

**ALINE BERNARDA DEBASTIANI**

**DESEMPENHO DE REDES NEURAIS ARTIFICIAIS E  
ÁRVORES DE REGRESSÃO NA MODELAGEM DO  
PROCESSO CHUVA-VAZÃO DA BACIA DO ALTO CANOAS**

Dissertação apresentada ao Curso de Mestrado em Engenharia Florestal do Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, como requisito para a obtenção do grau de mestre em Engenharia Florestal.

Prof. Dr. Sílvio Luís Rafaeli Neto

**LAGES, SC  
2016**



**ALINE BERNARDA DEBASTIANI**

**DESEMPENHO DE REDES NEURAIS ARTIFICIAIS E  
ÁRVORES DE REGRESSÃO NA MODELAGEM DO  
PROCESSO CHUVA-VAZÃO DA BACIA DO ALTO CANOAS**

Dissertação referente ao Curso de Mestrado em Engenharia Florestal do Centro de Ciências Agroveterinárias, pertencente à Universidade do Estado de Santa Catarina, para a obtenção do título de mestre em Engenharia Florestal tendo como concentração a área de produção florestal.

**Banca Examinadora:**

Orientador:

---

Prof. Dr. Sílvio Luís Rafaeli Neto  
Centro de Ciências Agroveterinárias – CAV/UDESC

Membro:

---

Olavo Correa Pedrollo  
Universidade do Rio Grande do Sul (UFRGS), Instituto de  
Pesquisas Hidráulicas

Membro:

---

Prof. Dr. Marcos Benedito Schimalski  
Centro de Ciências Agroveterinárias – CAV/UDESC



## **AGRADECIMENTOS**

À Deus por me dar saúde, discernimento e forças para lutar pelos meus objetivos.

Aos meus pais Ilceu e Nelci, aos meus irmãos Douglas e Francine por me entenderem, me apoiarem nas decisões e por muitas vezes dedicarem parte de seus recursos financeiros em prol da minha educação.

A minha “Família Lageana”, Renata Menegatti, Jaiane Lazaretti, Greicy Salvador, Hadson Hoffer, Rorai Neto, Tásquila Loiola, Juliana Dallabrida, Rafael Fracasso e Alana Spanhol que me acolheram, foram amigos, companheiros e alegraram estes dias. Pessoas assim, nos dão forças para continuar, nos fazem querer ser melhores, a confiar nas pessoas e almejar sempre te-los por perto.

Ao professor Mosar Botelho, aos amigos Ricardo da Silva, Mauricio de Sousa e Karina Guollo por me incentivarem a ingressar na pós graduação e por toda a ajuda e parceria durante este período, sem vocês eu não poderia ter concluído, jamais esquecerei. A minha amiga Karina Guollo em especial, que mesmo longe esteve sempre tão perto, sempre compartilhando comigo as dúvidas, tristezas e alegrias, sem dúvidas a melhor cúmplice que eu poderia ter.

Aos meus colegas de laboratório Thiago Antunes, Eder Sá, Victor Padilha, Carolina Natel, Guilherme Ricardo e tantos outros que passaram pelo laboratório, proporcionando uma parceria, troca de experiências e muitas risadas.

Ao meu orientador Sílvio Luis Rafaeli Neto, por aceitar me orientar, por ter paciência mesmo quando nossos pensamentos não coincidiam, pelas suas sugestões e críticas que resultaram nesta pesquisa.

À FAPESC pela concessão de bolsa durante a realização deste estudo e ao CAV/UDESC pelo ensino de qualidade.

A todos que de uma forma ou outra contribuíram para que esta dissertação fosse concluída, o meu muito obrigada.



## RESUMO

DEBASTIANI, Aline Bernarda. **Desempenho de redes neurais artificiais e árvores de regressão na modelagem do processo chuva-vazão da bacia do Alto Canoas.** 2016. 88f. Dissertação (Mestrado em Engenharia Florestal) Universidade do Estado de Santa Catarina. Programa de Pós-Graduação em Engenharia Florestal, Lages, 2016.

A estimativa do comportamento futuro das vazões mínimas, médias e máximas de uma bacia hidrográfica é fundamental para a elaboração do plano de gerenciamento dos seus recursos hídricos. Existem duas abordagens de modelos que possibilitam gerar séries de previsões: a abordagem dos modelos baseados nos processos físicos que ocorrem na bacia e a abordagem dos modelos orientados a dados. Esta dissertação se propõe a avaliar modelos orientados a dados, dentre os quais, os mais populares são as Redes Neurais Artificiais (RNAs). As Árvores de Regressão (RT) também apresentam grande potencial de aplicação, embora pouco difundidas na Hidrologia, motivo pelo qual estão incluídas neste trabalho. Estes modelos foram avaliados na bacia hidrográfica do Alto Canoas, cujo exutório coincide com a Estação Rio Bonito. No capítulo 1, o objetivo foi avaliar o desempenho de uma RNA do tipo *Multi Layer Perceptron* (MLP), em modo *closed-loop*, tratando-se diferentes combinações de vetores de entrada, visando determinar o mais adequado para estimar as vazões diárias. Os vetores de entrada foram constituídos de séries observadas de precipitação, evapotranspiração e da vazão do dia anterior. O treinamento foi realizado em modo *open-loop*, em que todos os tratamentos de entrada do modelo foram constituídos pela vazão observada do dia anterior ( $t-1$ ) entre outras. Para a simulação da vazão no período de teste foi utilizada a MLP em modo *open-loop* e *closed-loop*, sendo a última composta por uma das entradas a vazão simulada em  $t-1$ . A combinação de vetores de entrada que apresentou melhor desempenho foi constituído pelo registro da precipitação diária nas quatro estações pluviométricas, precipitação com atraso de  $t-2$  dias para as mesmas quatro estações e vazão em  $t-1$ . O capítulo 2 apresenta a avaliação do desempenho, na escala mensal, de algumas RTs (M5P, *REP Tree* e *Decision Stump*) frente ao desempenho de uma RNA do tipo MLP. O experimento foi configurado com um período para treinamento e dois períodos para teste. Entre as RTs, a



M5P produziu os melhores resultados. Em um dos períodos de teste, a M5P apresentou desempenho semelhante ao da MLP, sendo considerada uma alternativa interessante ao uso de RNAs.

**Palavras-chave:** gerenciamento de recursos hídricos, aprendizado de máquina, *closed-loop*, árvore de regressão.



## **ABSTRACT**

DEBASTIANI, Aline Bernarda. **Performance of artificial neural networks and regression trees in the rainfall-runoff modeling in the basin Alto Canoas process.** 2016. 88f. Dissertation (Master in Forest Engineering) Santa Catarina State University. Forest Engineering Graduate Program, Lages, 2016.

The future behavior estimate of minimum, medium and maximum discharges of a watershed is essential to elaborate the management plan of its water resources. There are two modelling approaches to generate predictions series: models that consider the physical processes occurring in the basin and data-oriented models. This work aims to evaluate data-oriented models, among which the most popular are the Artificial Neural Networks (ANN). The Regression Trees (RT) also have great potential for this kind of application, but they are not so widespread in Hydrology, which is why they were included in this work. These models were evaluated in the Upper Canoas basin, whose outlet coincides with Rio Bonito Station. In the first chapter, the objective was to evaluate the performance of an ANN method called Multi Layer Perceptron (MLP) in closed-loop mode to estimate daily discharge, considering different input vectors in order to assess the most appropriate combinations. The input vectors data series were composed of observed precipitation, evapotranspiration and discharge of the previous day. The training was held in open-loop mode, where all model input treatments were constituted of observed flow rate of the previous day ( $t-1$ ) among other variables. To simulate the flow in the test period was the MLP used for open-loop and closed-loop mode, the latter being composed of a simulated flow of entries in  $t-1$ . The combination of input vectors with the best performance constituted of daily rainfall of the four rainfall stations, rainfall with  $t-2$  days delay of the same four stations and discharge with  $t-1$  day delay. The second chapter presents an evaluation of modeling performance in the monthly scale comparing some RTs (M5P, REP Tree and Decision Stump) and the MLP ANN. The experiment was set up with one period for training and two periods for testing. Among the RTs, the M5P produced the best results. In one of the test periods, M5P presented similar performance to the MLP, being considered an interesting alternative to using ANNs.



**Keywords:** water resources management, machine learning, closed-loop, regression tree.



## LISTA DE FIGURAS

Figura 1 - Localização da Bacia hidrográfica do Alto Canoas.....	35
Figura 2 - Períodos dos sub-conjuntos de treinamento, validação e teste indicados no hidrograma e hietograma diários entre 1996 e 1999.....	37
Figura 3 - Arquitetura da <i>Multi Layer Perceptron</i> (MLP), (A) arquitetura <i>open-loop</i> ; (B) arquitetura <i>closed-loop</i> . .....	37
Figura 4 - Função de auto-correlação (FAC) e intervalo de confiança de 95%: A) precipitação da estação Urubici (P1); B) precipitação da estação Vila Canoas (P2); C) precipitação da estação Lomba Alta (P3); D) precipitação da estação Anitápolis (P4); E) evapotranspiração de referência (ET <sub>0</sub> ), F) vazão observada (Q <sub>obs</sub> ) na estação Rio Bonito.....	42
Figura 5 - Correlação cruzada (CC) com intervalo de confiança de 95% entre a vazão e: A) precipitação da estação Urubici (P1); B) precipitação da estação Vila Canoas (P2); C) precipitação da estação Lomba Alta (P3); D) precipitação da estação Anitápolis (P4); E) evapotranspiração (ET <sub>0</sub> ), F) vazão observada (Q <sub>obs</sub> ) na estação Rio Bonito.....	44
Figura 6 - Hidrograma da vazão observada e simulada pela MLP nos tratamentos 5, 8 e 10, para parte do período analisado.....	49
Figura 7 - Análise da contribuição relativa (CR) de cada variável para os tratamentos 5 (A), 8 (B) e 10 (C).....	50
Figura 8 -Boxplots dos resíduos das (A) vazões mínimas (n = 770), (B) vazões médias (n = 276) e (C) vazões máximas (n = 414). 51	51
Figura 9 - Períodos dos sub-conjuntos de treinamento (01/1980 a 12/1984) e validação cruzada (01/1985 a 05/1987), onde PP: precipitação média diária do mês ponderada pela contribuição relativa de cada estação pluviométrica na área da bacia.....	60
Figura 10 - Hidrograma da precipitação média diária do mês e vazão média do mês do sub-conjunto de teste 1 (06/1987 a 12/1989). .....	60
Figura 11 - Hidrograma da precipitação média diária do mês e vazão média do mês do sub-conjunto de teste 2 (01/1998 a 12/1999). .....	61
Figura 12 - Delineamento experimental.....	63



Figura 13 - Correlação cruzada com intervalo de 95% de confiança entre vazão e: A) P1 - precipitação na estação Urubici; B) P2 - precipitação na estação Vila Canoas; C) P3 - precipitação na estação Lomba Alta; D) P4 - precipitação na estação Anitápolis; E) Q - vazão observada na estação Rio Bonito.	67
Figura 14 - Hidrograma observado e simulado pela MLP e M5P no tratamento 1 e período de teste 1.....	77
Figura 15 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 1 e período de teste 1.....	78
Figura 16 - Hidrograma observado e simulado pela MLP e pela M5P no tratamento 1 e no período de teste 2.....	79
Figura 17 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 1 e período de teste 2.....	79
Figura 18 - Hidrograma observado e simulado pela MLP e pela M5P no tratamento 4 e no período de teste 1.....	80
Figura 19 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 4 e período de teste 1.....	81
Figura 20 - Hidrograma observado e simulado pela MLP e pela M5P no tratamento 4 e no período de teste 2.....	82
Figura 21 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 4 e período de teste 2.....	82



## LISTA DE TABELAS

Tabela 1 – Constituição dos vetores de entrada e saída das arquiteturas aplicadas nas etapas de modelagem. ....	38
Tabela 2 – Matriz de correlação linear de Pearson (R) entre as variáveis utilizadas para compor os vetores de entrada da RNA.....	41
Tabela 3 -Índices de eficácia da simulação da vazão média diária pela MLP em <i>open-loop</i> no período de treinamento e teste sobre os tratamentos combinatórios dos vetores de entrada.....	46
Tabela 4 - Índices de eficácia da simulação da vazão média diária pela MLP em <i>closed-loop</i> no período de teste sobre os tratamentos combinatórios dos vetores de entrada.....	47
Tabela 5 - Estatísticas das precipitações médias diárias do mês e vazão média do mês nos sub-conjuntos de treinamento e testes...	64
Tabela 6 - Matriz de correlação linear de Pearson entre as séries de precipitações (P) e de vazões (Q) utilizadas para compor os sub-conjuntos de dados.....	65
Tabela 7 - Desempenho do algoritmo M5P sem poda (SP) e com poda (CP) para a simulação da vazão nos períodos de treinamento e testes nos diferentes tratamentos de entrada do modelo..	69
Tabela 8 - Desempenho do algoritmo <i>REP Tree</i> sem poda (SP) e com poda (CP) para a simulação da vazão para os períodos de treinamento e testes nos diferentes tratamentos de entrada do modelo.....	71
Tabela 9 - Desempenho do algoritmo <i>Decision Stump</i> para a simulação da vazão para os períodos de treinamento e testes nos diferentes tratamentos de entrada do modelo. ....	73
Tabela 10 - Desempenho da RNA - MLP na fase de treinamento e arquitetura para os diferentes tratamentos de entrada do modelo.....	74
Tabela 11 - Desempenho da RNA - MLP para a simulação da vazão para os períodos de teste 1 e 2 para os diferentes tratamentos. ....	74
Tabela 12 - Desempenho dos algoritmos de RT e RNA para a simulação da vazão para os períodos de teste 1 e de teste 2 nos diferentes tratamentos.....	75



## **LISTA DE ABREVIATURAS E SIGLAS**

CC	Correlação Cruzada
CP	Com Poda
CR	Contribuição Relativa
ETo	Evapotranspiração de Referência
FAC	Funções de Auto-Correlação
M5P	Árvore Modelo
MLP	<i>Multi Layer Perceptron</i>
NS	Nash-Sutcliffe
P	Precipitação
PP	Precipitação Ponderada
R <sup>2</sup>	Coeficiente de Determinação
RMSE	Raiz do Erro Médio Quadrático
RNA	Rede Neural Artificial
RT	<i>Regression Trees</i>
SP	SemPoda
WEKA	<i>Waikato Environment for Knowledge Analysis</i>



## SUMÁRIO

<b>INTRODUÇÃO .....</b>	<b>27</b>
<b>REFERÊNCIAS .....</b>	<b>29</b>
<b>CAPÍTULO 1: DESEMPENHO DE UMA REDE NEURAL ARTIFICIAL NA PREVISÃO DE VAZÕES DIÁRIAS .....</b>	<b>31</b>
RESUMO .....	31
ABSTRACT .....	31
1.1 INTRODUÇÃO .....	32
1.2 MATERIAL E MÉTODOS .....	34
1.2.1 Área de estudo .....	34
1.2.2 Variáveis das camadas de entrada e de saída .....	35
1.2.3 Análise exploratória .....	36
1.2.4 Estrutura da simulação da vazão em <i>open-loop</i> e <i>closed-loop</i> .....	36
1.2.5 Eficácia da MLP .....	38
1.2.6 Contribuição relativa dos vetores de entrada na MLP .....	39
1.3 RESULTADOS E DISCUSSÃO .....	40
1.3.1 Análise exploratória .....	40
1.3.2 Constituição dos vetores de entrada da MLP .....	45
1.3.3 Eficácia da MLP em <i>open-loop</i> e <i>closed-loop</i> .....	46
1.3.4 Contribuição relativa dos vetores de entrada .....	49
1.3.5 Análise de resíduos .....	51
1.4 CONCLUSÃO .....	52
1.5 REFERÊNCIAS .....	52
<b>CAPÍTULO 2: DESEMPENHO DE ÁRVORES DE REGRESSÃO e rede neural artificial NA PREVISÃO DE VAZÕES médias diárias do mês.....</b>	<b>56</b>
RESUMO .....	56
ABSTRACT .....	56
2.1 INTRODUÇÃO .....	57
2.1.1 Árvores de regressão.....	58
2.2 MATERIAL E MÉTODOS .....	59
2.2.1 Área de estudo e série histórica.....	59
2.2.2 Análise exploratória .....	61
2.2.3 Estrutura dos ensaios e simulação da vazão média do mês por RNA e RT.....	61
2.2.4 Avaliação dos métodos .....	63
2.3 RESULTADOS E DISCUSSÃO .....	64
2.3.1 Análise exploratória .....	64



<b>2.3.2 Desempenho das árvores de regressão (RT) .....</b>	<b>68</b>
<b>2.3.2.1 Desempenho do algoritmo M5P .....</b>	<b>68</b>
<b>2.3.2.2 Desempenho do algoritmo <i>REP Tree</i> .....</b>	<b>70</b>
<b>2.3.2.3 Desempenho do algoritmo <i>Decision Stump</i> .....</b>	<b>72</b>
<b>2.3.3 Desempenho da Rede Neural Artificial .....</b>	<b>74</b>
<b>2.3.4 Análise conjunta dos desempenhos dos algoritmos de RT .....</b>	<b>75</b>
<b>2.4 CONCLUSÕES.....</b>	<b>83</b>
<b>2.5 REFERÊNCIAS .....</b>	<b>84</b>
<b>CONSIDERAÇÕES FINAIS .....</b>	<b>88</b>



## INTRODUÇÃO

A hidrologia pode ser definida como a ciência que estuda os processos naturais que armazenam ou transferem a água no ciclo hidrológico e suas relações físicas com o espaço geográfico e a sociedade. Destacam-se na fase terrestre deste ciclo os processos de infiltração da água no solo, de escoamento superficial e sub-superficial, de evaporação, de evapotranspiração e de vazão no sistema hidrográfico. Na fase climática, tem-se o processo de precipitação, especificamente a chuva como sendo a precipitação da água na forma líquida. A nível de uma bacia hidrográfica, a chuva é a principal forma de entrada de água e a vazão no exutório a principal saída. A contabilidade hídrica destes fluxos ocorre pelo balanço de massa.

