em  $m^3 s^{-1}$ .

Além disso, as vazões de referência, estimadas com as séries sintéticas, também foram comparadas com as vazões estimadas pelos métodos tradicionais de vazão, uma vez que, as vazões de referência utilizadas na gestão dos recursos hídricos na área em estudo foram obtidas através de métodos tradicionais.

Sendo assim, comparou-se as vazões de referências observadas e estimadas pelas RNA's com as vazões de referências obtidas através da regionalização de parâmetros hidrológicos-estatísticos de bacias hidrográficas, disponível no Relatório 05-A (aditivo), intitulado de "Estudo de regionalização de vazões e metodologias para determinação de vazões insignificantes para as 12 bacias hidrográficas do estado do Espírito Santo" (AGERH, 2017), cujas vazões são utilizadas atualmente para a emissão de outorgas de direito de uso d'água no estado do Espírito Santo. Neste estudo (relatório) de regionalização de vazões do IEMA (Instituto Estadual de Meio Ambiente e Recursos Hídricos), a primeira etapa consistiu na identificação de regiões hidrologicamente homogêneas e, na segunda etapa, foram ajustadas equações de regressão entre a variável regionalizada (vazões de referência), a área de drenagem e a precipitação (obtida através do método das Isoietas) da bacia de drenagem em cada região homogênea (AGERH, 2017).


## 5. RESULTADOS E DISCUSSÃO

### 5.1. Análise preliminar dos dados fluviométricos

Na análise preliminar dos dados fluviométricos foram identificadas as estações que apresentaram um comportamento hidrológico distinto das demais estações.

Na Figura 7 são representadas as análises do BoxPlot referentes as vazões específicas de referência e ao escoamento superficial, respectivamente, das estações fluviométricas selecionadas neste trabalho.

Figura 7 – Análises BoxPlot das vazões de referência das estações fluviométricas, em  $L s^{-1} km^{-2}$ , e do coeficiente de escoamento superficial - C, adimensional.



Através da análise Bloxplot, identificou-se a estação de Matilde (57250000) como um “*outlier*” para a  $q_{90}$ , a  $q_{95}$  e a  $q_{7,10}$ . Já para o coeficiente de escoamento e a  $q_{mld}$ , identificou-se a estação de Ibitirama (57420000) como “*outlier*”, devido as altas vazões registradas, associada a uma pequena área de drenagem, quando comparada com as demais áreas de drenagem das estações fluviométricas.

Diante do exposto, os dados medidos das estações fluviométricas de Ibitirama e Matilde foram excluídos das etapas posteriores deste trabalho.


## 5.2. Aplicação da metodologia proposta

Neste tópico, estão apresentados e discutidos os resultados para a aplicação do modelo geral, em agrupamentos e em pares de estações.

### 5.2.1. Modelo geral

Na Figura 8 são apresentados os índices estatísticos médios (NSE, NSElog, RMSE e  $r^2$ ) resultantes da aplicação do modelo geral para toda a área de estudo, considerando diferentes combinações de variáveis de entrada, a partir do conjunto de variáveis proposto por Vilanova, Zanetti e Cecílio (2019) (Cenário 1).

Figura 8 - Índices estatísticos médios dos testes das RNA's para as estações fluviométricas utilizadas, localizadas no estado do Espírito Santo: NSE, NSElog e  $r^2$  (a); e RMSE, em  $L s^{-1} km^{-2}$  (b).



De acordo com os resultados médios gerados pelo modelo geral, observou-se que a inclusão das precipitações de seis, sete e oito dias anteriores (Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$  e  $P_{t-8}$ ), como variável de entrada, apresentou melhora nos índices estatísticos comparados aos obtidos apenas com as variáveis do Cenário 1. Já a inclusão das variáveis acumuladas de 60 e 90 dias (Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$  e  $P_{t-8}$ ,  $P_{60}$  e  $P_{90}$ ), possibilitou uma melhora nos índices, principalmente para o NSE, indicando que este foi o conjunto de variáveis que resultou nos melhores resultados, quando se considerou apenas a precipitação na estimativa das vazões.

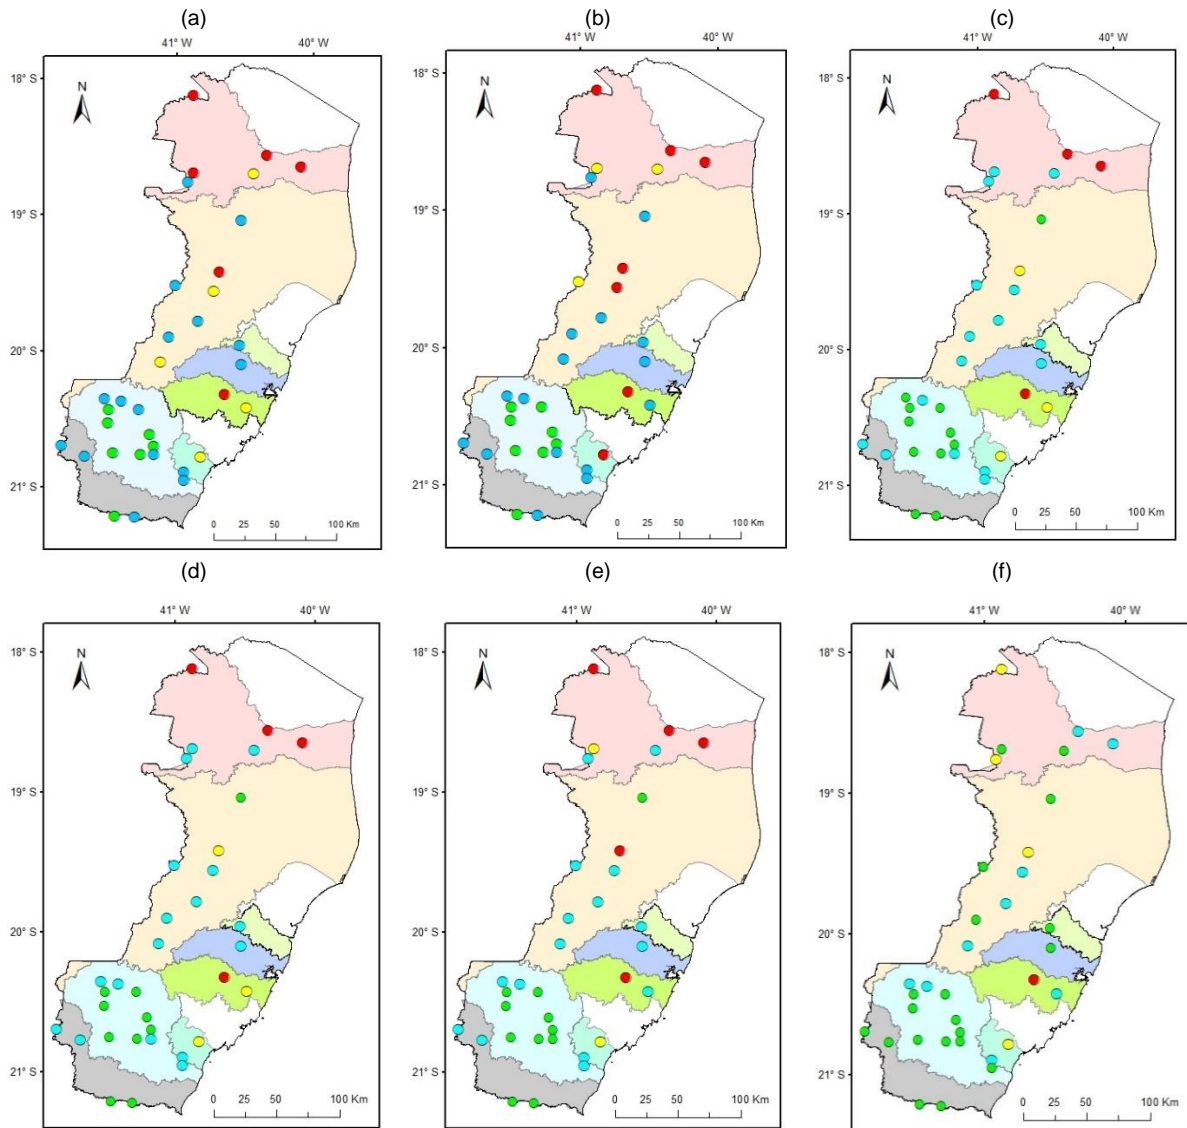
O fato de as precipitações acumuladas terem resultado em uma melhora na estimativa das vazões diárias está diretamente relacionado ao sistema hídrico das bacias. Para que um evento de precipitação seja convertido em escoamento superficial, de forma geral, é necessário que primeiro o solo atinja o ponto de saturação para que depois ocorra o escoamento, que é o responsável pela variação abrupta da vazão. Normalmente, esses eventos estão associados a precipitações que ocorreram durante vários dias, por isso as precipitações acumuladas tem uma maior interferência no comportamento da vazão (REIS et al., 2021).

Além disso, as precipitações de poucos dias anteriores possuem maior relação com a vazão de escoamento superficial, enquanto as precipitações acumuladas de meses anteriores representam melhor o escoamento de base (Vilanova, Zanetti e Cecílio, 2019).

Com relação a inclusão da área e do número do mês (Cenário 1 +  $P_{60}$ ,  $P_{90}$ , Área e Mês) no conjunto de variáveis de entrada, em média, o modelo apresentou melhor desempenho com a inclusão dessas duas variáveis em todos os índices estatísticos, sendo que em mais de 90% das estações fluviométricas testadas, o NSE foi superior a 0,30, indicando resultados satisfatórios (NOORI; KALIN, 2016).

Nas Figuras 9, 10, 11 e 12 são apresentados os resultados obtidos para cada estação fluviométrica com os diferentes conjuntos de variáveis de entrada.

Figura 9 – NSE resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 +  $P_{t-6}$  (b); Cenário 1 +  $P_{t-6}$  e  $P_{t-7}$  (c); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$  e  $P_{t-8}$  (d); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$  e  $P_{90}$  (e); e Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$ ,  $P_{90}$ , Área e Mês (f).



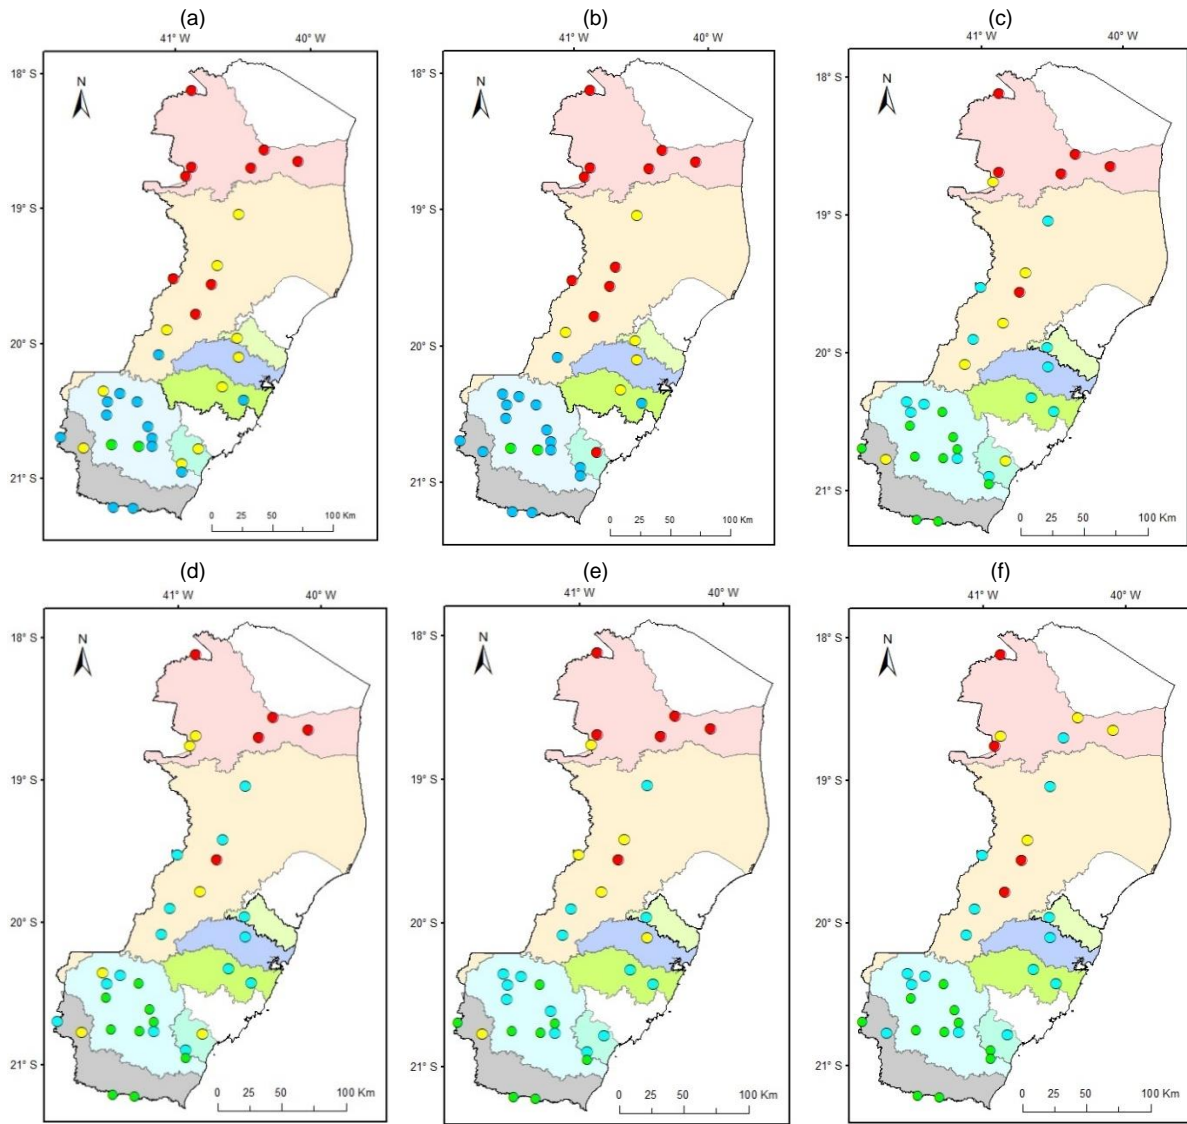
- NSE < 0,30
- 0,30 ≤ NSE < 0,50
- 0,50 ≤ NSE < 0,70
- NSE ≥ 0,70

- São Mateus
- Rio Doce
- Reis Magos
- Santa Maria
- Jucu
- Rio Novo
- Rio Itapemirim
- Itabapoana

Datum: WGS 1984



Figura 10 – NSElog resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 +  $P_{t-6}$  (b); Cenário 1 +  $P_{t-6}$  e  $P_{t-7}$  (c); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$  e  $P_{t-8}$  (d); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$  e  $P_{90}$  (e); e Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$ ,  $P_{90}$ , Área e Mês (f).

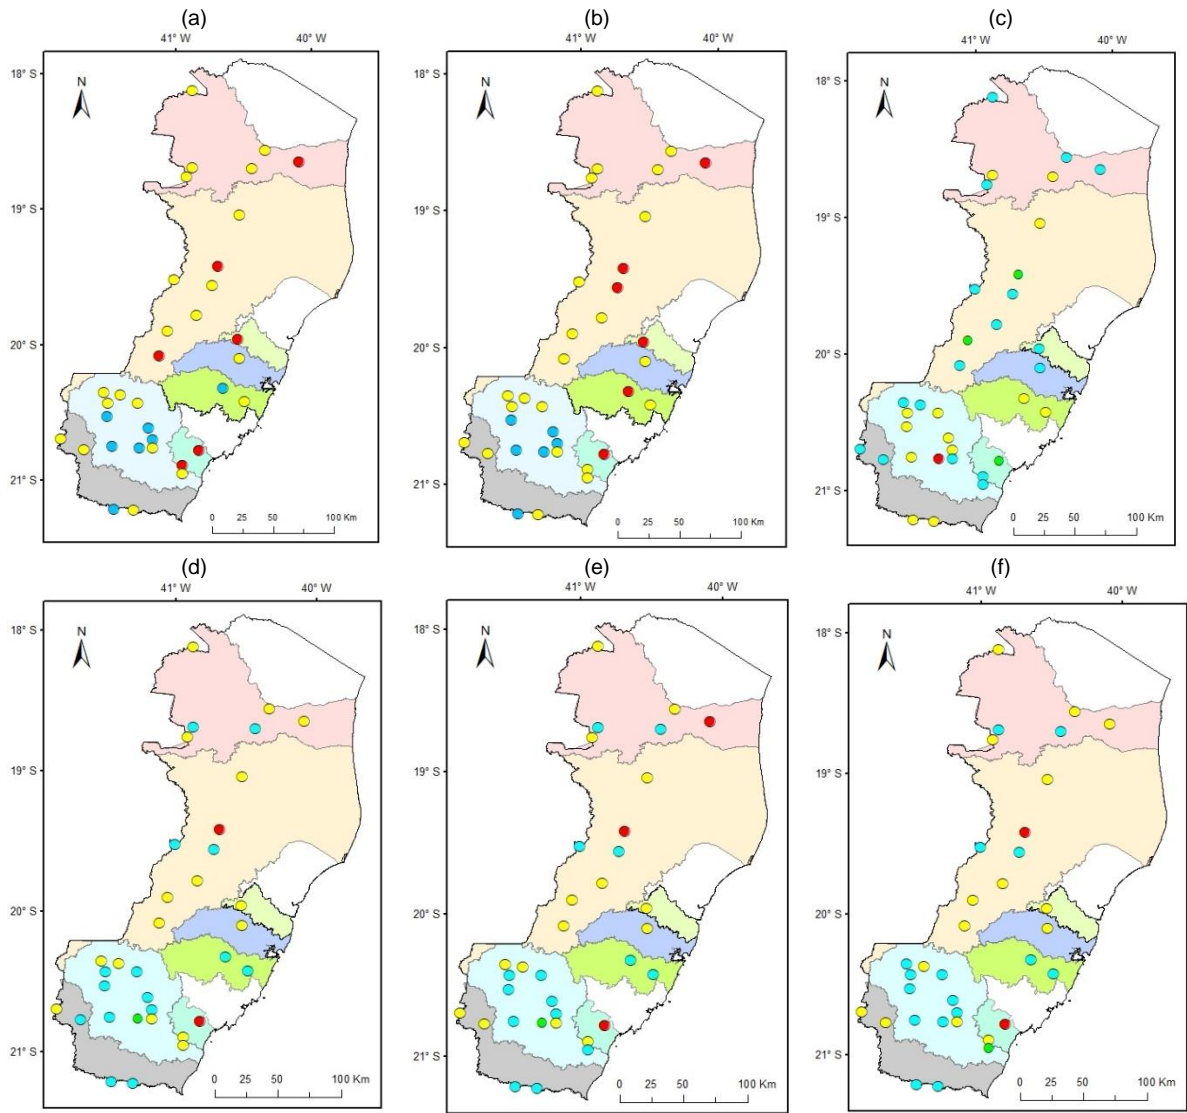


- NSElog < 0,30
- $0,30 \leq \text{NSElog} < 0,50$
- $0,50 \leq \text{NSElog} < 0,70$
- NSElog  $\geq 0,70$

- São Mateus
- Rio Doce
- Reis Magos
- Santa Maria
- Jucu
- Rio Novo
- Rio Itapemirim
- Itabapoana

Datum: WGS 1984

Figura 11 –  $R^2$  resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 +  $P_{t-6}$  (b); Cenário 1 +  $P_{t-6}$  e  $P_{t-7}$  (c); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$  e  $P_{t-8}$  (d); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$  e  $P_{90}$  (e); e Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$ ,  $P_{90}$ , Área e Mês (f).

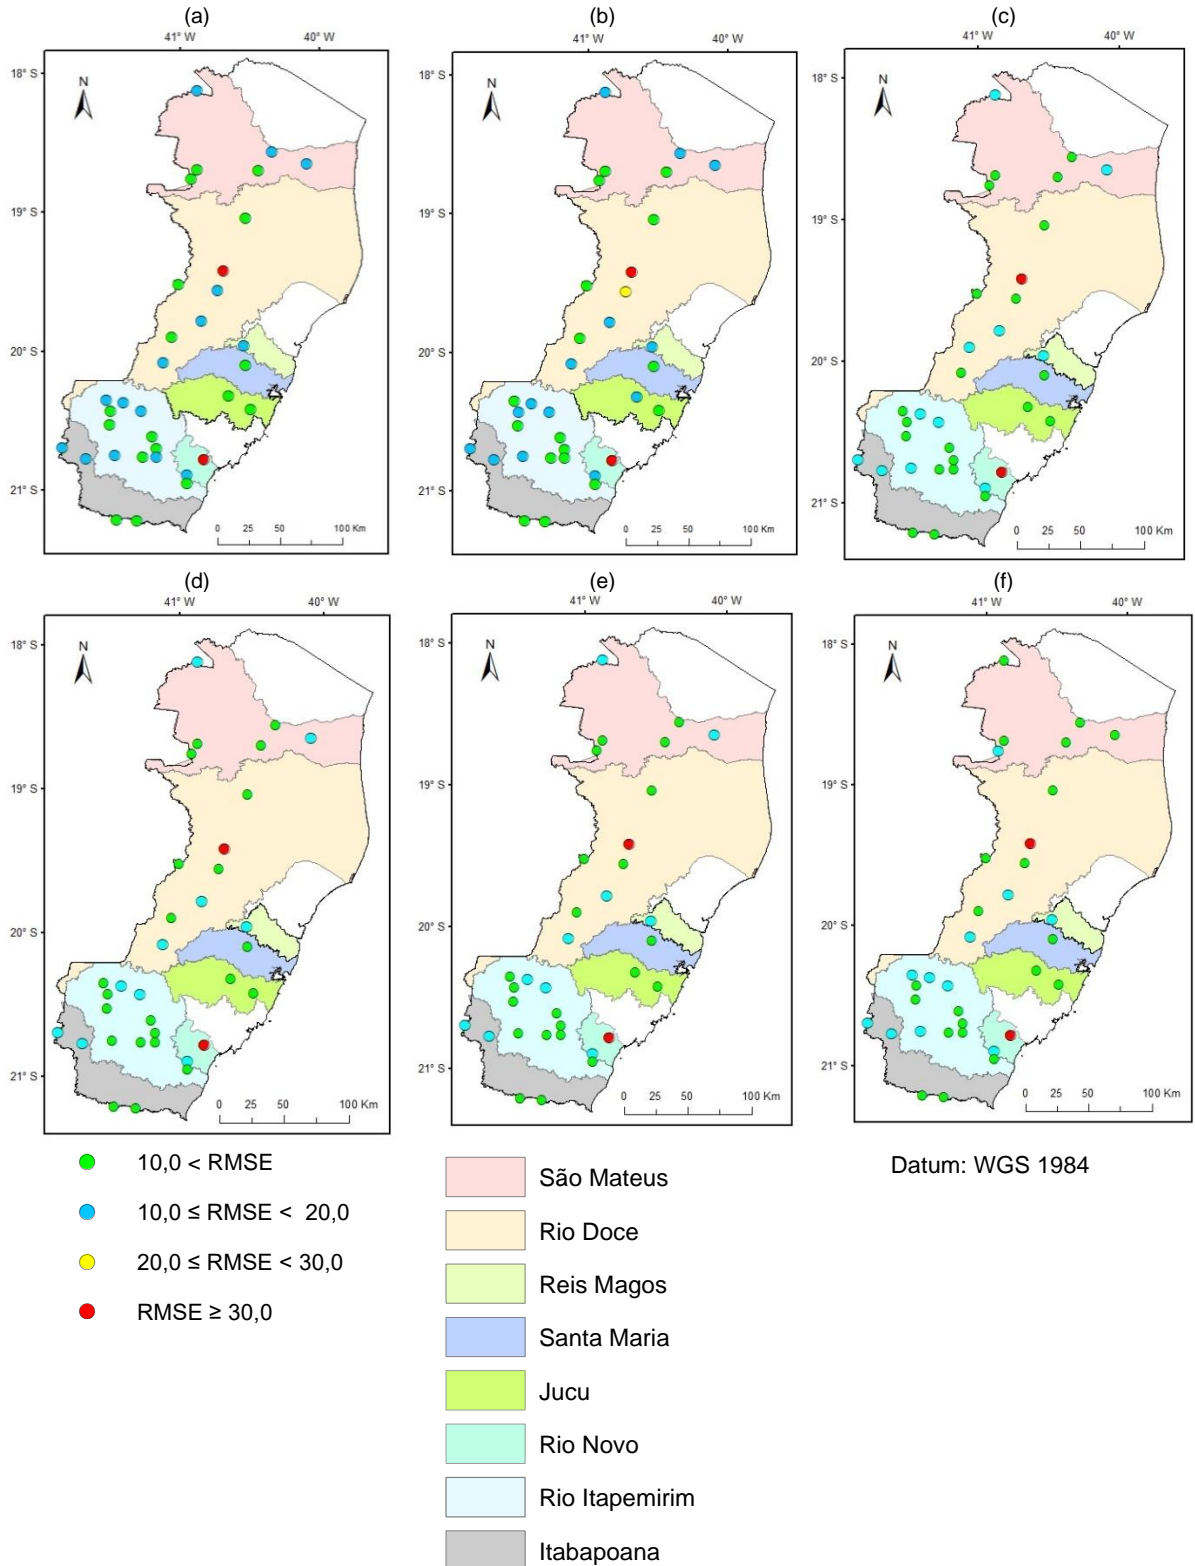


- $R^2 \leq 0,60$
- $0,60 < R^2 \leq 0,75$
- $0,75 < R^2 \leq 0,85$
- $R^2 > 0,85$

- São Mateus
- Rio Doce
- Reis Magos
- Santa Maria
- Jucu
- Rio Novo
- Rio Itapemirim
- Itabapoana

Datum: WGS 1984

Figura 12 – RMSE, em  $L s^{-1} km^{-2}$ , resultantes dos treinamentos e testes das RNA's para as estações fluviométricas localizadas no estado do Espírito Santo, considerando as variáveis de entrada: Cenário 1 (a); Cenário 1 +  $P_{t-6}$  (b); Cenário 1 +  $P_{t-6}$  e  $P_{t-7}$  (c); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$  e  $P_{t-8}$  (d); Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$  e  $P_{90}$  (e); e Cenário 1 +  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$ ,  $P_{90}$ , Área e Mês (f).