A interdependência e relacionamentos entre os processos do ciclo hidrológico na bacia hidrográfica, bem como sua magnitude ou grau de importância no sistema, caracterizam as dificuldades em analisá-los.

Com a popularização dos computadores no final da década de 1950 foi possível o crescimento e desenvolvimento de modelos hidrológicos com base em conceitos físicos, em contraponto aos modelos hidrológicos estocásticos até então predominantes naquela época (TUCCI, 2005).

Os modelos hidrológicos são tentativas de representar estes processos por meio de relações formais. Sua principal utilidade estaria no melhor conhecimento do sistema e no apoio aos processos de tomada de decisão. Estes são técnicas que procuram prever o comportamento do sistema hidrológico, a partir de premissas que estabeleçam condições diferentes das condições inicialmente observadas.

Os modelos hidrológicos são ferramentas computacionais utilizadas como instrumento para a simulação das variáveis hidrológicas de uma bacia, dentre as quais a vazão no seu exutório. A previsão de vazões é um recurso fundamental no âmbito do gerenciamento de recursos hídricos. As vazões previstas podem ser analisadas como cenários ou prognósticos durante a etapa de elaboração dos Planos de Bacias. Este planos são documentos que estabelecem as diretrizes fundamentais do gerenciamento dos seus recursos hídricos, disponíveis aos Comitês de Bacias e agências de águas. Gerenciar os recursos hídricos significa criar um conjunto de regras para a alocação da água, o que, em última instância, é a essência do sistema de gestão dos recursos hídricos (PORTO; PORTO, 2008).

Os modelos hidrológicos podem ser classificados de acordo com alguns critérios, os quais podem estar relacionados com o tipo de variável utilizada na modelagem (estocástica ou determinística), tipo de relação entre as variáveis (empírico ou conceitual), forma de representação dos dados (discreto ou contínuo), existência ou não de relação espacial (concentrado ou distribuído) e dependência temporal (estacionário ou dinâmico) (TUCCI, 2005).

Os modelos conceituais, ou de base física, representam o sistema hidrológico por meio de um número de processos físicos considerados relevantes pela modelagem. Geralmente, estes modelos aplicam a solução de um sistema de equações que representam a melhor compreensão dos processos e fluxos de massa na bacia (TUCCI, 2005). De acordo com Fayal (2008), as maiores dificuldades no uso dos modelos de base física são determinar os parâmetros fixos das equações e em representar a variabilidade espacial com que os processos ocorrem.

Os modelos orientados a dados também são designados de modelos “caixas-pretas”. São classificados como modelos empíricos porque tratam a bacia hidrográfica como um sistema do tipo caixa-preta, ou seja, buscam encontrar uma relação numérica entre as entradas com as saídas de água da bacia, ignorando os processos intermediários. Estes modelos tradicionalmente provêm das áreas de estatística, computação, inteligência artificial e de mineração de dados (SOLOMATINE; DULAL, 2003).

As redes neurais artificiais são os modelos orientados a dados mais conhecidos e utilizados na modelagem do processo chuva-vazão. Porém, há estudos que utilizam também as árvores de regressão (SOLOMATINE; DULAL, 2003), lógica difusa (BARBALHO, 2001) e abordagem bayesiana (SILVA et al., 2014) para a modelagem do processo chuva-vazão.

A potencial utilidade dos modelos orientados a dados estaria na simplicidade conceitual aplicada ao sistema hidrológico de uma bacia hidrográfica, a rapidez do processo de treinamento do modelo, a possibilidade de se obter altos índices de qualidade nas previsões e na possibilidade de serem aplicados em situações que exigem respostas rápidas do modelo, como no caso da previsão de inundações.

Utilizar modelos hidrológicos é uma abordagem necessária no Brasil, diante da carência de estudos que subsidiem a etapa de prognóstico da construção dos Planos de Bacias.

Diante desta necessidade e da carência de estudos hidrológicos com modelos orientados a dados, elaborou-se um conjunto de

experimentos visando avaliar o desempenho de modelos orientados a dados, especificamente calçados em Redes Neurais Artificiais (RNA) e Árvores de Regressão (RT). O Capítulo 1 avalia o desempenho de uma RNA e o Capítulo 2 avalia o desempenho de três RTs. A RNA foi avaliada na escala diária e a RT na escala mensal, frente a uma RNA também na escala mensal (vazão média diária do mês).

Os estudos foram aplicados na bacia hidrográfica do Alto Canoas, em cujo exutório está instalada a estação fluviométrica Rio Bonito, pertencente à Agência Nacional de Águas (ANA). Esta bacia foi selecionada em virtude da disponibilidade de dados e da sua importância hidrológica para a bacia do Rio Canoas, por nela se encontrar a nascente do principal rio formador do Rio Uruguai (Rio Canoas, junto à Serra do Corvo Branco, no município de Urubici), por estar relativamente bem preservada em termos ambientais e ainda por ser considerada uma importante zona de recarga do Aquífero Guarani (ANTUNES, 2015).

Para a bacia do Alto Canoas já foram realizados os estudos com os modelos de base física: TOPMODEL (SÁ, 2014) e SWAT (ANTUNES, 2015). Sendo assim, esta dissertação também visa complementar com os estudos nesta área, procurando contribuir com a modelagem hidrológica através de redes neurais artificiais e de árvores de regressão.

## REFERÊNCIAS

**ANTUNES, T. A. Modelagem hidrológica da bacia hidrográfica do Alto Canoas através do modelo SWAT.** 2015. 130 f. Dissertação (Mestrado em Engenharia Florestal) –Universidade do Estado de Santa Catarina, Lages, 2015.

**BARBALHO, V. M. S. Sistemas baseados em conhecimento e lógica difusa para simulação do processo chuva-vazão.** 2001. 77 f. Tese (Doutorado em Ciências) –Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

**FAYAL, M. A. A. Previsão de vazão por redes neurais artificiais e transformada.** 2008. 158 f. Dissertação (Mestrado em Engenharia Elétrica), Pontifícia Universidade Católica do Rio de Janeiro, 2008.

**PORTE, M. F. F.; PORTO, R. L.L.** Gestão de bacias hidrográficas. **Estudos Avançados**, v.22, n.63, 2008.

SÁ, E. A. S. **Estudo do modelo TOPMODEL na bacia hidrográfica do Alto Canoas – SC.** 2014. 103 f. Dissertação (Mestrado em Engenharia Florestal) –Universidade do Estado de Santa Catarina, Lages, 2014.

SILVA, F. E.; NAGHETTINI, M.; FERNANDES, W. Avaliação bayesiana das incertezas nas estimativas dos parâmetros de um modelo chuva-vazão conceitual. **Revista Brasileira de Recursos Hídricos.** V. 19, n. 4, p.148-159, 2014.

SOLOMATINE, D. P.; DULAL, K. N. Modeltrees as analternativeto neural networks in rainfall-runoffmodeling.**HidrologicalSciences**, v.48, n.3, p.399-411, 2003.

TUCCI, C. E. M. **Modelos hidrológicos.** 2. ed. Porto Alegre: Editora da UFRGS, 2005.

## CAPÍTULO 1: DESEMPENHO DE UMA REDE NEURAL ARTIFICIAL NA PREVISÃO DE VAZÕES DIÁRIAS

### RESUMO

Tendo em vista a necessidade da estimativa da resposta hidrológica desta bacia hidrográfica do Alto Canoas para a elaboração do plano de bacia, o objetivo desse estudo foi de avaliar a simulação do comportamento hidrológico da bacia através de redes neurais artificiais *Multi Layer Perceptron* (MLP), bem como de analisar a contribuição das variáveis de entrada para a modelagem. Foram testados 10 tratamentos sendo estes combinações de variáveis de precipitação e evapotranspiração de referência (ET<sub>0</sub>), além de transformações e deslocamentos temporais dessas, a fim de determinar as variáveis que promovessem o melhor desempenho da modelagem da vazão. A MLP foi treinada em modo *open-loop* utilizando parte das vazões observadas. Tendo a MLP treinada, as vazões diárias para toda série foram simuladas em *open-loop* e também *closed-loop*, utilizando a vazão simulada no passo de tempo anterior como entrada. O algoritmo de aprendizado utilizado foi o de Levenberg-Marquardt. O tratamento que apresentou melhor desempenho (NS = 0,9119, RMSE = 14,29 m<sup>3</sup>/s) empregou a precipitação diária das quatro estações pluviométricas (P1 – P4), precipitação das quatro estações com defasagem de t-2 dias, e vazão simulada do dia anterior. Apesar do baixo RMSE, a vazão modelada pela MLP foi, em geral, superestimada.

**Palavras-chave:** modelo chuva-vazão, MLP, algoritmo de Garson, bacia hidrográfica do Canoas

### ABSTRACT

In view of the need to estimate the hydrological response of the watershed of the Upper Canoas to prepare the basin plan, the aim of this study was to evaluate the simulation of the hydrological behavior of the basin through artificial neural networks Multi Layer Perceptron (MLP), as well as to analyze the contribution of the variables for modeling. It were tested 10 treatments with these combinations of variables such as reference evapotranspiration (ET<sub>0</sub>) and precipitation, as well as transformations and temporal displacements of these variables, in order to determine the variables that promoted the better performance of flow

modeling. The MLP was trained in open-loop mode using part of the observed flow rates. Having trained the MLP, the daily flow rates for all series were simulated in open-loop as well as closed-loop, using the simulated flow in the previous time step as input. The learning algorithm used was the Levenberg-Marquardt. The treatment with the best performance ( $NS = 0.9119$ ,  $RMSE = 14.29 \text{ m}^3/\text{s}$ ) employed the daily precipitation of the four rainfall stations ( $P_1 - P_4$ ), precipitation of the four seasons with  $t-2$  days of discrepancy, and simulated flow rate from the previous day. Despite the low RMSE, the modeled flow by MLP was generally overestimated.

**Key-Words:** rainfall-runoff model, Garson algorithm, basin of Canoas.

## 1.1 INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) que utilizam o método MLP (*Multi Layer Perceptron*) tem sido cada vez mais estudadas na Hidrologia. As MLPs possuem capacidade de modelar sistemas não-lineares, sem a necessidade de se fazer quaisquer suposições sobre a interação das variáveis que compõem tais sistemas (RIAD et al., 2004).

A estrutura de uma MLP é constituída por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (FU, 1994). A MLP com arquitetura tradicional aqui denominada como *open-loop* é comumente estudada em simulação de sistemas hidrológicos, o que consiste em fornecer dados observados no tempo  $t-1$  como entrada para simular a saída no tempo  $t$ . Fornecer como entrada o valor observado, no tempo  $t-1$ , da variável de saída, é uma abordagem que tem demonstrado sucesso em diversos estudos hidrológicos. A técnica *closed-loop* é uma opção a esta variante, pouco explorada nestes estudos, onde o valor fornecido do vetor de saída no tempo  $t-1$  é o valor simulado pela própria MLP (ABRAHART et al., 2004).

Por outro lado a combinação de vetores na entrada da RNA tem se demonstrado um fator relevante no sucesso da rede em simulação hidrológica. Santos e Pereira Filho (2003) concluíram que o conjunto de vetores composto pelas variáveis precipitação observada no tempo  $t$  (em dias) ( $P_t$ ) e vazão observada no tempo  $t-1$  ( $Q_{t-1}$ ) produziu um  $R^2$  acima de 0,93, ao passo que o uso de apenas  $P_t$  produziu um  $R^2$  máximo de 0,409. Batista (2009) utilizou a vazão média mensal como vetor de entrada da RNA com o objetivo de comparar seu desempenho com relação à metodologia de Box e Jenkins. Concluiu que a RNA produziu

previsão mais precisa da vazão média mensal (erro quadrático médio de previsão de 779,59 m<sup>3</sup>/s) em relação à metodologia de Box e Jenkins, e que esta última seria mais adequada para extrair informações sobre a série temporal, como a identificação de ciclos e tendências. Sousa e Sousa (2010) obtiveram um R<sup>2</sup> de 0,92, também na estimativa de vazão média mensal, ao aplicarem vetores de entrada compostos por combinações de 5 estações pluviométricas relacionadas com a área de estudo.

O uso de dados pregressos de uma variável parece melhorar o desempenho da RNA na modelagem de sistemas hidrológicos. Riad et al. (2004) obtiveram R<sup>2</sup> significativo de 0,917 ao comporem os vetores de entrada com as variáveis precipitação e escoamento superficial dos 7 dias precedentes ao dia  $t$ , a partir de séries históricas de 7 anos. Oliveira et al. (2013) avaliaram o uso da RNA para previsão de vazão diária em diferentes proporções e características de área controlada. Os autores utilizaram dados de vazão média diária de 25 postos fluviométricos, os quais foram combinados em 83 vetores de entrada da RNA. Avaliaram ainda o desempenho destes vetores incluindo-se o valor da vazão no tempo  $t-1$  ( $Q_{t-1}$ ). Os autores afirmam que a inclusão da  $Q_{t-1}$  elevou o coeficiente de Nash-Sutcliffe (NS) de 0,75 para 0,94. Oliveira et al. (2014) avaliaram o desempenho da simulação da vazão média mensal da bacia do rio Ijuí (5.414 km<sup>2</sup>) por RNA. Após definidas as variáveis essenciais, utilizaram a RNA para simular em outro período e a compararam com o modelo hidrológico SMAP. Utilizaram dados meteorológicos e pluviométricos de 1941 a 2005. A melhor combinação de vetores de entrada foi constituída de três variáveis (balanço médio de água nos tempos  $t$  e  $t-1$ ; média móvel dos valores passados; filtro do balanço de água) com NS de 0,904 e RMSE de 37,1 m<sup>3</sup>/s. Com a RNA treinada, esta foi aplicada para simulações no período de 2002 a 2009 e produziu um NS de 0,89, enquanto o SMAP alcançou 0,67.