Em uma análise individual das bacias hidrográficas, observou-se que as estações fluviométricas localizadas nas bacias dos Rios Itabapoana, Itapemirim, Santa Maria, Reis Magos e Rio Novo, para as variáveis de entrada do Cenário 1, os índices estatísticos NSE e NSElog foram superiores a 0,30 (Figuras 9a e 10a, respectivamente), indicando resultados satisfatórios para o NSE, segundo a classificação apresentada por Noori e Kalin (2016).

Para esse mesmo conjunto de variáveis de entrada do modelo (Cenário 1), Vilanova, Zanetti e Cecílio (2020) obtiveram NSE iguais a 0,593 e 0,817 para os testes executados nas estações de Coutinho (57555000) e Pacotuba (57460000), respectivamente, quando a rede foi treinada com os dados observados da estação de Rive (57450000). Enquanto, para essas mesmas estações, os resultados obtidos pelo aqui proposto resultaram em índices NSE iguais a 0,66 (57555000) e 0,83 (57460000).

Já no teste executado para a estação de Rive (57450000), obteve-se um NSE igual a 0,77, valor este superior ao encontrado por Fukunaga et al. (2015), que foi de 0,75 para a amostra de calibração, através do modelo SWAT na simulação da vazão nesta bacia.

Cecílio, Mendes e Zanetti (2021), após a calibração do modelo DHSVM, encontraram valores de NSE para as sub-bacias de Rive (0,56), Paineiras (0,61), Castelo (0,43), Lajinha (0,46), Itaiçi (0,51) e Luna (0,49) inferiores aos testes executados com o método proposto neste trabalho (0,77, 0,66, 0,77, 0,64, 0,72 e 0,64, respectivamente).

Já para a estação fluviométrica 57170000, localizada no Rio Jucu, e para as estações localizadas no Rio Santa Joana (56993002 e 56993551), afluente do Rio Doce, os resultados foram insatisfatórios para os índices NSE e NSElog, respectivamente. Para a estação 57320000 (Rio Iconha) também não foram obtidos bons resultados, apresentando NSElog inferior a 0,30.

Correia (2016) aplicou o modelo SWAT para a simulação da vazão diária na bacia do Rio Jucu e encontrou valores de NSElog para a calibração e na validação do modelo valores iguais a 0,36 e 0,35, respectivamente, valores esses inferiores aos obtidos para os testes executados nas estações 57230000 e 57170000 (0,45 e 0,48, respectivamente).

Com relação ao RMSE (Figura 12a), observaram-se que os valores superiores a  $10,0 \text{ L s}^{-1} \text{ km}^{-2}$  estão associados às áreas de drenagens inferiores a  $430 \text{ km}^2$ , com

exceção das estações 57555000 (Coutinho) e 57450000 (Rive), que possuem área de drenagem superior a 2.000 km<sup>2</sup> e apresentaram RMSE iguais a 10,30 e 11,21 L s<sup>-1</sup> km<sup>-2</sup>, respectivamente. Vilanova, Zanetti e Cecílio (2020) também constataram que, na sub-bacia de Coutinho, o modelo proposto por eles também não apresentou resultados satisfatórios, utilizando redes treinadas somente para estações individuais, com aplicação (teste) em todas as sub-bacias.

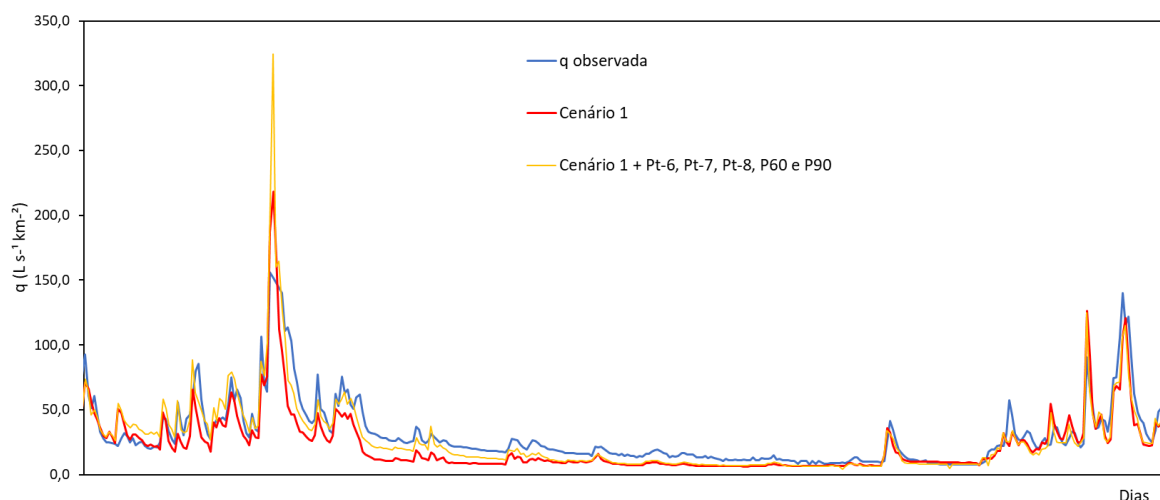
O fato de se obter maiores erros (RMSE) associados a menores áreas de drenagem, pode estar associado a resposta hidrológica das bacias hidrográficas, uma vez que, quanto menor a área de drenagem, mais rápida é a resposta hidrológica da bacia a um evento de precipitação.

Já para as estações fluviométricas localizadas na bacia hidrográfica do Rio São Mateus (localizada no norte do estado) não houve bons resultados, quando observados os valores de NSElog, uma vez que valores inferiores a 0,30. Além disso, verificou-se que há uma tendência de decréscimo nos índices NSE, NSElog e R<sup>2</sup> (Figuras 9a, 10a e 11a, respectivamente) quanto mais ao norte do estado estiver localizada a estações fluviométrica.

As inclusões das precipitações de dias anteriores, P<sub>t-6</sub>, P<sub>t-7</sub> e P<sub>t-8</sub>, ao Cenário 1 possibilitaram um aumento gradual nos valores de NSE (Figuras 9b, 9c e 9d), NSElog (Figuras 10b, 10c e 10d) e r<sup>2</sup> (Figuras 11b, 11c e 11d) e um decréscimo no valor de RMSE (12b, 12c e 12d), Além disso, a adição e das precipitações acumuladas, P<sub>60</sub> e P<sub>90</sub>, como variáveis de entrada do modelo possibilitaram um aumento nos valores de NSE, NSElog e r<sup>2</sup> (Figuras 9e, 10e e 11e) e um decréscimo no valor de RMSE (Figura 12e) em quase 80% das estações fluviométricas testadas, quando comparadas aos resultados obtidos com as variáveis do Cenário 1.

Como exemplo dessa melhora nos resultados estimados pelo modelo, com a inclusão das precipitações acumuladas, na Figura 13 é apresentada a hidrógrafa com as vazões específicas diárias observadas e as estimadas pelo modelo referentes ao ano de 2005, e na Figura 14 são apresentados os gráficos de dispersão da estação fluviométrica 57830000, localizada no Rio Itabapoana.

Figura 13 – Vazões específicas ( $L s^{-1} km^{-2}$ ) diárias observadas e estimadas pelo modelo (estação fluviométrica 57830000) no ano de 2005.




Comparando as hidrógrafas da Figura 13, observou-se que, com a inclusão das precipitações acumuladas e das precipitações de dias anteriores como variáveis de entrada, as vazões específicas estimadas aproximaram-se das vazões observadas, tanto para as vazões mínimas, quanto para as vazões máximas. Além disso, foi possível notar que há uma tendência de retardamento temporal nas vazões mínimas estimadas pelo modelo, com relação as vazões observadas. Com a inclusão das precipitações acumuladas, esse retardamento foi minimizado.

A melhoria nas estimativas das vazões específicas diárias também pode ser observada nos gráficos de dispersão (Figura 14), uma vez que, com a adição das precipitações acumuladas nas variáveis de entrada do modelo, há um acréscimo em  $r^2$  e as vazões estimadas tendem a estar mais próximas da reta, cujo coeficiente angular é igual a 1.

Através dos índices estatísticos (Figuras 9f, 10f e 11f), observou-se que as inclusões do número do mês e da área de drenagem de cada estação fluviométrica, como variáveis de entrada do modelo, resultaram em um aumento mais expressivo nos índices NSE, NSElog e  $r^2$ , em mais de 90% das estações fluviométricas, quando comparado aos resultados gerados apenas com a precipitação (Figuras 9d, 10d e 11d). A inclusão dessas novas variáveis fez com que das 34 estações que foram testadas individualmente, 30 estações fluviométricas apresentassem valores de NSE superiores a 0,30. 29 estações apresentassem valores de NSElog também superiores a 0,30.

Figura 14 – Gráficos de dispersão das vazões específicas ( $L s^{-1} km^{-2}$ ) diárias observadas e estimadas pelo modelo (estação fluviométrica 57830000) com as seguintes variáveis de entrada: Cenário 1 (a) e Cenário 1,  $P_{t-6}$ ,  $P_{t-7}$ ,  $P_{t-8}$ ,  $P_{60}$  e  $P_{90}$  (b).



Reis et al. (2021), em um trabalho desenvolvido para a bacia hidrográfica do Rio Piranga, localizado em Minas Gerais, também constataram que a inclusão do mês como variável de entrada resultou em uma maior eficiência dos modelos Regressão Adaptativa Multivariada, Regressão Linear Múltipla e *Random Forest* na estimativa de vazões.


Diante do exposto, as variáveis de entrada do modelo de RNA adotadas foram as variáveis de entrada do Cenário 1, com a inclusão das precipitações de dias anteriores,  $P_{t-6}$ ,  $P_{t-7}$  e  $P_{t-8}$ , da  $P_{60}$ , da  $P_{90}$ , da área e do mês, sendo esse novo conjunto de variáveis chamado de Cenário 2.

Apesar de ter sido observado uma melhora nos índices NSE, NSElog e  $r^2$  com a inclusão do número do mês, ainda assim, os resultados obtidos para algumas estações testadas localizadas na bacia do Rio São Mateus, Rio Novo e Santa Joana foram inferiores a 0,30, para o NSElog. Resultados insatisfatórios também foram obtidos para a bacia do Rio Jucu, com NSE inferior a 0,30. Já as estações testadas localizadas nas bacias dos Rios Itabapoana, Itapemirim, Guandu, Reis Magos e Santa Maria apresentaram NSE superior a 0,50, indicando bons resultados (NOORI; KALIN, 2016), e  $R^2$  superior a 0,60, o que significa que foram gerados resultados satisfatórios de acordo com Moriasi et al. (2015).


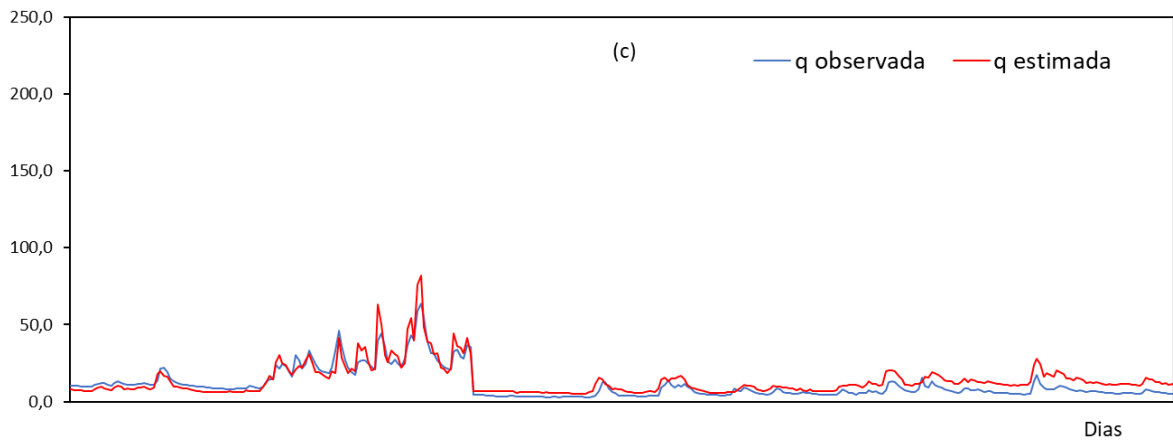

A título de exemplo, a Figura 15 apresenta o comportamento das vazões diárias específicas observadas e estimadas pelo modelo de RNA (variáveis de entrada: Cenário 2) em estações fluviométricas pertencentes a cada bacia hidrográfica dos Rios Itabapoana, Itapemirim, Jucu, Santa Maria, Guandu, Santa Joana e São Mateus, durante o ano de 2005.