Estes trabalhos mostram que as RNAs são eficazes para simular eventos hidrológicos, especialmente para a previsão de vazões. A composição do conjunto de vetores de entrada demonstra ser uma questão fundamental para que esta eficácia seja atingida, e também que seus componentes podem variar conforme o caso. Portanto, a inclusão de observações realizadas nas épocas antecedentes ao evento em análise mostra-se um recurso importante para o sucesso da simulação.

Se por um lado há uma variedade de estudos que procuram determinar a composição dos vetores de entrada, por outro se percebe uma carência nos mesmos quanto a determinar o efeito que cada vetor

produz na simulação. Esta análise possibilita identificar não apenas a melhor combinação, mas também qual vetor se mostra mais relevante no conjunto de entrada utilizado. As técnicas do diagrama de interpretação neural (GOZLAN et al., 1999), da análise de sensibilidade (OLDEN; JAKSON, 2002) e algoritmo de Garson (GARSON, 1991) são comumente empregadas com este propósito. Destas, o algoritmo de Garson tem se mostrado mais rápido e decisivo por ser estritamente quantitativo (PHUKOETPHIM et al., 2014; KALTEH, 2008).

Este trabalho tem por objetivo: (i) avaliar a eficácia de uma MLP, em *open-loop* e *closed-loop* na modelagem do processo chuva-vazão; (ii) avaliar a melhor composição de vetores de entrada (tratamento) e a influência dos vetores; (iii) avaliar a contribuição relativa dos vetores que compõem a camada de entrada dos melhores tratamentos.

## 1.2 MATERIAL E MÉTODOS

### 1.2.1 Área de estudo

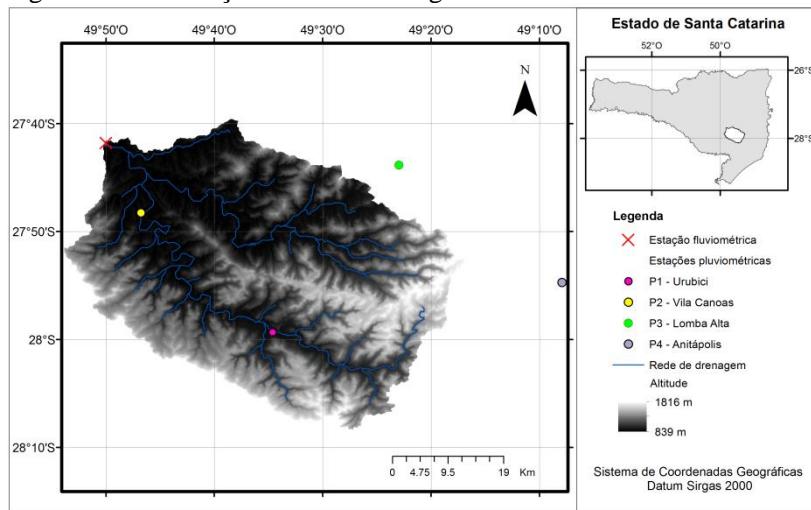
A bacia hidrográfica utilizada neste estudo é uma sub-bacia da bacia hidrográfica do Rio Canoas, denominada bacia do Alto Canoas (Figura 1), em cujo exutório se encontra a estação fluviométrica Rio Bonito, operada pela Agência Nacional de Águas (ANA).

A bacia do Alto Canoas apresenta uma área de cerca de 1980 km<sup>2</sup> cujo território abrange os municípios de Urubici, Bocaina do Sul, Rio Rufino e Bom Retiro. O relevo apresenta altitudes que variam de 839 a 1.816 m, caracterizado por uma área de platô, seguida por fortes depressões em direção ao vale, em que predominam Neossolos Litólicos e Cambisolos Húmicos. Como uso da cobertura da terra predominam campos de altitude, floresta primária do tipo Floresta Ombrófila Mista, reflorestamentos de *Pinus spp*, culturas agrícolas temporárias e áreas urbanas. As classes de floresta primária e campo somam cerca de 80% da área de estudo, situadas nas encostas e topes de morros, respectivamente. As áreas mais baixas da bacia são ocupadas pelas demais classes (ANTUNES, 2015).

Nesta bacia encontram-se as estações pluviométricas de Urubici (P1) e Vila Canoas (P2), cujas áreas de influências, calculadas pelo método dos polígonos de Thiessen, correspondem a 47% e 34% da área total da bacia, respectivamente. As estações Lomba Alta (P3), com 16%,

e Anitápolis (P4), com aproximadamente 3%, também foram consideradas (ANTUNES, 2015).

Figura 1 - Localização da Bacia hidrográfica do Alto Canoas.



Fonte: Adaptado de Valeriano (2008).

### 1.2.2 Variáveis das camadas de entrada e de saída

Os vetores de entrada foram constituídos das variáveis de Precipitação (P) e evapotranspiração de referência (ET<sub>0</sub>) diárias, no período de 01/01/1996 a 31/12/1999. Este período foi selecionado em virtude da disponibilidade ininterrupta dos dados diárias. A vazão média (Q) diária no exutório da bacia foi utilizada como vetor de saída do modelo.

Os dados diárias de precipitação e de vazão foram obtidos no portal Hidro Web da ANA. A ET<sub>0</sub> diária foi calculada pelo método de Penman-Monteith-Padrão (ALLEN et al., 1998), (Equação 1).

$$ET_0 = \frac{0,408s(Rn - G) + \frac{y900U_2(e_s - e_a)}{T + 273}}{s + y(1 + 0,34U_2)} \quad (1)$$

Onde, ET<sub>0</sub> = evapotranspiração de referência (mm.dia<sup>-1</sup>); S = declividade da curva de pressão de vapor na temperatura do ar (KPa °C<sup>-1</sup>).

<sup>1</sup>);  $R_n$  = radiação líquida total diária ( $MJ\ M^{-2}\ d^{-1}$ );  $G$  = fluxo de calor no solo ( $MJ\ M^{-2}\ d^{-1}$ );  $Y$  = constante psicrométrica ( $0,063\ KPa^{\circ}C^{-1}$ );  $U_2$  = velocidade do vento a 2 m de altura ( $m\ s^{-1}$ );  $E_s$  = pressão de saturação de vapor (KPa);  $E_a$  = pressão parcial de vapor (KPa); e  $T$  = temperatura média do ar ( $^{\circ}C$ ).

As séries diárias de temperatura, umidade relativa, radiação solar e velocidade do vento foram obtidas da Estação Climatológica de Lages, localizada a  $84^{\circ}NO$  e cerca de 75 km do ponto central da bacia, pertencente à EPAGRI/INMET e com altitude de 937m. Esta estação foi escolhida por ser a estação mais próxima da área de estudo, contar com uma série contínua de dados e ainda por situar-se próxima à latitude do ponto central da bacia e sua altitude encontrar-se dentro da faixa de altitudes da bacia do Alto Canoas.

### 1.2.3 Análise exploratória

A análise exploratória foi realizada com o objetivo de identificar os processos-chaves ligados às variáveis de entrada que influenciam as vazões no exutório da bacia estudada.

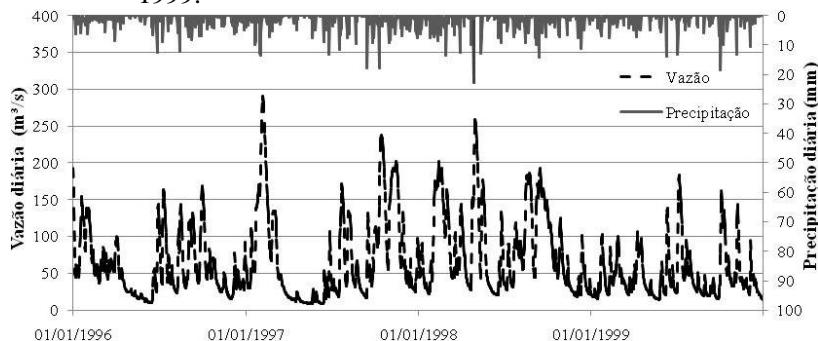
As variáveis utilizadas na composição dos vetores de entrada da MLP foram analisadas através do coeficiente de correlação linear de Pearson (R) e pelas Funções de Auto-Correlação (FAC) e Correlação Cruzada (CC).

A análise de FAC e de CC foram geradas no software MATLAB 2014a. Estas avaliaram a relação temporal entre uma ou mais variáveis, com deslocamento no tempo. Assim sendo, a FAC foi procedida sobre uma variável por vez e a CC envolveu duas variáveis, ambas dentro de um período de 10 dias, com intervalos de confiança de 95% em torno da média.

### 1.2.4 Estrutura da simulação da vazão em *open-loop* e *closed-loop*

O período do estudo foi dividido em três sub-períodos seguindo a ordem cronológica dos eventos, para constituir os sub-conjuntos amostrais de treinamento (50%), validação (25%) e teste (25%) (Figura 2). Na Figura 2, a precipitação indicada refere-se à precipitação média ponderada das estações, a partir dos valores diários medidos nas estações pluviométricas.

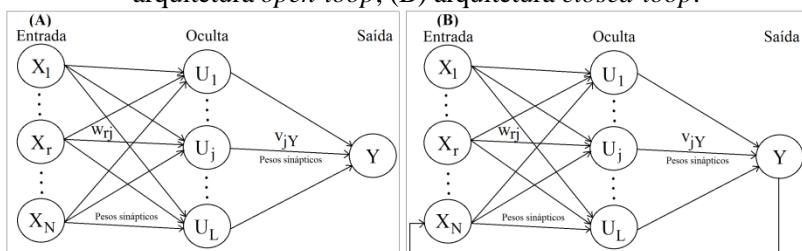
Figura 2 - Períodos dos sub-conjuntos de treinamento, validação e teste indicados no hidrograma e hietograma diários entre 1996 e 1999.



A arquitetura da RNA foi a MLP, aplicada no *software* MATLAB 2014a com o *Neural Network Toolbox*.

A MLP se constituiu de três camadas (Figura 3): (1) a camada de entrada, constituída pelas combinações de vetores ( $\mathbf{X}$ ), em que cada vetor corresponde a um neurônio da MLP; (2) a camada oculta, constituída por um número variável de neurônios ( $\mathbf{U}$ ), conforme o conjunto de vetores de entrada, sendo esta variação definida por testes de amplitude de neurônios; (3) a camada de saída, com um único neurônio ( $\mathbf{Y}$ ), correspondente ao vetor  $\mathbf{Q}$ .

Figura 3 - Arquitetura da *Multi Layer Perceptron* (MLP), (A) arquitetura *open-loop*; (B) arquitetura *closed-loop*.



A arquitetura *open-loop* foi aplicada na etapa de treinamento, na qual os vetores de entrada são constituídos por dados observados (Tabela 1).

Tabela 1 – Constituição dos vetores de entrada e saída das arquiteturas aplicadas nas etapas de modelagem.

Etapa	Percentual de dados (%)	Arquitetura	Variáveis de Entrada	Vetor de Saída
Treinamento	50	<i>Open-loop</i>	P, ETo, Qt-1Obs	QtSim
Validação	25	<i>Open-loop</i>	P, ETo, Qt-1Obs	QtSim
Teste	25	<i>Open-loop</i>	P, ETo, Qt-1Obs	QtSim
Teste	25	<i>Closed-loop</i>	P, ETo, Qt-1 Sim	QtSim

Onde: P: precipitação diária (mm), ETo: evapotranspiração diária (mm), Q<sub>Obs</sub>: vazão média diária observada (m<sup>3</sup>/s), Q<sub>t-1Sim</sub>: vazão média diária simulada (m<sup>3</sup>/s), t-1: tempo de atraso de 1 dia, considerando dia t da simulação.

O objetivo no treinamento foi determinar os valores dos pesos sinápticos através do algoritmo de aprendizado de *Levenberg-Marquardt*. Este algoritmo foi utilizado por ser rápido e apresentar convergência estável, resultante da integração dos algoritmos de *Error Back Propagation* e *Gauss-Newton* (HAGAN; MENHAJ, 1994).

A taxa de aprendizado utilizada foi de 0,01 e função de ativação tangente hiperbólica sigmoidal. Esta comprime os valores em um intervalo de -1 a 1.

Os vetores de entrada foram padronizados com distribuição Z (0; 1), a fim de melhorar a convergência (FU, 1994).

Uma relação inicial de 10 vezes mais equações de treinamento do que de pesos foi assumida com o objetivo de determinar o número de neurônios da camada oculta (HEATH, 2010). A partir deste valor, testou-se uma variação em torno de  $\pm 5$  neurônios na camada oculta, a fim de buscar a arquitetura que proporcionasse a melhor solução para o problema. Também foram testadas dez inicializações aleatórias dos pesos sinápticos.

Durante o processo de treinamento em *open-loop* foi realizado também o processo de validação cruzada, pelo qual se acompanhou a evolução do aprendizado sobre um conjunto de dados distinto, subconjunto de validação. A técnica de validação cruzada foi utilizada para identificar o momento de promover a interrupção do treinamento, baseado na curva do erro mínimo de validação.

### 1.2.5 Eficácia da MLP

A eficácia da MLP foi medida sobre os resíduos das vazões simuladas em relação às vazões observadas. Os parâmetros utilizados

para avaliar a MLP em *open-loop* e *closed-loop* foram o índice de Nash e Sutcliffe (1970) (NS) (Equação 2) e o Coeficiente de Determinação ( $R^2$ ) (Equação 3). Para a arquitetura *closed-loop* também foi calculado a Raiz do Erro Médio Quadrático (RMSE) (Equação 4).

Na etapa de treinamento avaliou-se o desempenho com base no sub-conjunto de validação cruzada e na etapa de teste avaliou-se o desempenho das previsões com o sub-conjunto de teste, para determinar a capacidade de generalização de uso com dados que não participaram de nenhuma etapa do treinamento e de definição da arquitetura.

$$NS = 1 - ((\sum_{i=1}^n (Q_{Obs_i} - Q_{Sim_i})^2 / (\sum_{i=1}^n (Q_{Obs_i} - Qméd_{Obs_i})^2)) \quad (2)$$

$$R^2 = \frac{[\sum(Q_{Obs_i} - Qméd_{Obs_i}) * (Q_{Sim_i} - Qméd_{Sim_i})]^2}{\sum(Q_{Obs_i} - Qméd_{Obs_i})^2 * \sum(Q_{Sim_i} - Qméd_{Sim_i})^2} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_{Sim_i} - Q_{Obs_i})^2} \quad (4)$$

Nas quais:  $Q_{Obs_i}$ : vazão média diária observada;  $Qméd_{Obs_i}$ : média das vazões médias diárias observadas no período;  $Q_{Sim_i}$ : vazão média diária simulada pelo modelo;  $Qméd_{Sim_i}$ : média das vazões diárias simuladas no período.

Na etapa de teste as vazões foram simuladas para todo o período pela arquitetura *open-loop* e também *closed-loop*, na qual os valores de  $Q_{t-1}$  são os valores que a própria MLP calculou, ou seja, os valores simulados. O processo começa na data inicial do período da simulação, adotando-se a primeira vazão pelo valor observado, e prossegue com as demais vazões pelos valores simulados. Deste modo, na medida em que se avança o passo de tempo de 1 dia, as vazões  $Q_{t-1}$  são simuladas em série encadeadas, de modo que a vazão para o dia da simulação  $Q_t$  depende da vazão simulada do dia anterior ( $Q_{t-1}$ ).

## 1.2.6 Contribuição relativa dos vetores de entrada na MLP

A Contribuição Relativa (CR) dos vetores de entrada (GARSON, 1991) e a análise de resíduos (XU, 2001; BIEGER et al.,

2012) foram realizadas sobre os tratamentos de entrada que apresentaram os melhores desempenhos no teste em *closed-loop*.

O cálculo do índice percentual CR de Garson consiste em ponderar as variações dos valores absolutos dos pesos entre os vetores da camada de entrada e da camada de saída (Equação 5), a fim de determinar a relevância relativa de cada vetor da camada de entrada.

$$CR_{ik} = \frac{\sum_{j=1}^L \left( \frac{w_{ij}}{\sum_{r=1}^N w_{rj}} v_{jk} \right)}{\sum_{i=1}^N \left( \sum_{j=1}^L \left( \frac{w_{ij}}{\sum_{r=1}^N w_{rj}} v_{jk} \right) \right)} \quad (5)$$

em que:  $CR_{ik}$  representa a influência do vetor de entrada  $i$  sobre o vetor de resposta  $k$ ;  $\sum_{r=1}^N w_{rj}$  é a soma dos pesos de conexão entre a camada de entrada  $i$  e o neurônio  $j$ ;  $N$  corresponde ao total de vetores de entrada;  $L$  corresponde ao total de vetores (neurônios) da camada oculta;  $v_{jk}$  peso da conexão entre neurônio da camada oculta  $j$  e o vetor da saída  $k$ .

A análise de resíduos consistiu na verificação da diferença da vazão observada pela simulada (resíduo) em níveis mínimos, médios e máximos, com objetivo de analisar em quais classes de vazão ocorreu subestimativa ou superestimativa pelo modelo. A delimitação dos níveis baseou-se na média dos valores observados, pelas seguintes regras: (1) mínima: vazões menores que 0,75\*(média observada); (2) média: vazões entre 0,75\*(média observada) e 1,25\*(média observada); e (3) máxima: vazões maiores que 1,25\*(média observada) (XU, 2001).

## 1.3 RESULTADOS E DISCUSSÃO

### 1.3.1 Análise exploratória

A matriz de correlação linear (Tabela 2) entre as séries apresenta correlações positivas significativas entre as séries das precipitações diárias registradas nas estações pluviométricas (0,54 a 0,8), o que serve de indicador do nível de variabilidade espacial das chuvas na área de estudo.

A ETo diária apresentou fraca correlação com as séries de precipitações registradas, o que parece indicar que não há relação entre o que choveu ou não com a ETo.

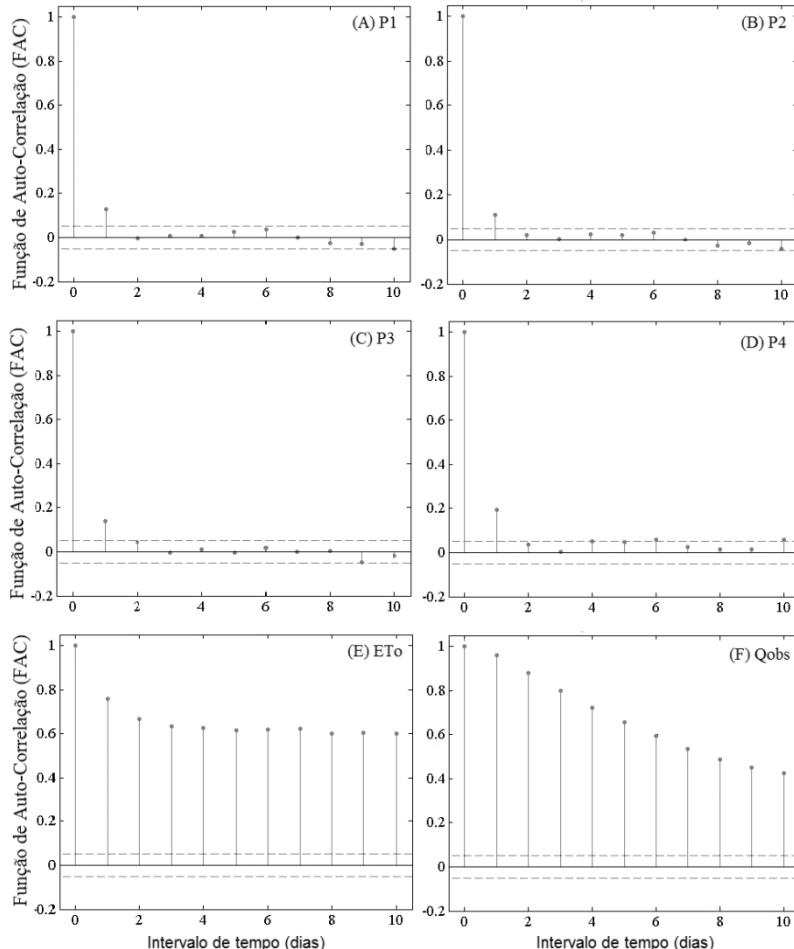
Tabela 2 – Matriz de correlação linear de Pearson (R) entre as variáveis utilizadas para compor os vetores de entrada da RNA.

Variáveis	P1	P2	P3	P4	ETo	Q
P1	1,00	0,79	0,80	0,60	-0,07	0,13
P2	0,79	1,00	0,73	0,54	-0,13	0,12
P3	0,80	0,73	1,00	0,61	-0,08	0,13
P4	0,60	0,54	0,61	1,00	0,03	0,13
ETo	-0,07	-0,13	-0,08	0,03	1,00	0,01
Q	0,13	0,12	0,13	0,13	0,01	1,00

A Figura 4 apresenta a FAC em um período de até 10 dias entre as variáveis utilizadas nos vetores de entrada da RNA.

As séries de precipitações diárias registradas nas quatro estações pluviométricas apresentaram fraca auto-correlação temporal (Figura 4: A a D), o que evidencia a variabilidade temporal das precipitações, entre dias consecutivos, num intervalo de até 10 dias.

Figura 4 - Função de auto-correlação (FAC) e intervalo de confiança de 95%: A) precipitação da estação Urubici (P1); B) precipitação da estação Vila Canoas (P2); C) precipitação da estação Lomba Alta (P3); D) precipitação da estação Anitápolis (P4); E) evapotranspiração de referência ( $ETo$ ), F) vazão observada ( $Q_{obs}$ ) na estação Rio Bonito.



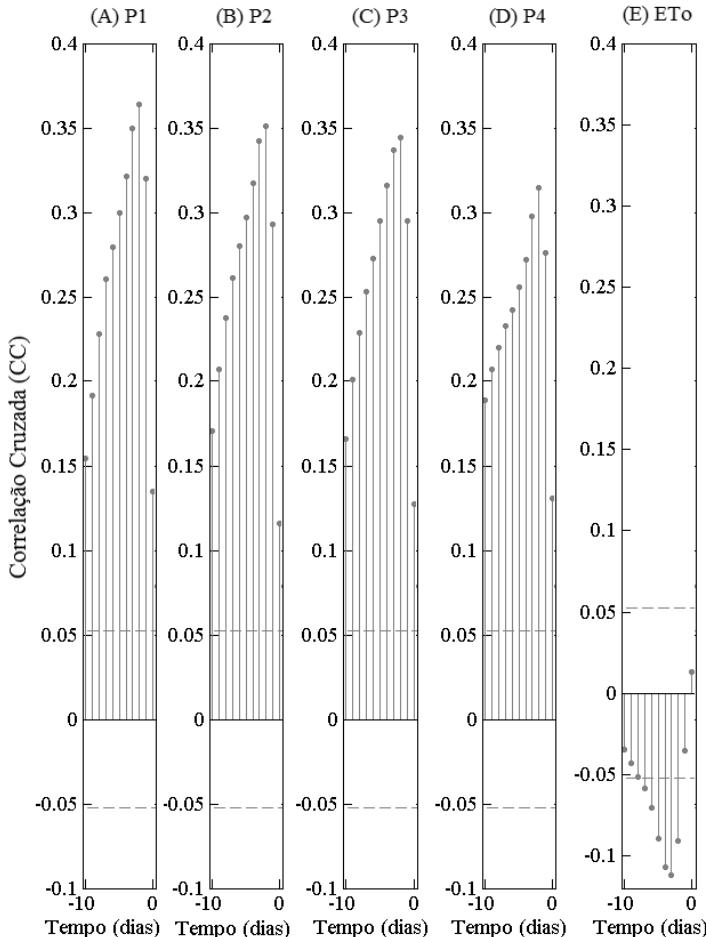
A FAC da  $ETo$  se apresentou significativa e forte em todo o período analisado de 10 dias (Figura 4E). As máximas auto-correlações ocorreram em até 2 dias, enquanto que no restante do período apresentou valores de FAC próximos de 0,6. Este comportamento

ocorre, provavelmente, devido às poucas variações nos parâmetros climáticos empregados no cálculo desta variável (temperatura do ar, umidade do ar, velocidade do vento e radiação solar) no período de até 10 dias.

A vazão observada apresentou FAC significativa em todo o período analisado (Figura 4F), sendo a máxima igual a 0,96, com uma diminuição de aproximadamente 0,05 por dia até a mínima em dez dias ( $FAC = 0,43$ ). Isto pode ser o fator que explica a melhora significativa do desempenho das RNAs quando introduz-se no vetor de entrada a  $Q_{t-1}$  observada.

A Figura 5 ilustra os coeficientes de CC entre as precipitações observadas e ETo calculada, com a vazão observada. O período analisado compreendeu defasagem de 10 dias.

Figura 5 - Correlação cruzada (CC) com intervalo de confiança de 95% entre a vazão e: A) precipitação da estação Urubici (P1); B) precipitação da estação Vila Canoas (P2); C) precipitação da estação Lomba Alta (P3); D) precipitação da estação Anitápolis (P4); E) evapotranspiração (ET<sub>0</sub>), F) vazão observada (Q<sub>obs</sub>) na estação Rio Bonito.



A precipitação passada ( $T < 0$ ) apresentou correlações significativas e moderadas, com máxima em -2 dias (Figura 5: A a D). O desfasamento de dois dias pode estar relacionado com o tempo de

concentração da bacia, cujo valor aproximado foi calculado por Moura (2014) de 3 dias.

As estações que apresentaram maiores correlações com a vazão foram as estações P1 e P2, situadas no interior da bacia, próximas ao canal principal. Além disso, é possível observar um sutil decréscimo da máxima correlação da estação P1 até P4 (0,37 a 0,32), o que pode estar relacionado com a distância de cada estação ao exutório ou, ainda, ao percentual da área de contribuição das estações, que também decresce no mesmo sentido.

Observou-se correlações não significativas, ou muito fracas, entre as variáveis média diária de ETo e vazão média diária (-0,1 até 0,5). Contudo, Sá (2014) e Antunes (2015) demonstram que a ETo desta estação foi útil na calibração dos modelos hidrológicos TOPMODEL e SWAT nesta bacia.

### **1.3.2 Constituição dos vetores de entrada da MLP**

O experimento foi realizado com 10 tratamentos distintos sobre a MLP, cuja constituição respectiva foi configurada por um número de vetores de entrada formado pelas variáveis de ETo, P e  $Q_{t-1}$  (Tabela 1).

A constituição dos tratamentos foi definida com base na análise exploratória. Os vetores de entrada foram os seguintes: 1) P1,  $Q_{t-1}$ ; 2) P1, P2,  $Q_{t-1}$ ; 3) P1, P2, P3,  $Q_{t-1}$ ; 4) P1, P2, P4,  $Q_{t-1}$ ; 5) P1, P2, P3, P4,  $Q_{t-1}$ ; 6) PP1, PP2, PP3, PP4,  $Q_{t-1}$ ; 7) P1, P2, P3, P4, ETo,  $Q_{t-1}$ ; 8) P1<sub>t-2</sub>, P2<sub>t-2</sub>, P3<sub>t-2</sub>, P4<sub>t-2</sub>,  $Q_{t-1}$ ; 9) P1<sub>t-2AC</sub>, P2<sub>t-2AC</sub>, P3<sub>t-2AC</sub>, P4<sub>t-2AC</sub>,  $Q_{t-1}$ ; 10) P1, P2, P3, P4, P1<sub>t-2</sub>, P2<sub>t-2</sub>, P3<sub>t-2</sub>, P4<sub>t-2</sub>,  $Q_{t-1}$ .

Sendo: ETo: Evapotranspiração de referência;  $Q_{t-1}$ : Vazão observada (treinamento) ou simulada (teste) para o dia anterior; PP: precipitação ponderada pela área da bacia; P<sub>t-2</sub>:precipitação com defasagem de 2 dias; P<sub>t-2AC</sub>: precipitação acumulada nos dois dias anteriores. As precipitações P1, P2, P3, P4 são as precipitações registradas nas respectivas estações. Para as precipitações e vazões com atraso de 1 ou 2 dias, buscou-se os dados correspondentes na série histórica antes de 01 de janeiro de 1996 (30 e 31/12/95).

### 1.3.3 Eficácia da MLP em open-loop e closed-loop

A eficácia da MLP foi testada sobre 10 tratamentos, variando-se a composição do conjunto de vetores de entrada (Tabela 3 e 4). Os vetores foram definidos a partir dos indicadores de correlações obtidos na análise exploratória e da área de influência das estações pluviométricas. As combinações dos vetores de entrada foram realizadas buscando determinar a influência que a adição ou subtração de algum vetor proporcionou para a modelagem.

Mais de 100 treinamentos em *open-loop* foram realizados para cada tratamento, variando-se os valores iniciais das matrizes de pesos sinápticos e número de neurônios da camada oculta, para se inferir a respeito dos desempenhos. A vazão com defasagem de -1 dia ( $Q_{t-1}$ ) esteve presente em todos os tratamentos, tendo-se em vista o resultado da análise exploratória. A simulação em *open-loop* (Tabela 3) e *closed-loop* (Tabela 4) foram realizadas, respectivamente, a cada tratamento, a fim de determinar a capacidade da MLP para previsão de longo-prazo.

Tabela 3 -Índices de eficácia da simulação da vazão média diária pela MLP em *open-loop* no período de treinamento e teste sobre os tratamentos combinatórios dos vetores de entrada.

N	Tratamento	Arquitetura MLP	Treinamento em <i>Open-loop</i>		Teste em <i>Open-loop</i>		
			NS	R <sup>2</sup>	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s) (%)
1	P1, Q <sub>t-1</sub>	2/18/1	0,964	0,924	0,912	0,871*	11,81 (6,9%)
2	P1, P2, Q <sub>t-1</sub>	3/14/1	0,966	0,928	0,913	0,872*	11,77 (6,9%)
3	P1, P2, P3, Q <sub>t-1</sub>	4/12/1	0,966	0,922	0,905	0,859*	12,50 (7,3%)
4	P1, P2, P4, Q <sub>t-1</sub>	4/12/1	0,966	0,925	0,910	0,867*	11,98 (7,1%)
5	P1, P2, P3, P4, Q <sub>t-1</sub>	5/10/1	0,965	0,927	0,907	0,866*	12,03 (7,1%)
6	P1, P2, P3, P4, ET <sub>0</sub> , Q <sub>t-1</sub>	6/9/1	0,967	0,929	0,907	0,853*	12,67 (7,4%)
7	PP1, PP2, PP3, PP4, Q <sub>t-1</sub>	5/10/1	0,965	0,927	0,907	0,864*	12,03 (7,1%)
8	P1 <sub>t-2</sub> , P2 <sub>t-2</sub> , P3 <sub>t-2</sub> , P4 <sub>t-2</sub> , Q <sub>t-1</sub>	5/10/1	0,969	0,924	0,915	0,851*	12,78 (7,5%)
9	P1 <sub>t-2AC</sub> , P2 <sub>t-2AC</sub> , P3 <sub>t-2AC</sub> , P4 <sub>t-2AC</sub> , Q <sub>t-1</sub>	5/10/1	0,974	0,922	0,894	0,823*	28,47 (61%)
10	P1, P2, P3, P4, P1 <sub>t-2</sub> , P2 <sub>t-2</sub> , P3 <sub>t-2</sub> , P4 <sub>t-2</sub> , Q <sub>t-1</sub>	9/6/1	0,971	0,937	0,921	0,878*	11,52 (6,8%)

\* p-valor < 0,05

A eficácia da MLP em *open-loop* no treinamento obteve NS e R<sup>2</sup> acima de 0,90, já para o período de teste o índice NS variou de 0,894 (tratamento 9) à 0,921 (tratamento 10).

A MLP se mostrou com pouca sensibilidade no desempenho entre os tratamentos, tanto para o período de treinamento, quanto para o período de teste em *open-loop*.

Tabela 4 - Índices de eficácia da simulação da vazão média diária pela MLP em *closed-loop* no período de teste sobre os tratamentos combinatórios dos vetores de entrada.