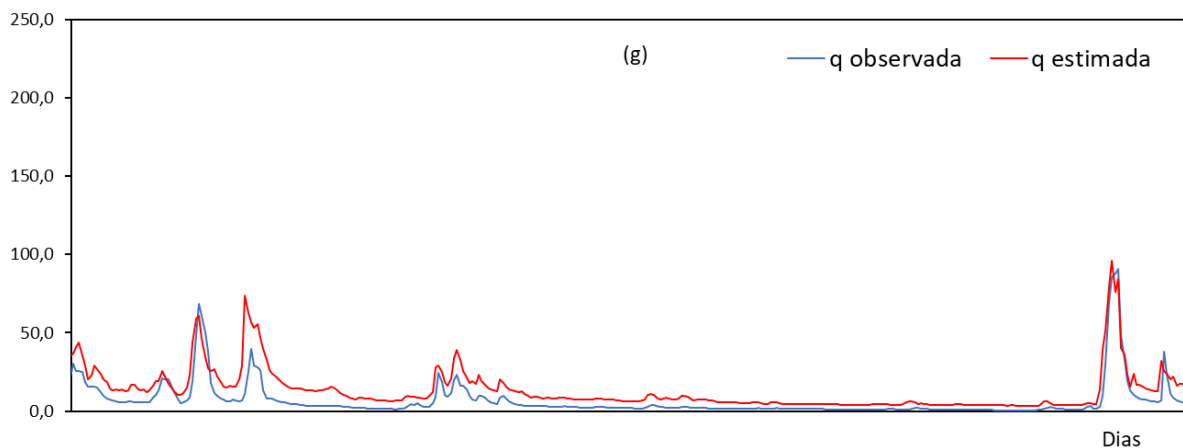


De acordo com a Figura 15, observou-se que as vazões diárias específicas estimadas para as estações fluviométricas utilizadas como testes, localizadas nas bacias hidrográficas dos Rios Itabapoana (Figura 15a), Itapemirim (Figura 15b), Jucu (Figura 15c), Santa Maria (Figura 15d) e Guandu (Figura 15e), foram bem próximas das vazões diárias específicas observadas, tanto para as vazões mínimas, quanto para as máximas. Já os resultados obtidos para as estações localizadas nos Rios Santa Joana (Figura 15f) e São Mateus (Figura 15g) mostraram que há uma tendência de superestimava das vazões estimadas com relação as vazões observadas, sendo mais evidente no período de janeiro a maio, principalmente para a estação localizada na bacia do Rio São Mateus.

Figura 15 - Hidrógrafa contendo as vazões diárias específicas no ano de 2005 das estações fluviométricas: 57830000- Rio Itabapoana (a); 57460000 – Rio Itapemirim (b); 57230000 – Rio Jucu (c); 57130000 – Rio Santa Maria (d); 56990990 – Rio Guandu (e); 56993002 – Rio Santa Joana (f); e 55800005 – Rio São Mateus (g).









Diante do exposto, ficou evidente que o modelo geral proposto, considerando o treinamento simultâneo das  $n-1$  estações inseridas na área em estudo, apresentou bons resultados apenas para as bacias hidrográficas dos Rios Itabapoana, Itapemirim (localizadas no sul do estado). Já para as bacias hidrográficas dos Rios São Mateus (localizada no norte do estado) e Santa Joana (afluente do Rio Doce), mesmo que os resultados obtidos tenham sido satisfatórios para o NSE, é necessário aumentar eficiência do modelo na estimativa das vazões, uma vez que os valores de NSElog

foram inferiores a 0,30. Por fim, para bacia do Rio Jucu, o modelo geral mostrou-se insatisfatório para a estimativa das vazões diárias.

### 5.2.2. Agrupamentos

O agrupamento 1 contém as estações fluviométricas pertencentes as bacias hidrográficas dos rios Itabapoana e Itapemirim (códigos das estações: 57930000, 57830000, 57580000, 57740000, 57460000, 57555000, 57450000, 57550000, 57720000, 57490000, 57400000, 57370000, 57350000, 57360000 e 57476500). O agrupamento 2 é formado pelas estações fluviométricas localizadas no litoral Centro-Sul (códigos das estações: 57300000, 57320000, 57230000, 57170000, 57130000 e 57040008). Já no agrupamento 3 estão inseridas as estações fluviométricas pertencentes a porção capixaba da bacia do Rio Doce (códigos das estações: 56990990, 56991500, 56993002, 56993551, 56992000, 56995500 e 56998400). Por fim, o agrupamento 4 abrange as estações fluviométricas localizadas na bacia do Rio São Mateus (código das estações: 55900000, 55920000, 55895000, 55960000, 55850000 e 55800005).

A Figura 16 apresenta os índices estatísticos obtidos para os testes executados nas estações fluviométricas, após o treinamento das RNA's de cada agrupamento, considerando como variáveis de entrada o Cenário 2. Já na Figura 17 são apresentados os índices estatísticos médios de cada agrupamento obtidos com as RNA's do modelo geral e dos agrupamentos.

Diante dos resultados apresentados nas Figuras 16 e 17, constatou-se que houve uma pequena melhoria nos índices estatísticos (NSE, NSElog e  $R^2$ ) do agrupamento 1, quando comparados aos índices obtidos com os testes executados considerando o treinamento simultâneo da rede para todo o estado (Figuras 9e, 10e e 11e). O NSElog resultante do teste da rede feito na estação 57360000, localizada no Rio Pardo afluente do Rio Itapemirim, por exemplo, aumentou cerca de 40% em relação ao índice resultante do modelo proposto ajustado para todo o estado. Para as demais estações do agrupamento 1, os índices NSE foram superiores a 0,66, indicando bons resultados (NOORI; KALIN, 2016).

Figura 16 – Resultados obtidos com a aplicação de uma rede para cada agrupamento: NSE (a); NSElog (b);  $r^2$  (c); e RMSE (d), em  $L s^{-1} km^{-2}$ .

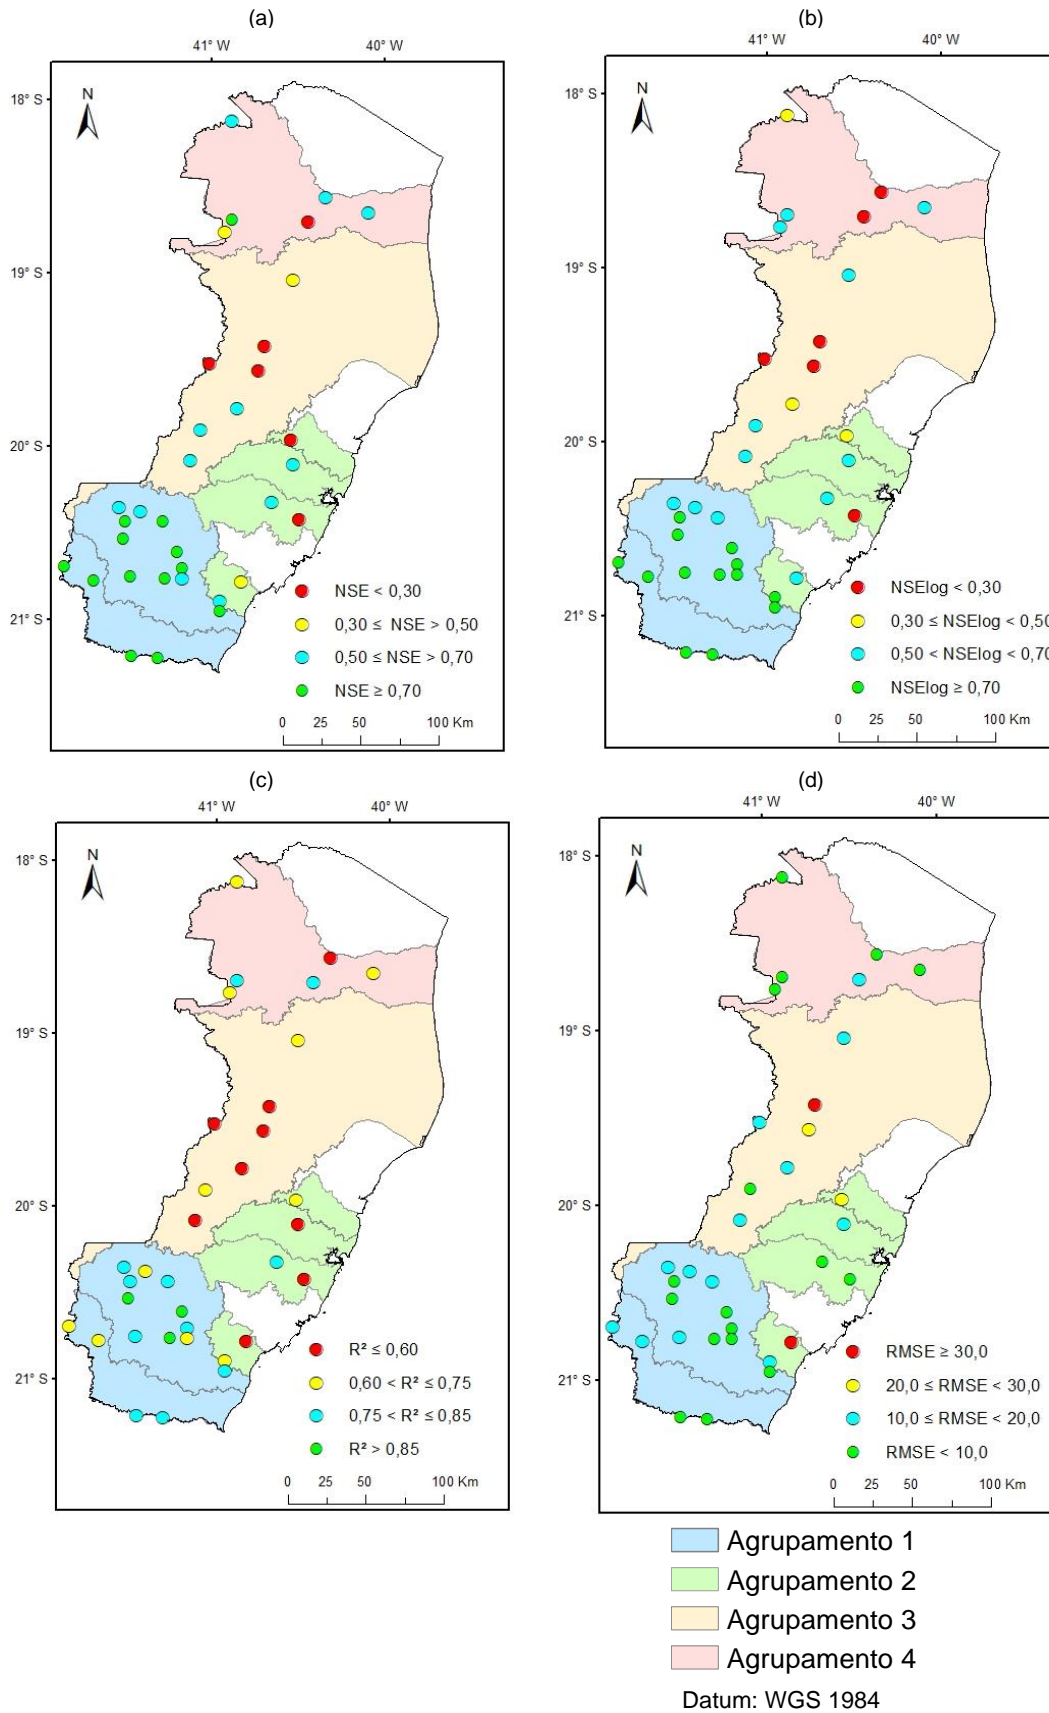



Figura 17 – Índices médios obtidos com a aplicação das RNA's para o modelo geral e para os modelos por agrupamento: NSE, NSElog e  $r^2$  (a) e RMSE (b), em  $L s^{-1} km^{-2}$ .



Delboni (2019) estimou as vazões diárias na bacia do Rio Itapemirim através dos modelos SWAT e MGB. Na fase de calibração do SWAT, a autora encontrou valores de NSE e RMSE iguais a: 0,81 e 25,72 para a estação 57450000, 0,67 e 10,70 para a estação 57490000, 0,72 e 13,39 para a estação 57550000 e 0,67 e 54,79 para a estação 57580000, respectivamente. Para essas estações, os resultados obtidos com a aplicação dos modelos de RNA's treinados com as estações do grupo 1, foram melhores que os do SWAT. Com relação ao modelo MGB, os modelos de RNA's também resultaram em valores de RMSE inferiores aos obtidos por Delboni (2019) para as mesmas estações (57450000, 57490000, 57550000 e 57580000).

Já no agrupamento 2, verificou-se que a estação 57300000, localizada em Rio Novo, teve uma melhora nos resultados obtidos em relação aos gerados pelo modelo ajustado para todo o estado, apresentando um aumento de quase 20% no índice NSE e uma redução de 16% no RMSE. Para a estação 57170000, localizada no Rio Jucu, o NSE passou de insatisfatório, com o modelo geral, para “muito bom”, segundo classificação de Noori e Kalin (2016). Nos testes executados nas demais estações deste agrupamento, não houve alteração expressiva nos resultados obtidos com o modelo proposto. Em termos médios, o desempenho do modelo para esse agrupamento teve uma piora nos resultados, quando comparado aos índices médios obtidos para o modelo geral (Figura 17).