N	Tratamento	Arquitetura MLP	Treinamento em <i>Open-loop</i>		Teste em <i>Closed-loop</i>		
			NS	R <sup>2</sup>	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s) (%)
1	P1, Q <sub>t-1</sub>	2/18/1	0,964	0,924	0,515	0,515*	71,37 (42,2%)
2	P1, P2, Q <sub>t-1</sub>	3/14/1	0,966	0,928	0,223	0,350*	34,73 (20,5%)
3	P1, P2, P3, Q <sub>t-1</sub>	4/12/1	0,966	0,922	0,908	0,824*	23,05 (13,6%)
4	P1, P2, P4, Q <sub>t-1</sub>	4/12/1	0,966	0,925	0,862	0,840*	17,91 (10,5%)
5	P1, P2, P3, P4, Q <sub>t-1</sub>	5/10/1	0,965	0,927	0,810	0,848*	16,68 (9,9%)
6	P1, P2, P3, P4, ETo, Q <sub>t-1</sub>	6/9/1	0,967	0,929	-1,10	0,785*	166,99 (98%)
7	PP1, PP2, PP3, PP4, Q <sub>t-1</sub>	5/10/1	0,965	0,927	0,273	0,250*	84,68 (50,1%)
8	P1 <sub>t-2</sub> , P2 <sub>t-2</sub> , P3 <sub>t-2</sub> , P4 <sub>t-2</sub> , Q <sub>t-1</sub>	5/10/1	0,969	0,924	0,922	0,833*	15,65 (9,2%)
9	P1 <sub>t-2AC</sub> , P2 <sub>t-2AC</sub> , P3 <sub>t-2AC</sub> , P4 <sub>t-2AC</sub> , Q <sub>t-1</sub>	5/10/1	0,974	0,922	0,340	0,351*	28,24 (16,7%)
10	P1, P2, P3, P4, P1 <sub>t-2</sub> , P2 <sub>t-2</sub> , P3 <sub>t-2</sub> , P4 <sub>t-2</sub> , Q <sub>t-1</sub>	9/6/1	0,971	0,937	0,919	0,868*	14,29 (8,4%)

\* p-valor < 0,05

A eficácia da MLP em *closed-loop* apresentou uma diversidade de comportamentos, sendo todos significativos a 95% de confiança. Os melhores índices de eficácia em *closed-loop* foram observados nos tratamentos 10 (NS = 0,919, RMSE = 14,29 m<sup>3</sup>/s), 8 (NS = 0,922, RMSE = 15,65 m<sup>3</sup>/s) e 5 (NS = 0,81, RMSE = 16,68 m<sup>3</sup>/s), respectivamente.

Já era esperado um bom desempenho da MLP em *open-loop*, visto que a previsão realizada era de apenas 1 dia adiante (+1d), sendo que os tratamentos sempre utilizaram como entrada a vazão observada do dia anterior. Por outro lado, esperavam-se resultados inferiores em *closed-loop*, pois o modelo simulou toda a série de vazões utilizando como entrada, a cada passo de tempo, a vazão simulada no passo de tempo anterior (-1d).

Houve melhoria sensível de eficácia a partir de 3 vetores de precipitação, conforme se constata nos tratamentos de 3 a 5 (NS de 0,223 a 0,86; RMSE de 71,37 a 16,68 m<sup>3</sup>/s). Considerando-se a correlação similar entre os vetores de precipitação e o vetor de vazão ( $R$  próximo a 0,13) e a forte correlação entre si ( $R$  de 0,54 a 0,8), acredita-se que o ganho na eficácia tenha ocorrido devido à distribuição espacial relativamente equitativa das estações pluviométricas na região da bacia, estando localizadas cerca de 20 a 40 km uma da outra. Este fato provavelmente garantiu a cada estação uma porção de variabilidade intrínseca a sua localização espacial, que colaborou consideravelmente para a modelagem. Um exemplo disso é o vetor P4 que, apesar de apresentar a correlação mais fraca com as demais estações ( $R$  de 0,54), causou uma melhoria considerável de desempenho com sua adição nos tratamentos 2 para 4 e 3 para 5.

A tentativa de ponderar a precipitação pelas áreas de influências das estações pluviométricas (tratamento 7) não apresentou resultado satisfatório ( $NS = 0,273$ ,  $RMSE = 84,68$  m<sup>3</sup>/s), o que pode ser explicado pela correlação entre os vetores P e a distância espacial das estações pluviométricas. Portanto, não há justificativa para utilização das precipitações ponderadas, pois conforme observado nos tratamentos 1 a 5, a MLP foi eficaz com os dados das estações individualmente.

A utilização das precipitações de -2 dias no tratamento 8 ( $NS = 0,922$ ,  $RMSE = 15,65$  m<sup>3</sup>/s) apresentou resultados pouco superiores ao do tratamento 5, que não leva em consideração este tempo. Seria esperado que, devido à ocorrência da correlação máxima entre as variáveis de precipitação e vazão em -2 dias, houvesse uma diferença maior entre tratamentos.

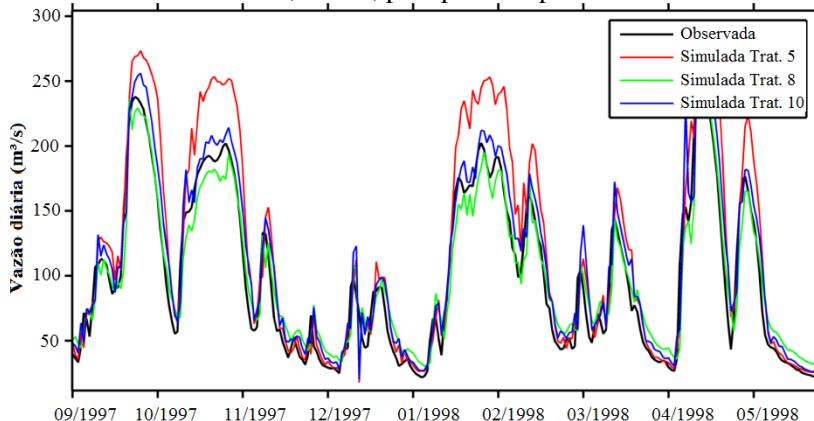
O acúmulo da precipitação a -2 dias, no tratamento 9, apresentou resultados insatisfatórios no período de teste ( $NS = 0,340$ ,  $RMSE = 28,24$  m<sup>3</sup>/s). A melhor eficácia foi encontrada no tratamento 10 ( $NS = 0,919$ ,  $RMSE = 14,29$  m<sup>3</sup>/s) ao associar os tratamentos 5 e 8.

A adição da variável ET<sub>0</sub> no tratamento 5, gerando o tratamento 6, acarretou em insuficiência completa a eficácia da MLP ( $RMSE =$

166,99 m<sup>3</sup>/s), o que pode ser explicado pela fraca correlação da ETo com a vazão (Figura 5E).

Apesar de apresentarem RMSE similar, os modelos dos tratamentos 5, 8 e 10 apresentam diferenças na modelagem das vazões mínimas e máximas (Figuras 6). Observou-se que o tratamento 5 obteve bom ajuste das vazões de base e superestimou as vazões máximas, enquanto que o tratamento 8 obteve melhor ajuste nas vazões máximas e superestimou as vazões mínimas. Conforme esperado, o tratamento 10 obteve um resultado intermediário entre 5 e 8, apresentando valores razoáveis tanto para vazões mínimas, quanto para vazões máximas.

Figura 6 - Hidrograma da vazão observada e simulada pela MLP nos tratamentos 5, 8 e 10, para parte do período analisado.



Resultado similar foi obtido por Sá (2014). O autor também observou que o modelo TOPMODEL superestimou as vazões básicas, apesar de ter alcançado NS = 0,84.

### 1.3.4 Contribuição relativa dos vetores de entrada

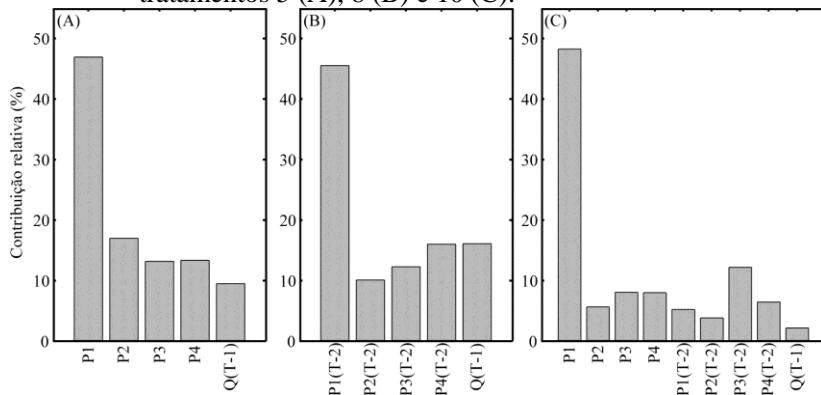
Os índices de Contribuição Relativa (CR) foram calculados para os tratamentos 5, 8 e 10 considerados os de melhor desempenho da MLP (Figura 7).

O vetor de precipitação da estação Urubici (P1) foi o que exerceu maior influência sobre a vazão simulada nos tratamentos, em torno de 45% de CR. O vetor da estação de Urubici (P1) correspondeu por cerca de 50% da eficácia da MLP. Quando analisado isoladamente,

no tratamento 1, percebe-se que a MLP atinge índices de 0,515 para o NS e RMSE de 71,37 m<sup>3</sup>/s. As demais estações parecem dividir entre si as contribuições relativas, cujo conjunto é necessário para que a MLP atinja alto índice de eficácia. Destas, as estações P3 e P4 parecem oferecer uma melhoria equivalente. A estação P2 demonstrou ser mais relevante em relação às demais (P3 e P4). Quando usado o vetor com dados do dia anterior (-1d), sua importância relativa diminuiu, possivelmente por esta estação localizar-se próxima ao exutório.

Esse resultado pode estar associado à localização da estação P1 próxima das vertentes íngremes da Serra Geral e que podem sofrer efeitos das chuvas orográficas. Apesar disso, esse resultado não está de pleno acordo com a análise exploratória, pois, apesar de P1 apresentar maior correlação com a vazão (CC = 0,37), as demais estações também apresentaram correlações similares. Com relação as demais estações, não houve concordância entre os três tratamentos sobre qual apresentou melhor relação com a vazão.

Figura 7 - Análise da contribuição relativa (CR) de cada variável para os tratamentos 5 (A), 8 (B) e 10 (C).



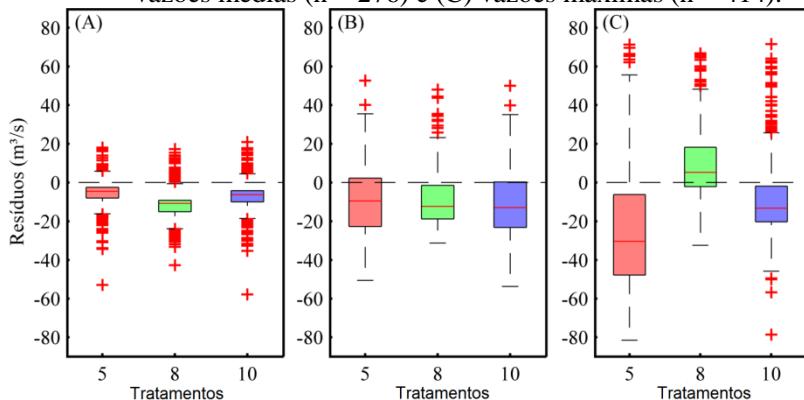
A vazão com defasagem - 1d ( $Q_{t-1}$ ) apresentou CR inferior ou similar às estações pluviométricas P2 à P4. Com isso, entende-se que essa variável não foi decisiva na estimativa da vazão. É possível que a vazão com defasagem - 1d ( $Q_{t-1}$ ) tenha servido de base para ajuste da magnitude dos valores, enquanto que as variáveis de precipitação foram responsáveis pelas variações diárias. Provavelmente, este seja o motivo da modelagem em *closed-loop* ter obtido êxito, por não depender fortemente das vazões estimadas anteriormente.

Estas constatações evidenciam a importância das estações situadas na cabeceira da bacia do Alto Canoas. As chuvas nesta região tendem a ter influência orográfica, devido à Serra Geral e relevo com vertentes íngremes. A estação P2 é a única que está fora deste contexto e próxima ao exutório.

### 1.3.5 Análise de resíduos

A análise de resíduos foi realizada sobre classes de vazões mínimas, médias e máximas. As classes de vazões médias e máximas apresentaram distribuição próximas da normal e com mediana negativa (indicador de superestimativa), com exceção do tratamento 8 que nas vazões máximas, apresentou mediana positiva (indicador de subestimativa). Já a classe de vazões mínimas apresentou distribuição diferente da normal, com valores negativos e próximos de zero. Em geral, o tratamento 10 apresentou valores negativos (indicando superestimativas), porém mais próximos de zero do que o restante dos tratamentos (Figura 8).

Figura 8 -Boxplots dos resíduos das (A) vazões mínimas ( $n = 770$ ), (B) vazões médias ( $n = 276$ ) e (C) vazões máximas ( $n = 414$ ).



Assim como verificado por Sá (2014), a superestimativa das vazões de recessão foi inevitável. Tanto o modelo TOPMODEL, utilizado pelo autor, como a MLP do presente trabalho, apontaram para a superestimativa da vazão de recessão

## 1.4 CONCLUSÃO

A RNA avaliada neste trabalho demonstrou alta capacidade em simular o processo chuva-vazão na bacia hidrográfica do Alto Canoas (NS máximo de 0,92), notadamente quando se inclui a vazão simulada do dia anterior (processo *closed-loop*).

A melhor estimativa da vazão foi obtida no tratamento 10, constituído pela utilização dos vetores P1, P2, P3, P4, P<sub>1T-2</sub>, P<sub>2T-2</sub>, P<sub>3T-2</sub>, P<sub>4T-2</sub> e Q<sub>t-1</sub> (NS = 0,919, RMSE = 14,29 m<sup>3</sup>/s). A combinação das variáveis de precipitação sem e com defasagem de -2 dias apresentou melhor desempenho que quando são utilizadas separadamente (tratamento 5 e 8). Este tratamento apresentou não só melhores índices estatísticos, mas também melhores estimativas das vazões mínimas e máximas.

A inclusão de todas as estações pluviométricas mostrou-se mais interessante do que sua utilização separada. Isto pode estar associado a sua boa distribuição espacial, capaz de captar a variabilidade de cada uma das estações, melhorando a modelagem pela MLP.

A precipitação ponderada não se mostrou eficaz, bem como a utilização da ETo, pois quando adicionadas na modelagem o desempenho da MLP foi inferior a sua não utilização.

O vetor que mais contribuiu para a eficácia da MLP foi a precipitação observada na estação de Urubici (P1). O vetor da vazão estimada (Q<sub>t-1</sub>) teve pouca contribuição relativa, mas manteve-se importante na arquitetura em *closed-loop*.

## 1.5 REFERÊNCIAS

ABRAHART, R.; KNEALE, P. E.; SEE, L. M. **Neural networks for hydrological modeling**. CRC Press. 2004, 316 pag.

ANTUNES, T. A. **Modelagem hidrológica da bacia hidrográfica do Alto Canoas através do modelo SWAT**. 2015. 130 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade do Estado de Santa Catarina, Lages, 2015.

BATISTA, A. L. F. Modelos de séries temporais e redes neurais artificiais na previsão de vazão. 2009. 79 f. **Dissertação** (Mestrado em Engenharia de Sistemas) – Universidade Federal de Lavras, Lavras, 2009.

BIEGER, K.; HORMANN, G.; FOHRER, N. Using residual analysis, auto-and cross-correlations to identify key processes for the calibration of the SWAT model in a data scarce region. **Advanced Geosciense**.n.31, p.23-30, 2012.

FU, L. **Neural networks in computer intelligence**. New York: McGraw-Hill, 1994.

GARSON, G .D. Interpreting neural-network connection weights. **Artificial Intelligence Expert**. v. 6, p. 47–51, 1991.

GOZLAN, R.E. et al. Predicting the structure and diversity of young-of-the-year fish assemblages in large rivers.**Freshwater Biology**.v. 41, p. 809–820, 1999.

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

HEATH, G. E. **Training, testing and validating data set in Neural Network**.2010. Disponível em:  
<[http://www.mathworks.com/matlabcentral/newsreader/view\\_thread/295781#917734](http://www.mathworks.com/matlabcentral/newsreader/view_thread/295781#917734)>. Acesso em: 04 de jul.2013.

KALTEH, A. M. Rainfall-runoff modelling using artificial neural networks (ANNs): modelling and understanding. **Caspian Journal of Environmental Sciences**, v.6, n.1, p. 53–58, 2008.

MOURA, C. V. **O monitoramento hidrológico na sala de situação da EPAGRI/CIRAM no estado de Santa Catarina**. 2014. 79 f. Relatório de estágio curricular (graduação em Engenharia Ambiental) - Universidade do Estado de Santa Catarina, Lages, 2014.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part 1– A discussion of principles. **Journal of Hydrology**, v.10, n.3, p.282-290, 1970.

OLDEN, J. D.; JACKSON, D. A. Illuminating the “black box”: a randomization approach for understanding variable contributions in

artificial neural networks. **Ecological Modelling**, v.154, p.135-150, 2002.

OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M. O desempenho das redes neurais artificiais (RNAs) para simulação hidrológica mensal. **Revista Brasileira de Recursos Hídricos**. v.19, n.2, p. 251-265, 2014.

OLIVEIRA, G. G. et al. Simulações hidrológicas com diferentes proporções de área controlada na bacia hidrográfica. **Revista Brasileira de Recursos Hídricos**. v.18, n.3, p.193-204, 2013.

PHUKOETPHIM, P.; SHAMSELDIN, A.; MELVILLE, B. Knowledge Extraction from Artificial Neural Networks for Rainfall-Runoff Model Combination Systems. **Journal of Hydrologic Engineering**. v.19, n.7, p. 1422–1429, 2014.

RIAD, S.; MANIA, J.; BOUCHAOU, L.; NAJJAR, Y. Rainfall-runoff model using na artificial neural network approach. **Mathematical and computer modelling**. n.40, p. 839-846, 2004.

SÁ, E. A. S. **Estudo do modelo TOPMODEL na bacia hidrográfica do Alto Canoas – SC**. 2014. 103 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade do Estado de Santa Catarina, Lages, 2014.

SANTOS, C. C.; PEREIRA FILHO, A. J. Modelagem hidrológica urbana por meio de redes neurais artificiais: uma aplicação para a bacia do Rio Tamanduateí em São Paulo, SP. **Revista Brasileira de Meteorologia**, v.18, n. 2, p. 149-159, 2003.

SOUSA, W. S.; SOUSA, F. A. S. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio Piancó. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v.14, n.2, p. 173-180, 2010.

VALERIANO, M. M. Topodata - banco de dados geomorfométricos locais do Brasil. 2008. Disponível em:  
<http://www.dpi.inpe.br/topodata/data/grd/>. Acesso em: 20 de nov. 2014.

XU, C. Y. Statistical analysis of parameters and residuals of a conceptual water balance model – methodology and case study. **Water resources management**.n.15, p.75-92, 2001.

## CAPÍTULO 2: DESEMPENHO DE ÁRVORES DE REGRESSÃO E REDE NEURAL ARTIFICIAL NA PREVISÃO DE VAZÕES MÉDIAS DIÁRIAS DO MÊS

### RESUMO

O objetivo deste capítulo é apresentar o estudo do desempenho de árvores de regressão (RT) para a simulação da vazão média diária do mês em relação ao desempenho de uma Rede Neural Artificial (RNA). A motivação para esta análise está na maior simplicidade das RTs e processamento mais rápido do que as RNAs. Pretende-se com isso, suprir parte da carência de trabalhos em Hidrologia utilizando esta ferramenta de modelagem. O estudo foi desenvolvido na bacia hidrográfica do Alto Canoas, com os mesmos dados de precipitação e vazão apresentados no Capítulo 1. O estudo ocorreu sobre um delineamento experimental composto por um período de treinamento, um de validação cruzada e dois períodos de testes, com proporções de 53%, 25,66% e 21,34% do período total de dados, respectivamente. A RNA utilizada foi a *Multi Layer Perceptron* implementada no *software* MATLAB, e as árvores de regressão foram: M5P e *REP Tree* (com e sem poda) e *Decision Stump*, disponíveis do *software* WEKA. Entre as árvores de regressão avaliadas, a M5P foi a que apresentou melhor desempenho. O processo de poda foi essencial na construção da árvore de decisão pelo algoritmo *Rep Tree*. No entanto, o algoritmo M5P se mostrou sensível à poda em quatro de oito tratamentos. A RNA conseguiu simular a vazão média mensal com menores resíduos comparados aos das árvores de decisão. Porém, a M5P apresentou índices estatísticos semelhantes aos da RNA no período de teste 2, sendo uma alternativa interessante ao uso de RNAs.

**Palavras-chave:** *multi layer perceptron*, árvore de regressão, M5P, *REP Tree*, *Decision Stump*, chuva-vazão.

### ABSTRACT

The aim of this chapter is to introduce the study of regression trees of performance (RT) for the simulation of the average daily flow of the month for the performance of an Artificial Neural Network (ANN). The motivation for this analysis is the simplicity of the RTs and faster processing than RNAs. It is intended with this, supply of the lack of jobs

in Hydrology using this modeling tool. The study was developed in the basin of Alto Canoas, with the same data of precipitation and presented in Chapter 1. The study was conducted on an experimental design consists of a training period, a cross-validation and two testing periods, with proportions 53%, 25.66% and 21.34% of the total amount of data, respectively. The RNA used was a Multi Layer Perceptron implemented in MATLAB, and regression trees were: M5P and REP Tree (with and without pruning) and Decision Stump available WEKA software. Among the evaluated regression trees, the M5P showed the best performance. The process of pruning is essential in the construction of the decision tree by Rep Tree algorithm. However, M5P algorithm was sensitive to pruning into four eight treatments. The RNA could simulate the average monthly flow with less waste compared to the decision trees. However, M5P presented statistical indices similar to the RNA in the test period 2 being an interesting alternative to using RNAs.

**Key-words:** multi layer perceptron, regression tree, M5P, REP Tree, Decision Stump, rainfall-runoff.

## 2.1 INTRODUÇÃO

Entre as várias abordagens dirigidas a dados, a Rede Neural Artificial (RNA) é o método mais conhecido e utilizado na hidrologia (SOLOMATINE; DULAL, 2003). As RNAs são inspiradas na estrutura e funcionamento do cérebro humano, não são lineares e o aprendizado consiste no ajuste dos pesos sinápticos para que a entrada de dados corresponda à saída esperada (HAYKIN, 2001).

Diversas pesquisas têm encontrado excelentes resultados ao utilizarem RNAs para a modelagem chuva-vazão, dentre os quais estão os relatados por Hsu et al. (1995), Santos e Pereira Filho (2003), Riad et al. (2004), Figueiredo et al. (2007), Batista (2009), Sousa e Sousa (2010), Castro (2011), Escarião et al. (2012), Oliveira et al. (2013) e Oliveira et al. (2014).

Uma das dificuldades na utilização de RNAs é interpretar como o algoritmo produziu determinado resultado, sendo por isso, denominadas de sistemas caixas-pretas. Existem outras abordagens dirigidas a dados como as árvores de regressão (BREIMAN et al., 1984). Com as árvores de regressão é possível atingir exatidão equivalente às RNAs e gerar resultados mais simples de interpretar. São aplicáveis a quaisquer tipos de dados, e serem capazes de organizar

grandes bancos de dados de maneira compacta e relativamente rápida (WITTEN et al., 2011). Uma modificação melhorada das árvores de regressão é o algoritmo da árvore modelo (M5P) (QUINLAN, 1992).

As árvores de regressão são praticamente desconhecidas na modelagem chuva-vazão, sendo encontrado apenas o estudo desenvolvido por Solomatine e Dulal (2003).

Tendo em vista a carência de estudos que envolvam o uso de árvores de regressão para simular o processo chuva-vazão de bacias hidrográficas, este estudo objetiva: (i) investigar o desempenho de modelos de árvores de regressão (M5P, *REP Tree*, *Decision Stump*); (ii) avaliar a contribuição da poda no desempenho dos algoritmos M5P e *REP Tree*; (iii) comparar o desempenho dos modelos de árvores de regressão com uma RNA para a simulação da vazão média diária do mês.

### **2.1.1 Árvores de regressão**

As *Regression Trees* (RT) são um tipo de árvore de decisão em que os nós das folhas foram concebidos como modelos de regressão, portanto podem ser previstos os valores numéricos contínuos. As árvores são construídas através da divisão da série de dados com base nos valores dos vetores preditivos. Uma vez que a árvore tenha sido construída, um modelo de regressão é calculado para cada nó. Em seguida, a árvore é podada a partir das folhas e o erro diminui em consequência. O erro para cada nó é estimado pela média da diferença absoluta entre o valor simulado e o valor observado da variável em cada instância do conjunto de treino que atinge o nó. O processo é repetido até que todas as instâncias são cobertas por uma ou mais regras e o erro seja mínimo (BREIMAN et al., 1984).

O algoritmo *REP Tree* pode ser utilizado como um classificador ou para resultado oriundo de regressão. O algoritmo constrói uma árvore de regressão usando ganho de informação e redução da variância por poda. Apresenta velocidade otimizada e classifica valores para atributos numéricos uma vez (WITTEN et al., 2011).

O algoritmo *Decision Stump* constrói uma árvore de regressão binária, com um ramo extra para valores em falta. Este algoritmo trabalha com valores de missão, estendendo um terceiro ramo do tronco ou tratamento “em falta” como um valor de atributo separado. Faz regressão baseado no erro médio quadrático, ou classificação com base na entropia (WITTEN et al., 2011).

O algoritmo conhecido como M5 ou M5P é utilizado para induzir uma árvore modelo. O critério de divisão para o algoritmo M5P é baseado em tratar o desvio padrão dos valores da classe que atingem um nó como uma medida do erro nesse nó. O cálculo da redução esperada para esse erro é como um resultado de teste de cada atributo desse nó. Depois de avaliar todos os grupos possíveis, o algoritmo escolhe aquele que minimiza o erro previsto (QUINLAN, 1992).

A principal vantagem da árvore modelo sobre a árvore de regressão é que as árvores modelos são muito menores do que as de regressão, a decisão é clara e as funções de regressão normalmente não envolvem muitas variáveis (QUINLAN, 1992).

## 2.2 MATERIAL E MÉTODOS

### 2.2.1 Área de estudo e série histórica

O estudo foi realizado na sub-bacia do Rio Canoas, denominada bacia do Alto Canoas (mais detalhes podem ser obtidos na seção 1.2.1).

Foram utilizadas séries históricas de precipitação média diária do mês e vazão média diária do mês. Os dados foram adquiridos no portal Hidro Web, sendo neste disponibilizados a altura total diária de precipitação e a média diária da vazão no exutório. As médias diárias do mês foram calculadas somando-se as observações diárias de cada mês e dividindo tais somas pelo número de dias do mês. Implica afirmar que o número de dias do mês atuou como fator de ponderação na construção de cada série. Evitou-se, desta forma, trabalhar com totais precipitados no mês em virtude do número de dias variar entre os meses.

As séries históricas obtidas no período foram divididas em quatro sub-conjuntos amostrais, sendo 01/1980 a 12/1984 (53%) para treinamento dos modelos, 01/1985 a 05/1987 (25,66%) para a validação cruzada do treinamento (Figura 9), como período de teste 1: 01/1988 a 12/1989 (Figura 10) e como período de teste 2: 01/1998 a 12/1999 (Figura 11). Estes períodos fazem parte de um delineamento experimental e foram escolhidos devido à disponibilidade e ausência de falhas, sendo que o teste 1 é composto pelos anos seguintes aos utilizados para o treinamento e validação, e o período de teste 2 abrange a série de 10 anos à frente.

Figura 9 - Períodos dos sub-conjuntos de treinamento (01/1980 a 12/1984) e validação cruzada (01/1985 a 05/1987), onde PP: precipitação média diária do mês ponderada pela contribuição relativa de cada estação pluviométrica na área da bacia.

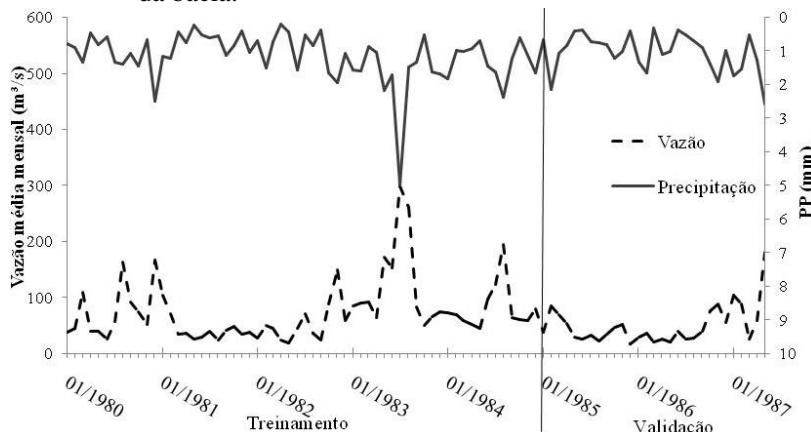


Figura 10 - Hidrograma da precipitação média diária do mês e vazão média do mês do sub-conjunto de teste 1 (06/1987 a 12/1989).

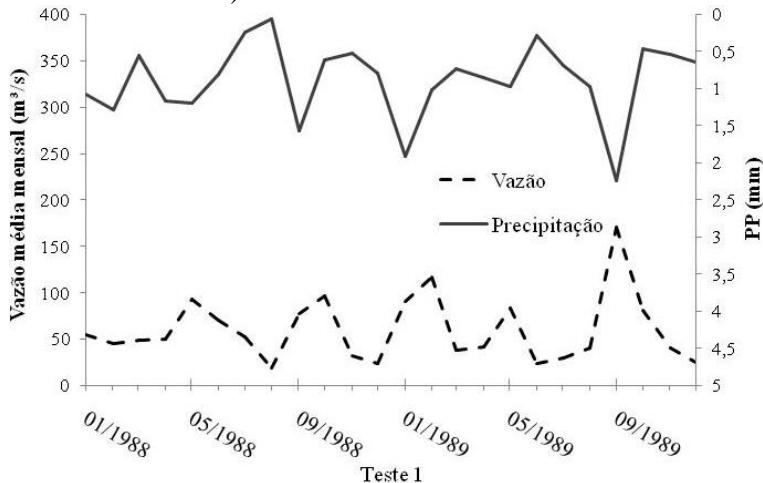
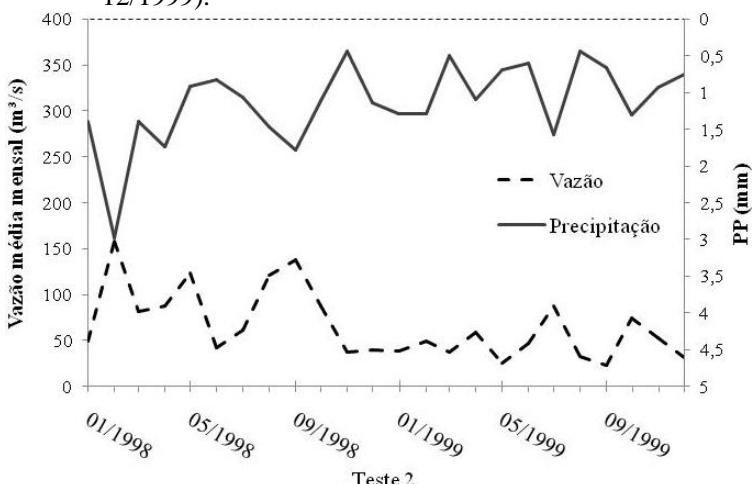


Figura 11 - Hidrograma da precipitação média diária do mês e vazão média do mês do sub-conjunto de teste 2 (01/1998 a 12/1999).



## 2.2.2 Análise exploratória

Uma análise exploratória das variáveis de entrada e de saída de água do sistema foi realizada com o objetivo de caracterizar o comportamento da série histórica.