Com relação ao agrupamento 3, quando comparados aos resultados obtidos com os testes executados com o modelo proposto para toda a área em estudo, notou-se que ocorreu uma diminuição no índice NSE em todas as estações. Com relação ao NSElog apenas a estação localizada no Rio Santa Joana (56993002) teve um aumento superior a 60%. Já para os demais índices analisados, RMSE e  $r^2$ , não houve melhora. Dessa forma, constatou-se que para o agrupamento 3, de forma geral, o desempenho do modelo por agrupamentos piorou, quando comparado aos índices médios resultantes do modelo geral (Figura 17).

Por fim, sobre o agrupamento 4, os resultados indicaram que o treinamento da rede feito apenas com as estações pertencentes a bacia hidrográfica do Rio São Mateus, resultaram um aumento nos índices estatísticos na maioria das estações em que foram executados os testes, quando comparados aos resultados apresentados nas Figuras 9e, 10e e 11e. O índice NSE (Figura 16a) foi inferior a 0,30 apenas na estação 55920000 (Córrego da Boa Esperança), indicando resultado insatisfatório, de acordo com a classificação de Noori e Kalin (2016). De forma geral, o modelo por agrupamentos não resultou em um aumento expressivo no índice NSElog e nos demais índices analisados ocorreu uma diminuição nos índices NSE e  $r^2$  (Figura 17a) e um aumento no RMSE (Figura 17b), quando comparados aos valores gerados pelo modelo geral

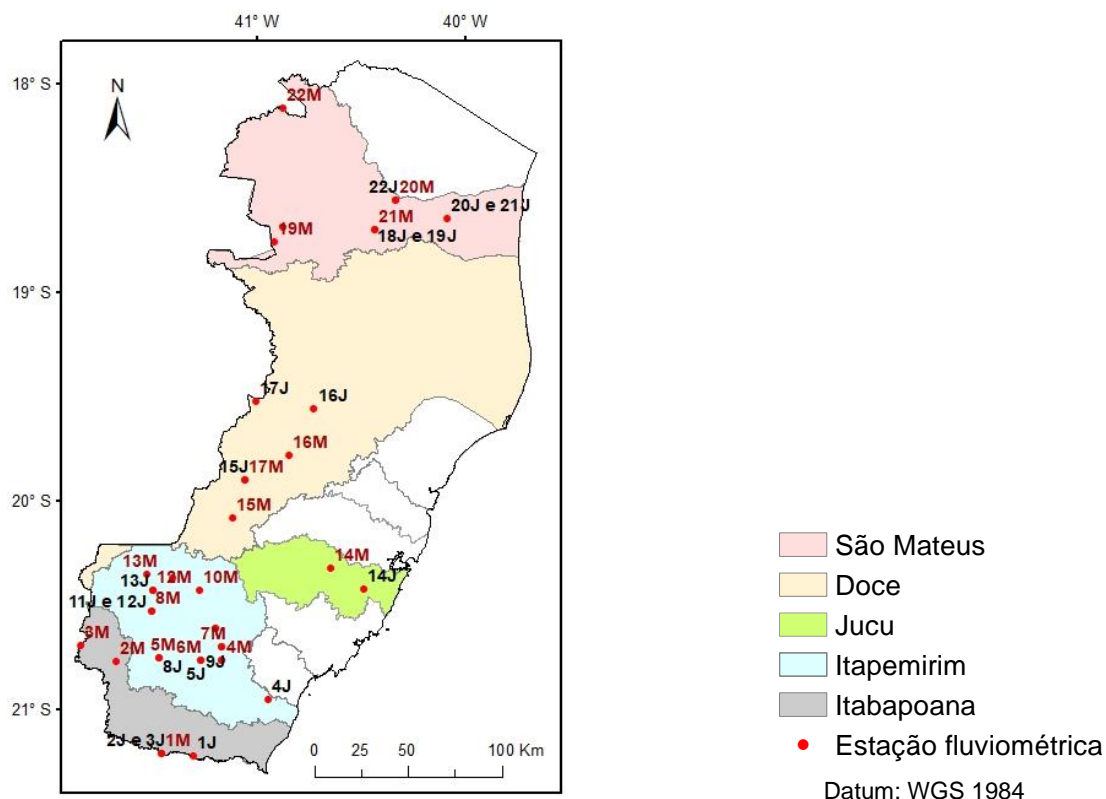
Diante do exposto, verificou-se que os modelos aplicados nos agrupamentos apresentados não proporcionaram melhora nos resultados obtidos para toda a área em estudo. Dessa forma, a escala espacial da aplicação do método proposto foi novamente reduzida, uma vez que, em geral, quanto menor é a distância entre as

estações fluviométricas, mais semelhante são as características físicas e climáticas das áreas de drenagem destas.

### 5.2.3. Pares de estações

Na área em estudo foi possível obter 22 pares de estações, os quais estão localizados nas bacias hidrográficas dos Rios Itabapoana, Itapemirim, Jucu e São Mateus; além disso também foi possível formar pares de estações nas sub-bacias do Rio Doce (Rios Guandu e Santa Joana). As localizações dos pares são apresentadas na Figura 18. Os pares de estações receberam um número de ordem de 1 a 22, iniciando das estações localizadas mais ao Sul do estado em direção ao Norte. As estações que receberam a letra J, junto ao número, significa que os dados daquela estação foram utilizados para o treino na rede; já os números que estão acompanhados com a letra M, indica que aquela estação foi utilizada para o teste do modelo proposto.

Figura 18 – Localização dos pares das estações fluviométricas testadas.



Fonte: a autora.

Após a aplicação do método proposto nos 22 pares de estações, considerando as variáveis de entrada do Cenário 2, foram obtidos os resultados apresentados na Figura 19. Já a Figura 20 apresenta os índices estatísticos médios obtidos para o modelo geral, o modelo por agrupamento e o modelo aplicado aos pares de estações.

Figura 19 – Resultados obtidos para o modelo proposto em pares de estações: NSE (a); NSElog (b);  $r^2$  (c); e RMSE (d), em  $L s^{-1} km^{-2}$ .

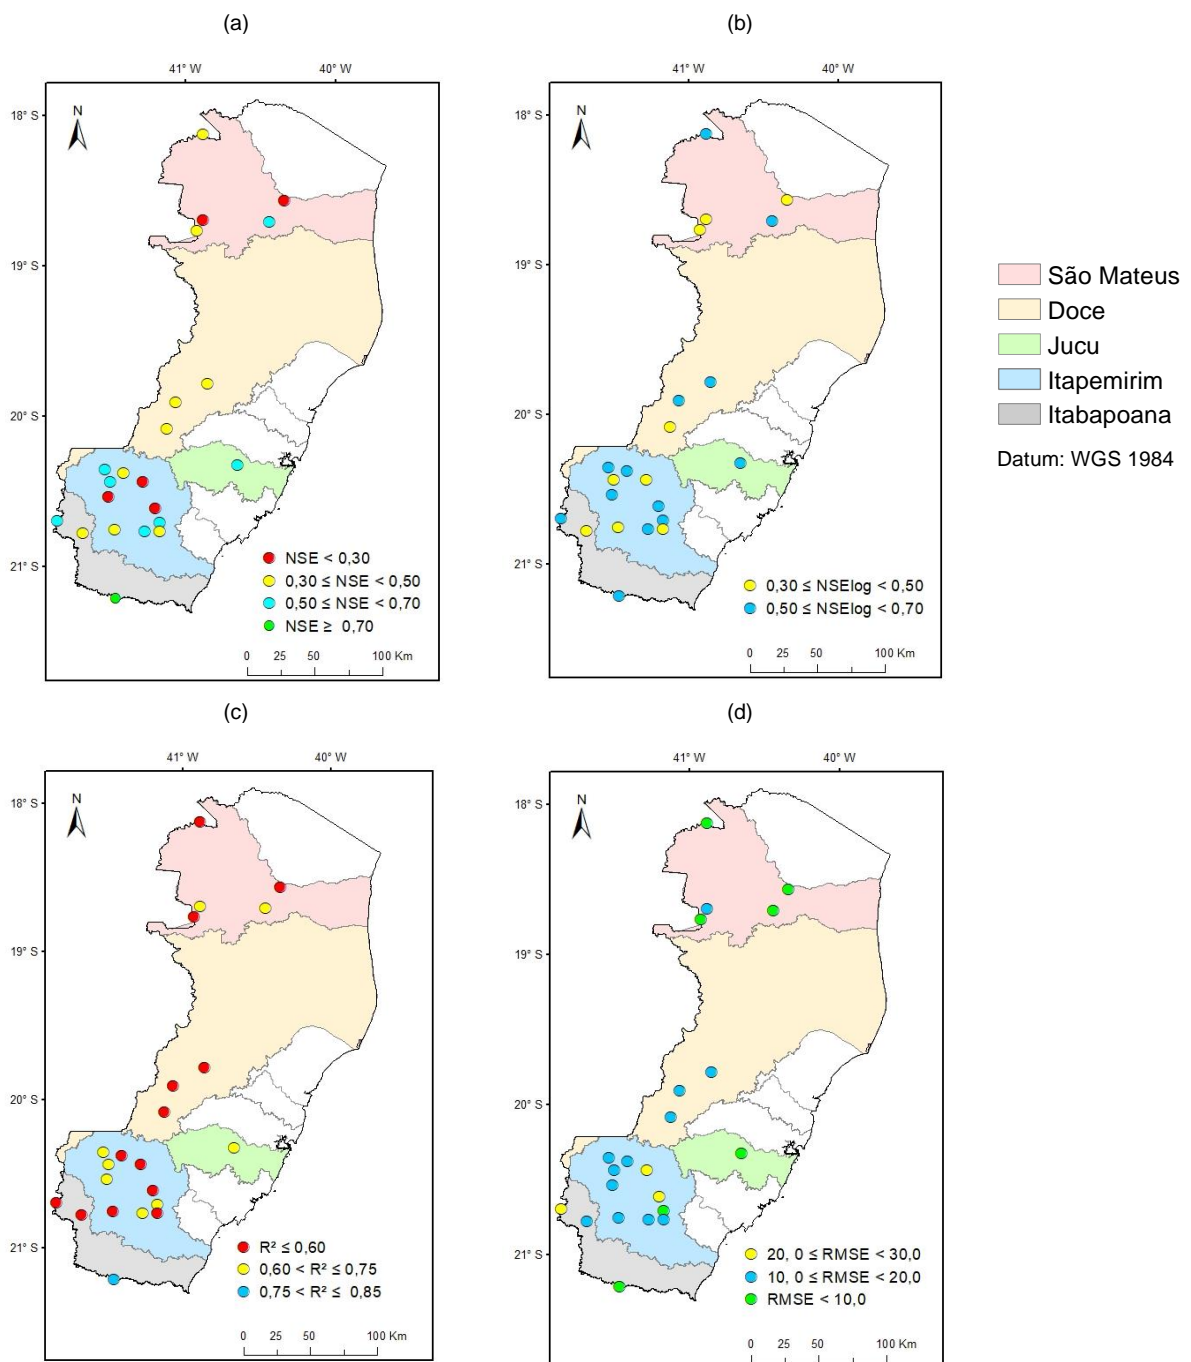





Figura 20 – Índices médios obtidos com a aplicação das RNA's para os modelos geral, por agrupamento e por pares de estações: NSE, NSElog e  $r^2$  (a) e RMSE (b), em  $L s^{-1} km^{-2}$ .



Para os pares localizados nas bacias dos Rios Itabapoana e Itapemirim (números de ordem de 1 a 13), observou-se que houve uma piora nos índices estatísticos (NSE, NSElog,  $r^2$  e RMSE) comparados aos testes executados para o modelo geral e para o agrupamento 1.

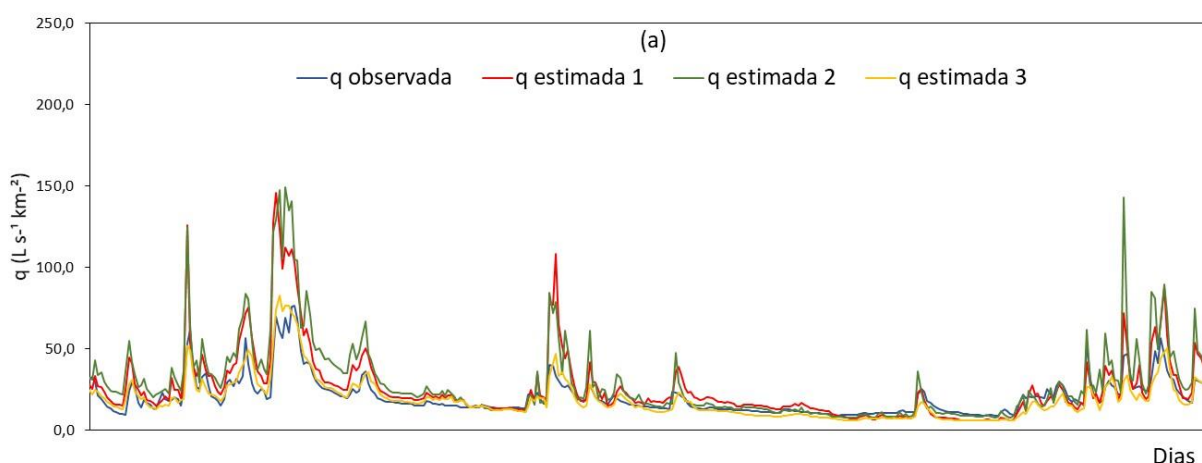
Já o par localizado na bacia do Rio Jucu (número de ordem 14) teve um aumento expressivo nos índices NSE, NSElog e  $R^2$  quando comparados aos resultados obtidos com as redes treinadas para o modelo geral e para o agrupamento 2, passando de resultados insatisfatórios para bons resultados, segundo a

classificação de Noori e Kalin (2016). A título de exemplo, a melhora nos resultados obtidos nessa bacia também pode ser evidenciada na Figura 21 através da hidrógrafa da estação 57170000, localizada no Rio Jucu. Observa-se que as vazões máximas e mínimas estimadas foram mais próximas das observadas quando a rede foi treinada com as estações a jusante.