A análise exploratória foi realizada sobre estatísticas descritivas dos dados, correlação linear de Pearson e correlação cruzada entre as variáveis de entrada (precipitação) e de saída (vazão).

## 2.2.3 Estrutura dos ensaios e simulação da vazão média do mês por RNA e RT

A simulação do processo chuva-vazão da bacia hidrográfica do Alto Canoas foi realizada por duas técnicas de inteligência artificial: RNA e RT.

A RNA utilizada foi a *Multi Layer Perceptron* (MLP) compilada no aplicativo MATLAB 2014a com o *Neural Network Toolbox*. O algoritmo de aprendizado escolhido foi o de retropropagação de *Levenberg-Marquardt* (HAGAN; MENHAJ, 1994). Os vetores de entrada foram padronizados conforme distribuição Z. O número de neurônios na camada oculta variou em  $\pm 5$  neurônios em torno de um

número satisfatório (HEATH, 2010). Foram configuradas dez inicializações aleatórias dos pesos sinápticos. A arquitetura da MLP foi constituída de três camadas, sendo apenas uma camada oculta (mais detalhes podem ser obtidos na seção 1.2.4).

Os vetores de entrada da MLP e das RTs foram constituídos de 4 tratamentos, sendo: 1) P1, P2; 2) P1, P2, P3, P4; 3) PP1, PP2, PP3, PP4; 4) P1, P2, P3, P4,  $Q_{t-1}$ . Onde, P1: precipitação na estação Urubici; P2: precipitação na estação Vila Canoas; P3: precipitação na estação Lomba Alta; P4: precipitação na estação Anitápolis; PP: precipitação média diária do mês ponderada pela contribuição relativa de cada estação pluviométrica na área da bacia;  $Q_{t-1}$ : vazão média do mês, observada no mês anterior (t-1).

A camada de saída foi constituída de um único neurônio correspondente à vazão média do mês.

Durante o processo de treinamento da RNA e como critério de parada, utilizou-se um conjunto de dados distinto para realizar a validação cruzada.

Para a simulação da vazão média do mês por árvores de regressão foram testados os três algoritmos implementados no aplicativo WEKA (*Waikato Environment for Knowledge Analysis*), sendo eles: M5P e *REP Tree*, com e sem poda, e *Decision Stump*.

O algoritmo *Decision Stump* implementado no aplicativo WEKA não tem opção de configurar à realização ou não da poda.

Breiman et al. (1984) definiu e usou a técnica de poda de árvore para impedir que estas sejam demasiadamente grandes, complexas e para evitar o problema conhecido como *overfitting*. Depois que a árvore é construída, alguns nós intermediários são transformados em nós terminais, ou folhas. Este processo aumenta o erro na fase de treinamento, porém o erro é reduzido no teste, desenvolvendo uma árvore melhor e mais interpretável.

As configurações do algoritmo *REP Tree* para treinamento e simulação da média diária no mês foram: não ter restrição quanto à profundidade máxima da árvore (`maxDepth = -1`); o peso mínimo total dos casos em uma folha (`minNum`) é igual a 2; proporção da variância mínima de 0,001 em todos os dados que tem que estar presentes em um nó a fim de obter separação (`minVarianceProp`); quando da realização da poda, foram determinadas 3 dobras para a realização da mesma e definido como sendo 1 a semente para gerar os dados aleatórios.-

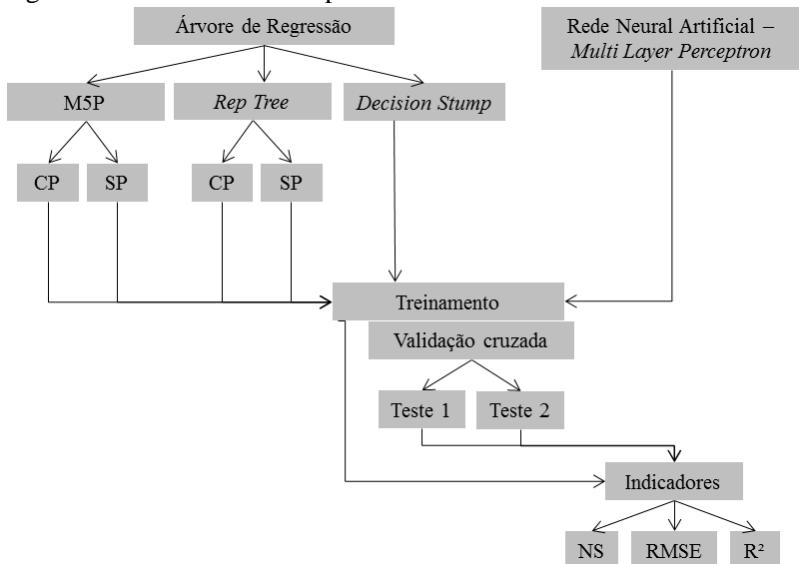
As árvores são geradas a partir de um conjunto de dados de treinamento sendo que, em cada nó, o algoritmo escolhe os atributos que

mais eficientemente subdividem o conjunto das amostras em subconjuntos homogêneos e caracterizados por sua classe. O critério é o ganho de informação obtido na escolha do atributo para subdivisão (QUINLAN, 1993).

O treinamento foi realizado em modo *Percentage Split* com os mesmos dados e proporções utilizadas na RNA, sendo, aproximadamente 53%, e de 25,66% para avaliação do treinamento. Após definidas as regras, foi aplicado o mesmo para a estimativa da vazão nos períodos de testes 1 e 2.

A Figura 12 apresenta o delineamento experimental realizado neste estudo.

Figura 12 - Delineamento experimental.



## 2.2.4 Avaliação dos métodos

As eficárias da RNA e das RTs foram medidas sobre os resíduos das vazões simuladas pelos modelos em relação às vazões observadas. Os parâmetros utilizados para a avaliação foram o índice de Nash e Sutcliffe (1970) (NS) (Equação 1), coeficiente de determinação ( $R^2$ ) (Equação 2) e Raiz do Erro Médio Quadrático (RMSE) (Equação 3), descritos na seção 1.2.5, e para os tratamentos com melhores resultados observou-se os resíduos pelo erro% (Equação 6).

$$Erro\% = \frac{(Q_{Sim} - Q_{Obs})}{Q_{Obs}} * 100(6)$$

Nas quais:  $Q_{Obs}$ : vazão média diária do mês observada;  $Q_{Sim}$ : vazão média diária do mês simulada pelo modelo.

## 2.3 RESULTADOS E DISCUSSÃO

### 2.3.1 Análise exploratória

A Tabela 5 apresenta as estatísticas descritivas das séries utilizadas como vetores de entrada da RNA e RT.

O período de treinamento registrou, em média, o maior volume de precipitação, sendo estes registrados pelas estações de Urubici (P1), Lomba Alta (P3) e Anitápolis (P4).

A estação pluviométrica Anitápolis (P4) registrou a maior média diária de precipitação no treinamento e teste 1, e maior volume médio diário por mês (13,87) no teste 2, comparado com as demais estações pluviométricas.

Tabela 5 - Estatísticas das precipitações médias diárias do mês e vazão média do mês nos sub-conjuntos de treinamento e testes.

	Parâmetros	P1 (mm)	P2 (mm)	P3 (mm)	P4 (mm)	Q (m³/s)
Treinamento 01/1980 a 12/1984	Média	4,79	4,37	4,71	5,91	75,28
	Mediana	4,26	4,13	4,23	5,67	59,04
	Máxima	19,44	19,40	22,19	21,10	297,95
	Mínima	0,55	0,91	1,08	0,94	19,36
	Curtose	7,97	12,50	13,71	7,85	4,96
	Assimetria	2,07	2,72	2,86	2,30	2,08
	CV%	63,71	64,76	68,51	61,15	74,13
Teste 1 01/1988 a 12/1989	Média	3,68	3,18	3,70	4,35	60,17
	Mediana	3,11	3,32	3,05	4,53	49,20
	Máxima	10,57	6,58	9,42	8,66	170,83
	Mínima	0,24	0,17	0,37	0,14	18,79
	Curtose	2,35	-0,49	0,74	-0,71	2,51
	Assimetria	1,49	0,09	1,01	0,17	1,41
	CV%	66,16	51,80	63,43	55,53	59,63
Teste 2 01/1998 a 12/1999	Média	4,31	4,90	4,49	4,87	66,32
	Mediana	3,85	4,70	4,18	4,59	51,45
	Máxima	12,12	12,27	10,70	13,87	158,59
	Mínima	1,21	1,20	1,79	1,61	23,63
	Curtose	4,58	3,44	1,32	4,51	0,34
	Assimetria	1,62	1,26	1,18	1,81	1,09
	CV%	53,65	47,04	50,29	55,33	56,54

Os coeficientes de variação ( $CV > 47\%$ ) implicam que há alta dispersão entre os valores de precipitação média diária do mês. Isto deve estar relacionado com o efeito sazonal, uma vez que os valores estão agrupados na escala mensal (vazão média diária do mês), sendo observados nas Figuras 9, 10 e 11. Os valores médios dos períodos de treinamento e teste 2 são maiores do que a mediana, o que indica a assimetria positiva dos dados (assimetria  $>1,09$ ). Resultados semelhantes foram encontrados por Gomes et al. (2011) para a precipitação na Paraíba. Os valores médios das precipitações no período de teste 1 para as estações Vila Canoas (P2) e Anitápolis (P4) são menores do que a média, sendo indicadores de baixa assimetria, 0,09 e 0,17 respectivamente.

O período de treinamento apresentou a maior média (75,28  $m^3/s$ ) e dispersão (CV% 74,13) da vazão média do mês, demonstrando que este período tem comportamento mais disperso, comparado aos períodos de testes, o que pode ser considerado bom para o treinamento dos modelos, pois inclui uma maior variabilidade de situações de entradas e saídas, incluindo até mesmo os extremos de 1983 e 1984, período de ocorrência do *El Niño*.

De acordo com as máximas e a média, o período de teste 2 é o que mais se assemelha com o período utilizado para treinamento. Porém, se levar em consideração a variabilidade, o período de teste 1 é o mais parecido com o período de treinamento.

Os coeficientes de correlações lineares de Pearson entre as séries são apresentados na Tabela 6.

Tabela 6 - Matriz de correlação linear de Pearson entre as séries de precipitações (P) e de vazões (Q) utilizadas para compor os sub-conjuntos de dados.

	P1	P2	P3	P4	Q
P1	1,00				
P2	0,87	1,00			
P3	0,91	0,86	1,00		
P4	0,80	0,68	0,76	1,00	
Q	0,78	0,72	0,75	0,59	1,00

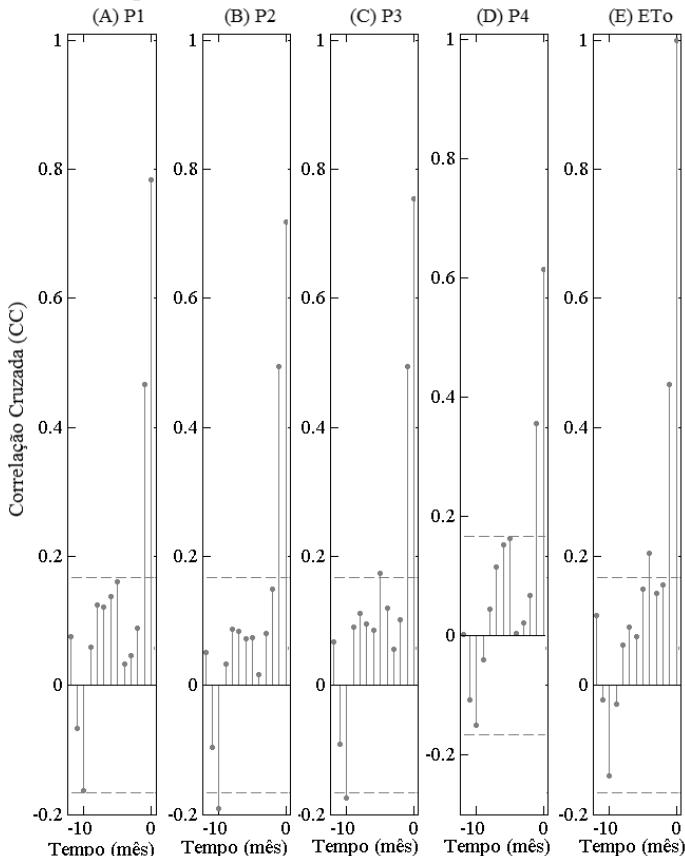
O grau de dependência estatística linear entre as séries históricas de precipitação e vazão são positivas. Para a precipitação, a

correlação varia de 0,68 a 0,91, indicando que a precipitação registrada em uma estação varia de moderada a forte com a estação vizinha, de acordo com a classificação de Dancey e Reidy (2006). Este comportamento se justifica por se tratar da precipitação média diária do mês e esta variar pouco entre estações próximas.

As correlações lineares entre as precipitações e as vazões variaram de 0,59 a 0,78. A maior correlação ocorreu com a estação P1 que está localizada próxima ao exutório da bacia, e a menor correlação ocorreu com a estação mais distante do exutório (P4) e que possui menor área de influência na bacia.

A Figura 13 apresenta os coeficientes de correlações cruzadas entre as precipitações com as vazões observadas, em um período de defasagem de 12 meses.

Figura 13 - Correlação cruzada com intervalo de 95% de confiança entre vazão e: A) P1 - precipitação na estação Urubici; B) P2 - precipitação na estação Vila Canoas; C) P3 - precipitação na estação Lomba Alta; D) P4 - precipitação na estação Anitápolis; E) Q - vazão observada na estação Rio Bonito.



A precipitação passada ( $t < 0$ ) com defasagem de 1 mês apresentou correlação significativa moderada (0,37 a 0,53), indicando que a precipitação do mês anterior exerce alguma influência sobre a vazão do mês atual. Este comportamento se justifica pela precipitação não apresentar alta variação média diária de um mês para outro, seguindo uma sazonalidade durante o ano. O mesmo comportamento é observado pela vazão.

### 2.3.2 Desempenho das árvores de regressão (RT)

#### 2.3.2.1 Desempenho do algoritmo M5P

Os indicadores de desempenho do algoritmo M5P estão apresentados na Tabela 7.

Para a fase de treinamento o NS variou de 0,573 com RMSE de 31,173 m<sup>3</sup>/s (tratamento 1 - CP) a NS = 0,708 com RMSE de 31,549 m<sup>3</sup>/s (tratamento 2 - SP). Na fase de treinamento, apenas o tratamento 3 apresentou melhor desempenho com a realização da poda.

A M5P apresentou melhores desempenhos ao realizar a poda, nos tratamentos 1 e 4 dos períodos testes 1 e 2, possivelmente devido a P1 e P2 presentes nestes tratamentos.

A M5P no período de teste 2 apresentou desempenho superior ao se comparar com o período de teste 1.

A adição da Q<sub>t-1</sub> do tratamento 2 para o 4, proporcionou aumento do NS e R<sup>2</sup>, justificada pela influência e correlação que a vazão média diária do mês anterior possui com a vazão média diária do mês subsequente.

Resultados menos significativos foram encontrados por Zia et al. (2015) ao utilizar uma árvore modelo para prever a vazão na bacia hidrográfica Dripsey, no sul da Irlanda. Os autores obtiveram R<sup>2</sup> de 0,09 e RMSE de 3,05 m<sup>3</sup>/s ao utilizar a precipitação diária como entrada. Ao utilizarem a precipitação dos últimos cinco dias alcançaram R<sup>2</sup> de 0,58 e RMSE de 2,17 m<sup>3</sup>/s.

Tabela 7 - Desempenho do algoritmo M5P sem poda (SP) e com poda (CP) para a simulação da vazão nos períodos de treinamento e testes nos diferentes tratamentos de entrada do modelo.