Os testes executados nas bacias dos Rios Guandu e Santa Joana apresentaram um aumento nos valores de NSE, quando comparados aos testes executados para o agrupamento 3 e para o modelo geral, indicando no mínimo resultados satisfatórios para todas as estações testadas (NOORI; KALIM, 2016).

Nos pares localizados na bacia do Rio São Mateus (números de ordem 18 a 22) também foi evidenciado uma melhora no NSElog, quando comparado aos valores obtidos para o modelo por agrupamento, porém, ocorreu uma piora nos resultados em relação aos testes executados com o modelo geral. Com relação ao NSE, alguns pares de estações apresentaram resultados insatisfatórios para os testes executados em pares (NOORI; KALIN, 2016). Com relação ao índice  $R^2$ , observou-se uma piora nos resultados e o RMSE não houve mudança expressiva comparados aos testes executados com o agrupamento 4 e com o modelo geral.

Figura 21 – Hidrógrafa contendo as vazões diárias observadas ( $q$  observada) e as estimadas, durante o ano de 2005, para as RNA's do modelo geral ( $q$  estimada 1), para os agrupamentos ( $q$  estimada 2) e para os pares ( $q$  estimada 3), da estação fluviométrica 57170000.



De forma geral, notou-se que aplicando o método proposto em pares não houve melhoria nos índices estatísticos em todas as estações testadas neste estudo, quando comparados com os métodos geral e por agrupamento (Figura 20).

Entretanto, deve-se considerar que, neste caso, para a aplicação do método proposto na estimativa das vazões em um determinado curso d'água, deve existir uma estação fluviométrica com dados diários de vazões observadas no mesmo curso d'água, ou seja, o número de estações foi padronizado, usando-se apenas uma para treinamento da RNA (jusante) e outra para teste (montante), em todo o estado.

Com relação aos resultados obtidos para a bacia do Rio Itabapoana, tanto os obtidos pela rede treinada com as estações do agrupamento 1, quanto os obtidos para os pares de estações, foram bons, segundo classificação de Noori e Kalin (2016).

O melhor desempenho das RNA's nas bacias localizadas no Sul do Espírito Santo, tanto para o modelo geral, quanto para o modelo por agrupamento, pode estar relacionado a quantidade e a qualidade dos dados registrados de vazão existente nessa região. Além de haver um período de dados maior de registros, além do percentual de falhas ser menor, como pode ser observado no Quadro 2. Entretanto, quando foram executados os testes em pares de estações, ainda assim, alguns pares localizados nessa região apresentaram melhor desempenho, indicando que há outros fatores influenciando nos resultados.

Outra hipótese está relacionada a hidrogeologia do estado do Espírito Santo. De acordo com o mapa hidrogeológico do Espírito Santo, disponível no Sistema integrado de bases geoespaciais do estado do Espírito Santo (GEOBASES, 2020), ao leste da bacia do Rio São Mateus, por exemplo, existe um aquífero subterrâneo com alta produtividade, variando de 40,0 a 100,0 m<sup>3</sup> h<sup>-1</sup>; enquanto na porção oeste, os aquíferos possuem baixa produtividade, variando de 3,0 a 10,0 m<sup>3</sup> h<sup>-1</sup>. Essa característica faz com que o comportamento hidrológico ao longo da bacia seja distinto, visto que as vazões superficiais, durante o período de estiagem, têm o predomínio da contribuição do escoamento subterrâneo. Essa mudança no comportamento hidrológico nesta bacia pode ser a explicação para o baixo desempenho das RNA's treinadas no agrupamento 4.

### 5.3. Estimativa e comparação de vazões de referência

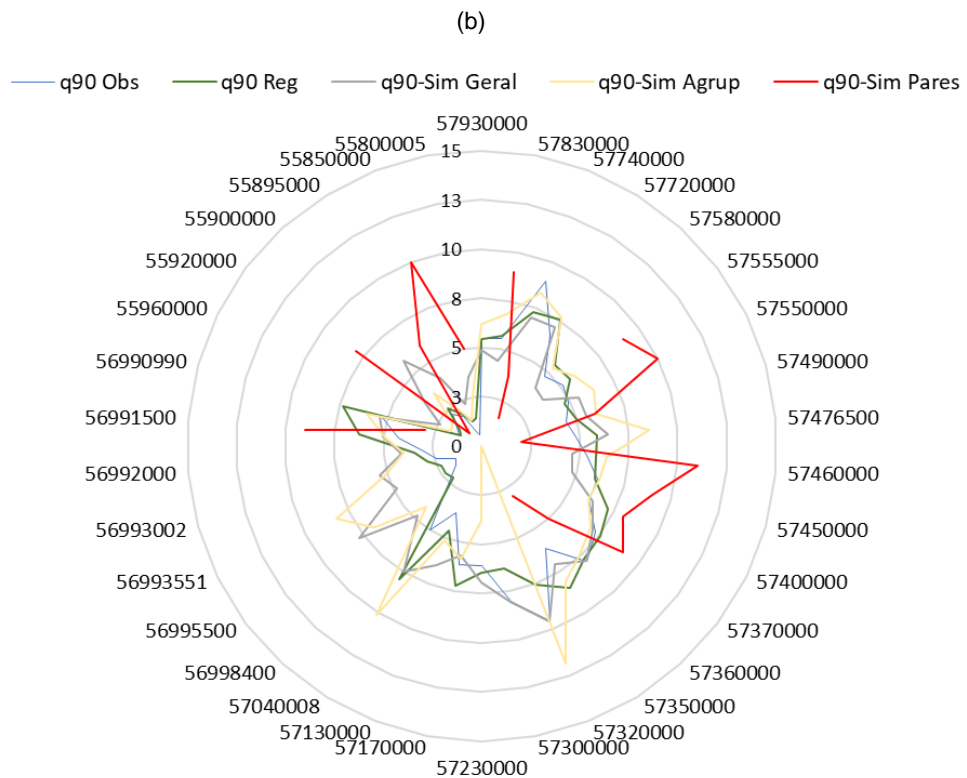
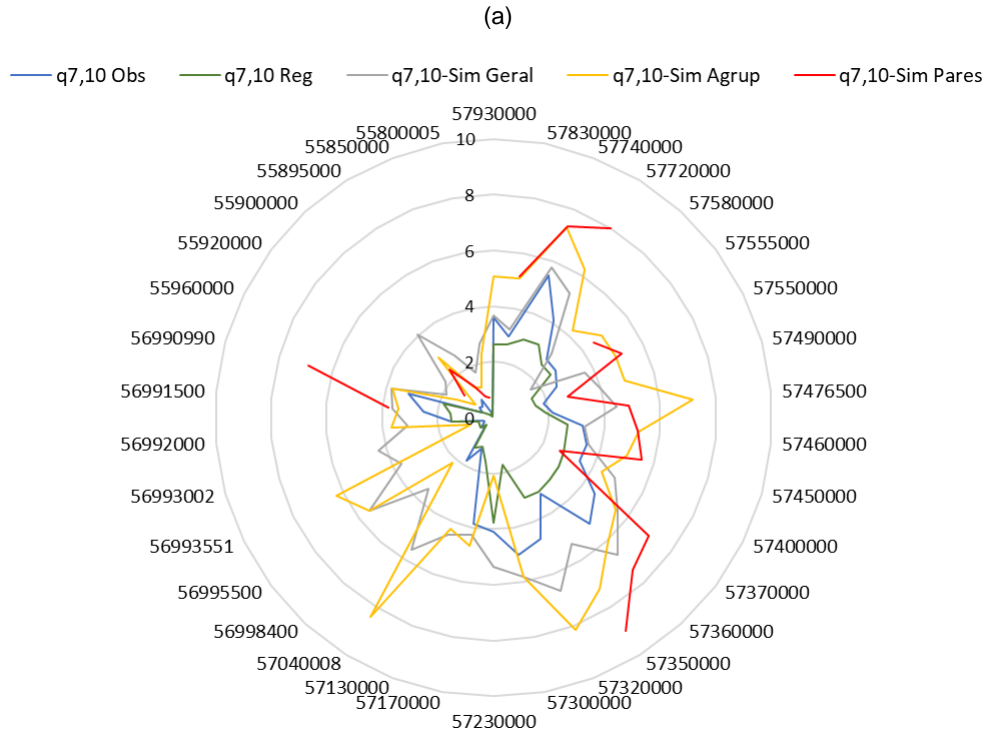
Após a seleção da melhor combinação de variáveis de entrada (Cenário 2), de acordo com os índices estatísticos, foram calculadas as vazões específicas de referência das séries sintéticas de dados de vazão geradas pela RNA ( $Q_{7,10-Sim}$ ,  $Q_{90-Sim}$  e  $Q_{mld-Sim}$ ) para cada estação fluviométrica utilizada para teste. Essas vazões foram comparadas com as vazões de referência dos dados registrados nessas estações ( $Q_{7,10}$ ,  $Q_{90}$  e  $Q_{mld}$ ), sendo a qualidade das estimativas avaliadas através do erro percentual. Além disso, as vazões de referência  $Q_{7,10}$ ,  $Q_{90}$  e  $Q_{mld}$  também foram comparadas com as vazões de referência regionalizadas ( $Q_{7,10-Reg}$ ,  $Q_{90-Reg}$  e  $Q_{mld-Reg}$ ) (AGERH, 2017).

Para melhor compreensão das magnitudes das vazões de referência, optou-se pela comparação das vazões de referências específicas observadas ( $q_{7,10}$ ,  $q_{90}$  e  $q_{mld}$ ) com as geradas pelas séries sintéticas ( $q_{7,10-Sim}$ ,  $q_{90-Sim}$  e  $q_{mld-Sim}$ ) e pelo método tradicional de regionalização ( $q_{7,10-Reg}$ ,  $q_{90-Reg}$  e  $q_{mld-Reg}$ ).

A Figura 22 apresenta as vazões de referência específicas observadas (Obs.), estimadas com os modelos geral (Sim. Geral), por agrupamentos (Sim. Agrup.) e por pares de estações (Sim. Pares), e as vazões regionalizadas (Reg.). Já a Figura 23 apresenta as vazões de referências específicas médias para todo o estado e subdivididas em macrorregiões do estado (Figura 24). Essa divisão foi utilizada para uma melhor visualização e discussão dos resultados.

Na Figura 25 são apresentados os erros percentuais médios obtidos entre as vazões de referências das séries sintéticas estimadas pelas RNA's e as regionalizadas, com as vazões de referências observadas. Por fim, na Figura 26 são apresentados os Índices estatísticos médios (NSE,  $r^2$  e RMSE em  $L s^{-1} km^{-2}$ ), para todo o estado e para as macrorregiões, obtidos para o modelo geral, agrupamentos e pares de estações, com as variáveis de entrada do Cenário 2.

Figura 22 –  $q_{7,10}$  (a),  $q_{90}$  (b),  $q_{mid}$  (c) estimadas com os dados observados, com as RNA's e as vazões regionalizadas (AGERH, 2017), em  $L s^{-1} km^{-2}$ , nas estações fluviométricas inseridas na área em estudo.



(c)

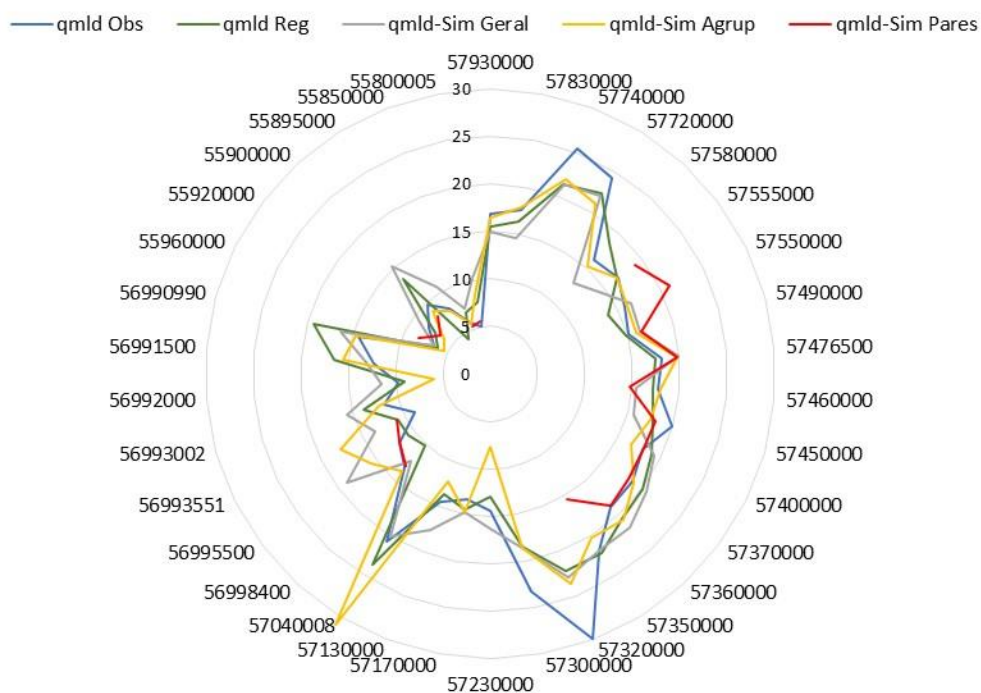


Figura 23 – Vazões de referências específicas médias ( $q_{7,10}$ ,  $q_{90}$  e  $q_{mld}$ ) obtidas com os dados observados (Obs.), com as séries sintéticas resultantes do modelo geral (Geral), por agrupamentos (Agrup.) e por pares de estações (Pares), além das vazões regionalizadas (Reg.) (AGERH, 2017), em  $L s^{-1} km^{-2}$ .


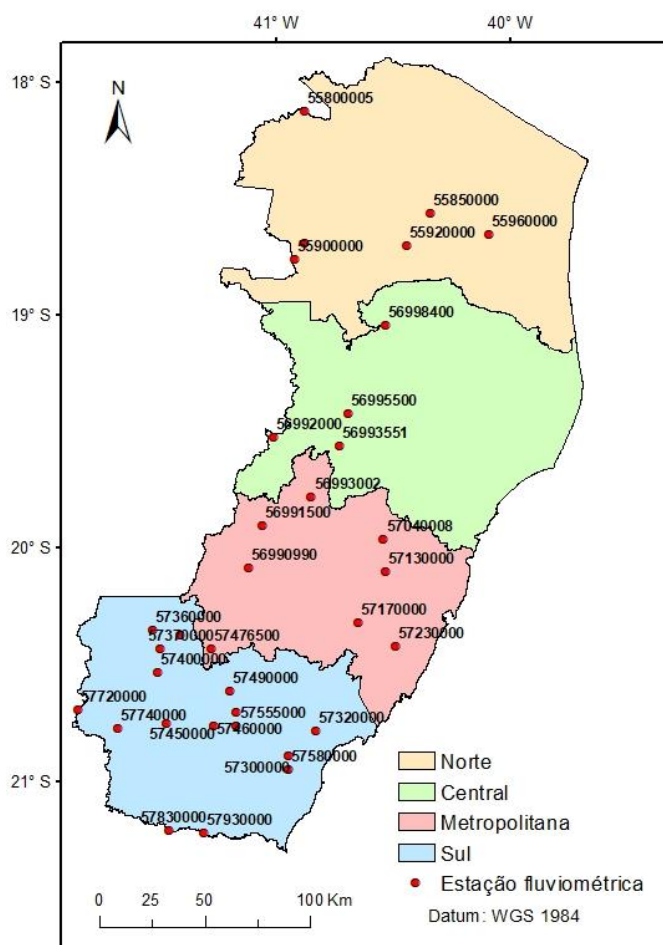



Figura 24 – Representação das macrorregiões do estado do Espírito Santo.



De acordo com os resultados apresentados na Figuras 22a, notou-se que há uma tendência de superestimativa da  $q_{7,10-Sim}$  para todos os modelos de RNA propostos (geral, por agrupamentos e por pares) em relação a  $q_{7,10}$ , principalmente para as estações localizadas na região Norte. Entretanto, para a  $q_{90}$  notou-se uma melhora expressiva nos resultados obtidos quando o modelo proposto foi aplicado no agrupamento 2 (Figuras 22b) e nos pares das estações localizadas nas macrorregiões Central e Metropolitana do estado.

Com relação as vazões mínimas de referência obtidas pelo método tradicional de regionalização de vazões, observou-se que a  $q_{7,10-Reg}$  foi subestimada em relação a observada ( $q_{7,10}$ ), principalmente para as estações localizadas nas regiões Sul e Metropolitana (Figuras 22a e 25). Entretanto, para a  $q_{90-Reg}$  há uma tendência de superestimava em relação a  $q_{90}$  em quase todas as estações (Figuras 22b e 25).

Figura 25 – Erros percentuais médios, em %, obtidos entre as séries sintéticas resultantes do modelo geral (Geral), por agrupamentos (Agrup.) e por pares de estações (Pares), e das vazões regionalizadas (Reg.) (AGERH, 2017), com as vazões de referência observadas (Obs.).



Com relação aos erros percentuais médios da  $q_{90-Sim}$ , constatou-se que para as estações localizadas na macrorregião Sul, os erros percentuais médios foram menores que os obtidos para  $Q_{90-Reg}$ , apenas na aplicação do método geral (Figura 25).

Já para as vazões médias, observou-se que também há uma tendência de superestimativa da  $Q_{mld-Sim}$  em relação a  $Q_{mld}$  mais evidente nas estações localizadas nas macrorregiões Metropolitana e Central do estado (Figuras 22a e 23). Entretanto, os erros percentuais médios da  $Q_{mld-Sim}$  na macrorregião Metropolitana foram inferiores aos obtidos para a  $Q_{mld-Reg}$  (Figura 25).

Cecílio et al. (2018) estimaram as vazões de referência para a bacia hidrográfica do Rio Itapemirim através dos métodos de regionalização de vazões: Tradicional, Interpolação Linear Chaves et al.(2002), Interpolação Linear Modificado e Chaves et al. (2002) Modificado. Comparando os erros percentuais médios obtidos pelos autores, verificou-se que, para as vazões mínimas de referência, apenas o



método tradicional resultou em erros médios inferiores aos obtidos nas aplicações dos modelos de RNA's, treinados com n-1 estações localizadas no estado, e testados nas estações localizadas na macrorregião Sul.

Com relação a  $Q_{mld}$ , os erros médios obtidos com as aplicações dos modelos de RNA's, treinados com as estações localizadas em todo o estado, no agrupamento 1, foram inferiores aos obtidos por Cecílio et al. (2018) em todos os métodos de regionalização de vazões aplicados pelos autores.

Dessa forma, mesmo que nos métodos de regionalização de vazões tradicionais, as equações são estimadas com variáveis conhecidas para áreas com características semelhantes (regiões hidrologicamente homogêneas) e, por isso, já se espera que as vazões estimadas sejam próximas as vazões reais, ainda assim os modelos de RNA's apresentaram bons resultados, principalmente para a  $Q_{mld}$ .

Vale lembrar que as vazões estimadas para as áreas de drenagem correspondentes a cada estação, foram geradas através de uma rede treinada sem o conhecimento prévio do comportamento hidrológico da respectiva estação. Sendo assim, pode-se considerar que o modelo RNA proposto é viável na estimativa das vazões, através da precipitação, na área em estudo, tendo potencial como uma ferramenta de suporte à decisão na gestão e planejamento dos recursos hídricos.

## 6. CONCLUSÕES

Com base nos resultados obtidos no presente estudo, foi possível concluir que:

- De maneira geral, o método proposto para estimativa das vazões diárias em bacias hidrográficas, por meio das redes neurais artificiais, mostrou-se eficiente quando aplicado em bacias não utilizadas no processo de treinamento da rede.
- A inclusão do número do mês e da área de drenagem, juntamente com os dados de chuva, aumentaram a eficiência do modelo geral.
- As vazões de referências calculadas com as vazões diárias, estimadas pelo método, apresentaram uma tendência de superestimativa em relação as vazões de referências observadas. Além disso, quanto mais restritiva forem essas vazões, maior é o erro percentual.
- Com relação ao método proposto aplicado nos pares de estações, houve uma tendência de decréscimo nos índices estatísticos na maioria das estações fluviométricas testadas da área de estudo. Entretanto, este estudo mostrou que o método proposto tem potencial de aplicação nestes casos, mas é necessário testar outras variáveis de entrada para o modelo.

Além disso, a escolha da amplitude espacial de aplicação do método, seja com o treinamento simultâneo da rede para toda a área em estudo, ou com a divisão em grupos ou com a formação de pares, dependerá da disponibilidade de dados registrados e do objetivo do trabalho.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

\_\_\_\_\_. Agência Estadual de Recursos Hídricos – Agerh. Mapas das bacias hidrográficas capixabas. Disponível em: <<https://agerh.es.gov.br/GrupodeArquivos/mapas-das-bacias-hidrograficas-capixabas>> Acessado em: 18 de abril de 2021.

\_\_\_\_\_. Instrução Normativa Nº 13, de 9 de dezembro de 2009, do Instituto Estadual de Meio Ambiente e Recursos Hídricos - IEMA

\_\_\_\_\_. Sistema de informações hidrológicas (Hidroweb). Disponível em: <https://www.snirh.gov.br/hidroweb/serieshistoricas> . Acesso em: 15 de dezembro de 2019.

ABBASPOUR, K. C. et al. A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. **Journal of Hydrology**, v. 524, p. 733–752, 2015.

AGERH, A. E. DE R. H. DO E. S. **Diagnóstico dos Recursos Hídricos do Estado do Espírito Santo Relatório Técnico sobre Disponibilidades Hídricas**. [s.l: s.n.]. Disponível em: <[https://perh.es.gov.br/Media/perh/Arquivos/Biblioteca/Diagnosticos/Diagnostico\\_Disponibilidade\\_Hidrica\\_PERHES.pdf](https://perh.es.gov.br/Media/perh/Arquivos/Biblioteca/Diagnosticos/Diagnostico_Disponibilidade_Hidrica_PERHES.pdf)>.

AICHOURI, I. et al. River Flow Model Using Artificial Neural Networks. **Energy Procedia**, v. 74, p. 1007–1014, 2015.

ALMEIDA, L.; SERRA, J. C. V. Modelos hidrológicos, tipos e aplicações mais utilizadas. **Revista da FAE**, v. 20, n. 1, p. 129–137, 2017.

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

AMIRI, B. J.; SUDHEER, K. P.; FOHRER, N. Linkage between in-stream total phosphorus and land cover in chugoku district , Japan : an ann approach **J. Hydrol. Hydromech**, v. 60, p. 33–44, 2012.

ANDRADE, C. W. L. et al. Análise de sensibilidade de parâmetros do modelo SWAT em uma sub-bacia da Região Nordeste, Brasil. **Revista Brasileira de Geografia**, v. 51, n. 2, p. 440–453, 2017.

ANDRADE, C. W. L. et al. Soil moisture and discharge modeling in a representative watershed in northeastern Brazil using SWAT. **Ecohydrology and Hydrobiology**, v. 19, n. 2, p. 238–251, 2019.

ARAÚJO, C. B. C. DE; DANTAS NETO, S. A.; SOUZA FILHO, F. DE A. Previsão de vazões para açude Orós/CE a partir de dados hidrometeorológicos utilizando perceptrons. **Revista Brasileira de Meteorologia**, v. 30, p. 37–46, 2015

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L. **Redes neurais com aplicações em controle e em sistemas especialistas**. 1. ed. V. Books, Florianópolis: 2000.

BAKSHAEI, M. et al. Estimativa de escoamento em captação urbana utilizando modelos de rede neural artificial. **Sistemas & Gestão**, v. 15, n. 2, p. 170–180, 2020.

BORSATO, F.; MARTONI, A. M. Estudo da fisiografia das bacias hidrográficas urbanas no Município de Maringá, Estado do Paraná. **Acta Scientiarum. Human and Social Sciences**, v. 26, n. 2, p. 273–284, 2004.

BREUER, L. et al. Assessing the impact of land use change on hydrology by ensemble modeling (LUCHEM). I: Model intercomparison with current land use. **Advances in Water Resources**, v. 32, n. 2, p. 129–146, 2009.

BRUBACHER, J. P.; DE OLIVEIRA, G. G.; GUASSELLI, L. A. Gap filling in historical data of daily precipitation in Rio Grande do Sul. **Revista Brasileira de Meteorologia**, v. 35, n. 2, p. 335–344, 2020.

CAMPANILI, M.; PROCHNOW, M. **Mata atlântica: uma rede para a floresta**. 2006. Disponível em: [https://apremavi.org.br/frutos/uma-rede-pela-floresta/..](https://apremavi.org.br/frutos/uma-rede-pela-floresta/)

CECÍLIO, R. A. et al. Evaluation of low-flow and long term average flow regionalization methods on Itapemirim river watershed. **Scientia Agraria**, v. 19, n. 2, p. 122–132, 2018.

CECÍLIO, R. A.; MENDES, H. D. A.; ZANETTI, S. S. Multiple solutions, multi-site, and parameter transfer to calibrate DHSVM hydrological model. **Ciência e Natura**, v. 43, p. e7, 2021.

CHAVES, H. et al. Regionalização de Vazões Mínimas em Bacias Através de Interpolação em Sistemas de Informação Geográfica. **Revista Brasileira de Recursos Hídricos**, v. 7, n. 3, p. 43–51, 2002.

CHENG et al. Long lead-time daily and monthly streamflow forecasting using machine learning methods M. **Journal of Hydrology**. v. 590, p: 1-13, 2020.

CORREIA, T. P. **Aplicação do modelo swat para simulação de cenários de uso da terra na bacia hidrográfica do Rio Jucu**. Dissertação (Mestrado em Ciências Florestais) Universidade Federal do Espírito Santo, 2016.

DE ARAÚJO, C. B. C. et al. Seasonal flow forecast for the orós dam (Ceará, Brazil) using neural networks and the resampling technique of k-neighbors. **Revista Brasileira de Meteorologia**, v. 35, n. 2, p. 197–207, 2020.

DEBASTIANI, A. B.; SILVA, R. D. DA; RAFAELI NETO, S. L. 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.

DELBONI, T. C. **Análise comparativa de modelos hidrológicos em função de suas estruturas e parametrização e de resultados de aplicações em bacias**

**hidrográficas.** Dissertação (Mestrado em Engenharia Ambiental) Universidade Federal do Espírito Santo, 2019.

DEO, R. C.; ŞAHIN, M. An extreme learning machine model for the simulation of monthly mean streamflow water level in eastern Queensland. **Environmental Monitoring and Assessment**, v. 188, n. 2, p. 1–24, 2016.

DEVIA, G. K.; GANASRI, B. P.; DWARAKISH, G. S. A Review on Hydrological Models. **Aquatic Procedia**, v. 4, n. December, p. 1001–1007, 2015.

DINIZ, F. DE A.; RAMOS, A. M.; REBELLO, E. R. G. Brazilian climate normals for 1981-2010. **Pesquisa Agropecuaria Brasileira**, v. 53, n. 2, p. 131–143, 2018.

FENICIA, F.; MCDONNELL, J. J.; SAVENIJE, H. H. G. Learning from model improvement: On the contribution of complementary data to process understanding. **Water Resources Research**, v. 44, n. 6, p. 1–13, 2008.

FERNANDES, L. G. L.; PORTUGAL, M. S.; NAVAUX, P. O. Previsão de séries de tempo: redes neurais artificiais e modelos estruturais. **Pesquisa e Planejamento Econômico**, v. 26, n. 2, p. 253–276, 1996.

FERRAZ, F. et al. Method for the analysis of the relationship between forest cover and streamflow in watersheds. **iForest - Biogeosciences and Forestry**, v. 14, n. 4, p. 344–352, 2021.

FERRAZ, F. T. **Método para análise da relação entre florestas e vazões em bacias hidrográficas.** Dissertação (Mestrado em Ciências Florestais) Universidade Federal do Espírito Santo, 2018.

FUKUNAGA, D. C. et al. Application of the SWAT hydrologic model to a tropical watershed at Brazil. **Catena**, v. 125, p. 206–213, 2015.

GASQUES, A. C. F. et al. Regionalization of minimum flows : brief theoretical review. **Revista Eletrônica de Engenharia Civil**, v. 14, n. 2, p. 60–70, 2018.

GAZZAZ, N. M. et al. Artificial neural network modeling of the water quality index for Kinta River ( Malaysia ) using water quality variables as predictors. **Marine Pollution Bulletin**, v. 64, n. 11, p. 2409–2420, 2012.

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

HASSAN, M.; HASSAN, I. Improving ANN-based streamflow estimation models for the Upper Indus Basin using satellite-derived snow cover area. **Acta Geophysica**. v: 68, n. 6; p: 1791-1801, 2020.

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

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

HEUVELMANS, G.; MUYS, B.; FEYEN, J. Regionalisation of the parameters of a hydrological model: Comparison of linear regression models with artificial neural nets. **Journal of Hydrology**, v. 319, n. 1–4, p. 245–265, 2006.

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

ISIK, S. et al. Modeling effects of changing land use / cover on daily streamflow : An Artificial Neural Network and curve number based hybrid approach. **Journal of Hydrology**, v. 485, p. 103–112, 2013.

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

JIMENO-SÁEZ, P. et al. A comparison of SWAT and ANN models for daily runoff simulation in different climatic zones of peninsular Spain. **Water (Switzerland)**, v. 10, n. 2, 2018.

KALIN, L.; ISIK, S.; LOCKABY, B. G. Predicting Water Quality in Unmonitored Watersheds Using Artificial Neural Networks. **Journal of Environmental Quality**, v. 39, p. 1429–1440, 2010.

KRAUSE, P.; BOYLE, D. P.; BÄSE, F. Comparison of different efficiency criteria for hydrological model assessment. **Advances in Geosciences**, v. 5, p. 89–97, 2005.

LI, B.; MCCLENDON, R. W.; HOOGENBOOM, G. Spatial interpolation of weather variables for single locations using artificial neural networks. **American Society of Agricultural Engineers**, v. 47, n. 2, p. 629–637, 2004.

MACHADO, A. R.; MELLO JUNIOR, A. V.; WENDLAND, E. W. Avaliação do modelo J2000/JAMS para modelagem hidrológica em bacias hidrográficas brasileiras. **Engenharia Sanitaria e Ambiental**, v. 22, n. 2, p. 327–3407, 2017.

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

MAIER, H. R.; DANDY, G. C. Neural network based modelling of environmental variables: A systematic approach. **Mathematical and Computer Modelling**, v. 33, n. 6–7, p. 669–682, 2001.

MARINHO FILHO, G. M. et al. Modelos Hidrológicos: Conceitos E Aplicabilidades. **Revista de Ciências Ambientais**, v. 6, n. 2, p. 35–47, 2012.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity (reprinted from bulletin of mathematical biophysics, vol 5, pg 115-133, 1943). **Bulletin of Mathematical Biology**, v. 52, n. 1--2, p. 99–115, 1990.

MENDONÇA, L. et al. Modelagem chuva-vazão via redes neurais artificiais para

simulação de vazões de uma bacia hidrográfica da Amazônia. **Revista de Gestão de Água da América Latina**, v. 18, n. 1, p. 2–0, 2021.

MORIASI, D. et al. Hydrologic and Water Quality Models: Performance Measures and Evaluation Criteria. **Transactions of the ASABE**, v. 58, n. 6, p. 1763–1785, 2015.

NASH, J. E.; SUTCHIFFE, J. V. River flow forecasting through conceptual models part i - a disclission of principles\*. **Journal of Hydrology**, v. 10, p. 282–290, 1970.

NIST/SEMATECH. **Engeneering Statistics**. 2013. Disponível em: <https://www.itl.nist.gov/div898/handbook/>

NOORI, N.; KALIN, L. Coupling SWAT and ANN models for enhanced daily streamflow prediction. **Journal of Hydrology**, v. 533, p. 141–151, 2016.

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

OLYAIE, E. et al. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States. **Environmental Monitoring and Assessment**, v. 187, n. 4, 2015.

ÖZÇELİK, R. et al. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**, v. 91, n. 3, p. 742–753, 2010.

PALANI, S. et al. ANN application for prediction of atmospheric nitrogen deposition to aquatic ecosystems. **Marine Pollution Bulletin**, v. 62, n. 6, p. 1198–1206, 2011.

PFANNERSTILL, M.; GUSE, B.; FOHRER, N. Smart low flow signature metrics for an improved overall performance evaluation of hydrological models. **Journal of Hydrology**, v. 510, p. 447–458, 2014.

PRADHAN, P.; TINGSANCHALI, T.; SHRESTHA, S. Evaluation of Soil and Water Assessment Tool and Artificial Neural Network models for hydrologic simulation in different climatic regions of Asia. **Science of the Total Environment**, v. 701, 2020.

PRUSKI, F. F. et al. Improved regionalization of streamflow by use of the streamflow equivalent of precipitation as an explanatory variable. **Journal of Hydrology**, v. 476, p. 52–71, 2013.

PRUSKI, F. F. et al. Low-flow estimates in regions of extrapolation of the regionalization equations: a new concept. **Engenharia Agrícola**, v. 35, n. 5, p. 808–816, 2015.

RAZAVI, T.; COULIBALY, P. Streamflow Prediction in Ungauged Basins: Review of Regionalization Methods. **Journal of Hydrologic Engineering**, v. 18, n. 8, p. 958–975, 2013.

REIS, G. B. et al. Effect of environmental covariable selection in the hydrological modeling using machine learning models to predict daily streamflow. **Journal of Environmental Management**, v. 290, n. April, 2021.

RENNÓ, C. D.; SOARES, J. V. **Modelos Hidrológicos para Gestão Ambiental**. [s.l.] Programa de Ciência e Tecnologia para Gestão de Ecossistemas Ação "Métodos, modelos e geoinformação para a gestão ambiental", 2000.

REZAEIAN-ZADEH, M.; TABARI, H.; ABGHARI, H. Prediction of monthly discharge volume by different artificial neural network algorithms in semi-arid regions. **Arabian Journal of Geosciences**, v. 6, n. 7, p. 2529–2537, 2013.

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

RODRIGUEZ, R. DEL G. **Prosposta conceitual para a regionalização de vazões**. Tese. (Doutorado em Engenharia Agrícola) Universidade Federal de Viçosa, 2008.

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

SAHOO, G. B.; RAY, C.; CARLO, E. H. DE. Use of neural network to predict flash flood and attendant water qualities of a mountainous stream on Oahu, Hawaii. **Journal of Hydrology**, v. 327, p. 525–538, 2006.

SALAME, C. W. et al. Um estudo comparativo dos modelos box-jenkins e redes neurais artificiais na previsão de vazões e precipitações pluviométricas da bacia Araguaia, Tocantins, Brasil. **Revista Brasileira de Ciências Ambientais**, v. 52, p. 28–43, 2019.

SARAIVA, I.; FERNANDES, W.; NAGHETTINI, M. Simulação Hidrológica Mensal em Bacias Hidrográficas sem Monitoramento Fluviométrico. **Revista Brasileira de Recursos Hídricos**, v. 16, n. 1, p. 115–125, 2011.

SÁRKÖZY, F. GIS functions - interpolation. **Periodica Polytechnica Civil Engineering**, v. 43, n. 1, p. 63–86, 1999.

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

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas - Curso básico**. São Paulo: 2010.

SINGH, K. P. et al. Artificial neural network modeling of the river water quality — A case study. **ecological modelling**, v. 220, p. 888–895, 2009.

SOUSA, H. T. et al. **SisCAH 1.0: Sistema Computacional para análises hidrológicas**. 1. ed. Brasília, DF: ANA, Viçosa: UFV, 2009 60p.



- TUCCI, C. E. M. **Regionalização de vazões**. Porto Alegre: UFRGS, 2002, 250p.
- TUCCI, C. E. M. **Modelos hidrológicos**. 2. ed. Porto Alegre: UFRGS, 1998.
- ULIANA, E. M. et al. Desenvolvimento de redes neurais artificiais para estimativa das vazões diárias na bacia do Rio Piracicaba. **Irriga**, v. 23, n. 4, p. 756–772, 2018.
- ULIANA, E. M. et al. Hybrid hydrological model for water flow prediction in the piracicaba river basin-MG, Brazil. **Revista Brasileira de Meteorologia**, v. 34, n. 4, p. 471–480, 2019.
- VANZELA, L. S.; HERNANDEZ, F. B. T.; FRANCO, R. A. M. Influência do uso e ocupação do solo nos recursos hídricos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 17, p. 55–64, 2010.
- VERTESSY, R. A. et al. Predicting water yield from a mountain ash forest catchment using a terrain analysis based catchment model. **Journal of Hydrology**, v. 150, n. 2–4, p. 665–700, 1993.
- VILANOVA, R. S.; ZANETTI, S. S.; CECÍLIO, R. A. Assessing combinations of artificial neural networks input / output parameters to better simulate daily stream flow: Case of Brazilian Atlantic Rainforest watersheds. **Computers and Electronics in Agriculture**, v. 167, n. January, p. 105080, 2019.
- VILANOVA, R. S.; ZANETTI, S. S.; CECÍLIO, R. A. Artificial Neural Networks – Based Model Parameter Transfer in Streamflow Simulation of Brazilian Atlantic Rainforest Watersheds. **Journal of Hydrologic Engineering**, v. 25, n. 7, p. 1–10, 2020.
- VILLELA, S. M.; MATTOS, A. **Hidrologia Aplicada**. São Paulo: Mcgraw Hill, 1975. 245p.
- WAGENA et al. Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. **Environmental Modelling and Software**. v. 126, p: 1-10, 2020.
- WHEATER, H. S. Modelling hydrological processes in arid and semi-arid areas: An introduction to the workshop. **Hydrological Modelling in Arid and Semi-Arid Areas**, v. 9780521869, p. 1–20, 2007.
- XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980-2013). **International Journal of Climatology**, v. 36, p. 2644–2659, 2015.
- YASEEN, Z. M. et al. Artificial intelligence based models for stream-flow forecasting: 2000-2015. **Journal of Hydrology**, v. 530, p. 829–844, 2015.
- YASEEN, Z. M. et al. Stream-flow forecasting using extreme learning machines: A case study in a semi-arid region in Iraq. **Journal of Hydrology**, v. 542, p. 603–614, 2016.

ZHANG, G.; PATUWO, B. E.; HU, M. Y. Forecasting with artificial neural networks : The state of the art. **International Journal of Forecasting**, v. 14, p. 35–62, 1998.