Tratamentos	Treinamento Avaliação com validação cruzada			Teste 1			Teste 2			
	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	
1) P1, P2	SP	0,621	31,627	0,715	0,476	27,663	0,361	0,605	23,704	0,583
	CP	0,678	37,173	0,573	0,479	27,222	0,378	0,683	20,898	0,676
2) P1, P2, P3, P4	SP	0,617	31,549	0,708	0,449	27,860	0,359	0,595	23,787	0,580
	CP	0,634	36,289	0,593	0,454	28,417	0,327	0,561	25,547	0,516
3) PP1, PP2, PP3, PP4	SP	0,612	36,455	0,590	0,449	27,863	0,359	0,595	23,795	0,580
	CP	0,634	36,288	0,593	0,409	28,589	0,320	0,548	25,821	0,505
4) P1, P2, P3, P4, Q <sub>t-1</sub>	SP	0,628	31,247	0,667	0,603	23,087	0,568	0,645	22,007	0,641
	CP	0,653	35,598	0,609	0,611	22,735	0,581	0,697	20,288	0,641

### 2.3.2.2 Desempenho do algoritmo *REP Tree*

Os indicadores de desempenho do algoritmo *REP Tree* estão apresentados na Tabela 8.

Na maioria dos tratamentos, o período de teste 2 apresentou R<sup>2</sup> e NS superiores ao período de teste 1. Na fase de treinamento, o NS variou de 0,037 com RMSE de 57,932 m<sup>3</sup>/s (tratamento 3 - CP) a NS = 0,484 e RMSE 40,867 m<sup>3</sup>/s (tratamento 4 - CP). Para o período de teste, o indicador NS variou de -0,067 (tratamento 1 – CP, teste 1) a 0,374 (tratamento 3 - CP, teste 2).

Nos tratamentos 1, 2 e 3 houve total falha em simular a vazão média diária do mês, ao não se realizar a poda, conforme aponta o indicador R<sup>2</sup>. Quando realizada a poda (CP), o algoritmo apresentou indicadores de desempenho melhores.

Também considerando-se o R<sup>2</sup>, a poda melhorou o desempenho para os quatro tratamentos no período de teste 1 e 2, indicando que, para a simulação da vazão média mensal (vazão média diária do mês) com o algoritmo *REP Tree* é imperativo realizar a poda.

Tabela 8 - Desempenho do algoritmo *REP Tree* sem poda (SP) e com poda (CP) para a simulação da vazão para os períodos de treinamento e testes nos diferentes tratamentos de entrada do modelo.

Tratamentos	Treinamento Avaliação com validação cruzada			Teste 1			Teste 2			
	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	
	SP	0,328	42,290	0,445	0	30,161	-0,037	0	36,712	0
1) P1, P2	CP	0,448	45,585	0,358	0,434	35,601	-0,067	0,397	33,150	0,184
	SP	0,315	44,020	0,275	0	35,786	-0,037	0	36,712	0
2) P1, P2, P3, P4	CP	0,400	46,176	0,341	0,432	34,464	0,000	0,499	29,031	0,374
	SP	0	57,932	-0,037	0	35,786	-0,037	0	36,712	0
3) PP1, PP2, PP3,PP4	CP	0,400	46,176	0,341	0,432	34,464	0,001	0,499	29,031	0,374
	SP	0,426	39,471	0,388	0,325	29,560	0,292	0,303	36,116	0,032
4) P1, P2, P3, P4, Q <sub>t-1</sub>	CP	0,531	40,867	0,484	0,485	28,838	0,326	0,514	34,945	0,094

### 2.3.2.3 Desempenho do algoritmo *Decision Stump*

O algoritmo *Decision Stump* realiza a regressão com base no erro médio quadrático. Os indicadores de seu desempenho estão expostos na Tabela 9.

Para o período de treinamento do algoritmo *Decision Stump*, o NS variou de -0,054 com RMSE de 39,471 m<sup>3</sup>/s (tratamento 4) a NS = 0,311 com RMSE de 47,224 m<sup>3</sup>/s (tratamento 3) e para o período de teste, o indicador NS variou de 0,274 (teste 1) a 0,389 (teste 2).

O comportamento do algoritmo *Decision Stump* foi distinto dos algoritmos M5P e *REP Tree*, sendo que a simulação da vazão foi semelhante entre os tratamentos 1, 2, 3 e 4, demonstrados pelos indicadores estatísticos. Entre os períodos, o período de teste 2 apresentou resultados melhores, da mesma forma que o encontrado pelo algoritmo M5P e *REP Tree*. Esse fato pode estar relacionado com o fato de o período de teste 2 ser, em média, mais semelhante com o período de treinamento.

Tabela 9 - Desempenho do algoritmo *Decision Stump* para a simulação da vazão para os períodos de treinamento e testes nos diferentes tratamentos de entrada do modelo.

Tratamentos	Treinamento Avaliação com validação cruzada			Teste 1			Teste 2		
	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS
1) P1, P2	0,328	42,290	0,136	0,328	29,561	0,274	0,456	28,704	0,389
2) P1, P2, P3, P4	0,315	44,020	-0,053	0,328	29,561	0,274	0,456	28,704	0,389
3) PP1, PP2, PP3, PP4	0,292	47,224	0,311	0,328	29,591	0,274	0,455	28,704	0,389
4) P1, P2, P3, P4, Q <sub>t-1</sub>	0,426	39,471	-0,054	0,325	29,919	0,274	0,456	28,703	0,389

### 2.3.3 Desempenho da Rede Neural Artificial

O desempenho da RNA para a simulação da vazão média diária do mês, na fase de treinamento, está apresentado na Tabela 10 e para os períodos de testes na Tabela 11.

Para cada um dos tratamentos foram realizados aproximadamente 100 treinamentos, modificando-se os valores iniciais dos pesos sinápticos e o número de neurônios da camada oculta.

Tabela 10 - Desempenho da RNA - MLP na fase de treinamento e arquitetura para os diferentes tratamentos de entrada do modelo.

Tratamentos	Treinamento Avaliação com validação cruzada			Número de Neurônios: Entrada/Oculta/ Saída
	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	
1) P1 e P2	0,689	30,847	0,771	2/5/1
2) P1, P2, P3, P4	0,702	30,252	0,757	4/5/1
3) PP1, PP2, PP3, PP4	0,697	30,472	0,760	4/4/1
4) P1, P2, P3, P4, Q <sub>t-1</sub>	0,860	21,046	0,973	5/3/1

O desempenho da RNA na fase de treinamento teve NS variando de 0,760 com RMSE de 30,472 m<sup>3</sup>/s (tratamento 3) a NS = 0,973 com RMSE de 21,046 m<sup>3</sup>/s (tratamento 4). O número de neurônios na camada intermediária que produziu os melhores resultados variou de 3 a 5.

Tabela 11 - Desempenho da RNA - MLP para a simulação da vazão para os períodos de teste 1 e 2 para os diferentes tratamentos.

Tratamentos	Teste 1			Teste 2		
	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	NS
P1 e P2	0,508	25,941	0,888	0,582	25,008	0,699
P1, P2, P3, P4	0,474	27,186	0,864	0,625	24,273	0,622
PP1, PP2, PP3, PP4	0,487	29,491	0,776	0,621	24,481	0,611
P1, P2, P3, P4, Q <sub>t-1</sub>	0,578*	23,205	0,872	0,684*	22,684	0,752

Ocorre uma divergência ao se considerar os índices de desempenho no período de teste. Considerando o R<sup>2</sup> dos tratamentos na fase de teste 1 e de teste 2, o desempenho, para todos os tratamentos, foi superior no período de teste 2. Porém, se levar em consideração o valor do NS, o período de teste 1 foi superior.

### 2.3.4 Análise conjunta dos desempenhos dos algoritmos de RT

Na Tabela 12, pode ser observado o desempenho dos algoritmos de RT e RNA para cada um dos conjuntos de dados, nos períodos de teste 1 e de teste 2.

Tabela 12 - Desempenho dos algoritmos de RT e RNA para a simulação da vazão para os períodos de teste 1 e de teste 2 nos diferentes tratamentos.

Tratamentos	RNA - MLP		M5P		REP Tree		Decision Stump	
	Teste 1	Teste 2	Teste 1	Teste 2	Teste 1	Teste 2	Teste 1	Teste 2
	NS	NS	NS	NS	NS	NS	NS	NS
1) P1, P2	0,888	0,699	0,378*	0,676*	-	0,184*	0,274	0,389
2) P1, P2, P3, P4	0,864	0,622	0,359	0,580	-0,037	0,374*	0,274	0,389
3) PP1, PP2, PP3, PP4	0,776	0,611	0,359	0,580	-0,037	0,374*	0,274	0,389
4) P1, P2, P3, P4, Q <sub>t-1</sub>	0,872	0,752	0,581*	0,641	0,326*	0,094*	0,274	0,389

\* Com poda.

O M5P se destacou em todos os tratamentos, seguido do *Decision Stump* e *REP Tree*.

O desempenho do algoritmo *REP Tree* foi melhor quando realizada a poda, para todos os tratamentos no período de teste 2 e para os tratamentos 1 e 4 no período de teste 1. Portanto, recomenda-se utilizar este algoritmo, quando presente.

O algoritmo M5P mostrou-se mais sensível à poda no tratamento 1 do período de teste 1 e tratamento 4 do 2º período de teste. O algoritmo *REP Tree* se mostrou mais sensível a poda quando comparado a M5P. Esta sensibilidade deve estar associada à forma de construção das árvores pelos algoritmos, já que os dados apresentados em cada etapa da modelagem foram os mesmos.

Para os algoritmos MLP e M5P, verifica-se que, para o tratamento 1 (que inclui apenas as estações que estão no interior da área de estudo e com maior área de contribuição definida pelos polígonos de Thiessen (P1 e P2)) o desempenho é ligeiramente superior ao tratamento 2 em que foram incluídas as estações P3 e P4, localizadas no entorno da bacia. Isto pode estar relacionado com fato dos modelos redistribuírem a contribuição de cada vetor para a modelagem, dando menor importância aos vetores que apresentam maior representatividade sobre a precipitação que ocorre na bacia do Alto Canoas.

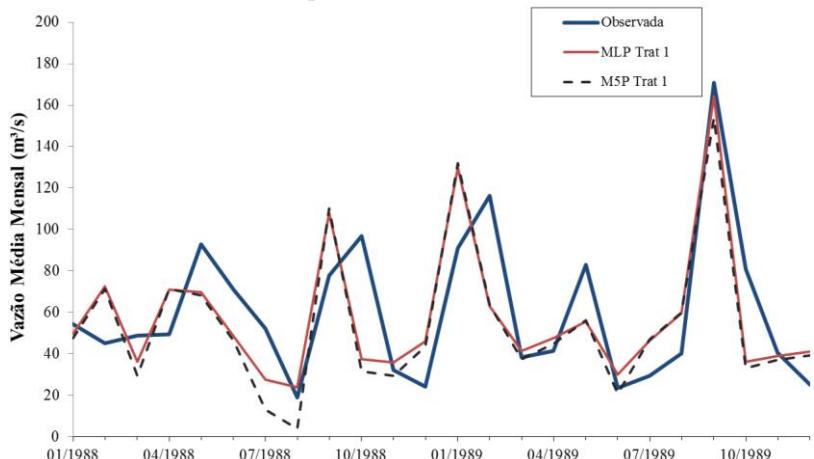
O desempenho em utilizar apenas dados de precipitação é menor ao desempenho obtido por Sousa e Sousa (2010). Os autores utilizaram uma RNA com a mesma arquitetura para prever vazões médias mensais da bacia hidrográfica do Rio Piancó, tendo como entrada a combinação e uso de cinco estações pluviométricas, sendo que a melhor arquitetura alcançou  $R^2$  de 0,92 e NS de 0,77.

A utilização da precipitação ponderada (tratamento 3) apresentou NS semelhante, ou até mesmo igual, comparada à utilização da precipitação pontual (tratamento 2), em todos os algoritmos nos períodos de teste 1 e 2. Isto demonstra a capacidade das técnicas de inteligência artificial em ponderar os vetores de entrada.

A adição da vazão média diária do mês anterior como entrada (tratamento 4) produziu um pequeno acréscimo no desempenho dos algoritmos MLP, M5P e *REP Tree*, com exceção do tratamento 3 (teste 2), comparando-se à não utilização (tratamento 2). Este comportamento pode estar associado à sazonalidade das vazões, no caso a  $Q_{t-1}$ , que é dependente da sazonalidade das precipitações na região. Também pode estar relacionada a alta correlação que a vazão atual tem com a do tempo anterior ( $t-1$ ). Segundo Braga et al. (1989) a inclusão da vazão antecedente tende a melhorar os resultados por causa da memória do processo hidrológico que dela resulta.

Na Figura 12, é possível observar o comportamento da vazão média diária do mês, simulada pela MLP e M5P, em relação à vazão observada para o tratamento 1, considerando que este foi o melhor desempenho para o período de teste 1, em que se utiliza apenas P1 e P2.

Figura 14 - Hidrograma observado e simulado pela MLP e M5P no tratamento 1 e período de teste 1.

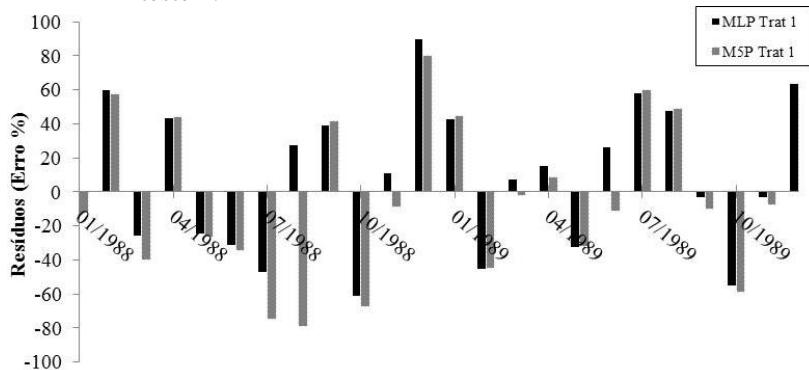


Observa-se que a MLP e a M5P apresentaram valores simulados próximos entre si e do valor observado, sendo que, para algumas datas, os modelos subestimaram a vazão e também houve superestimativa. Um modelo não apresentou um único comportamento.

A RNA é o modelo que melhor simulou a vazão alcançando no teste 1, NS de 0,888 e RMSE de 25,941 m<sup>3</sup>/s e a M5P obteve NS de 0,378 e RMSE de 27,222 m<sup>3</sup>/s, tendo como entrada a precipitação das estações localizadas dentro da área de estudo (P1, P2).

O comportamento dos resíduos calculado pelo erro% está representado na Figura 15.

Figura 15 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 1 e período de teste 1.

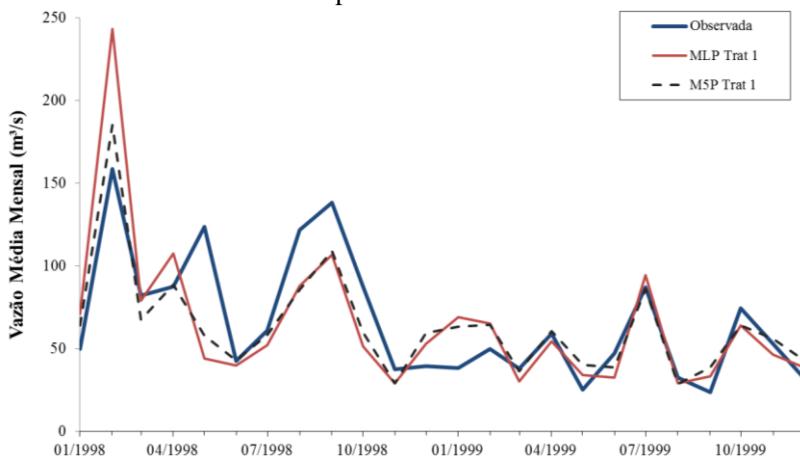


Observa-se que, em algumas datas, o comportamento dos resíduos foi inverso, para os algoritmos MLP e M5P, quando um modelo tendeu a superestimar, outro tendeu a subestimar os valores.

Em média, os resíduos da MLP (8,02) são maiores que os do M5P (-2,99) para o período de teste 1, porém o coeficiente de variação é menor para a MLP (5,31%) comparado aos da M5P (-15,81%).

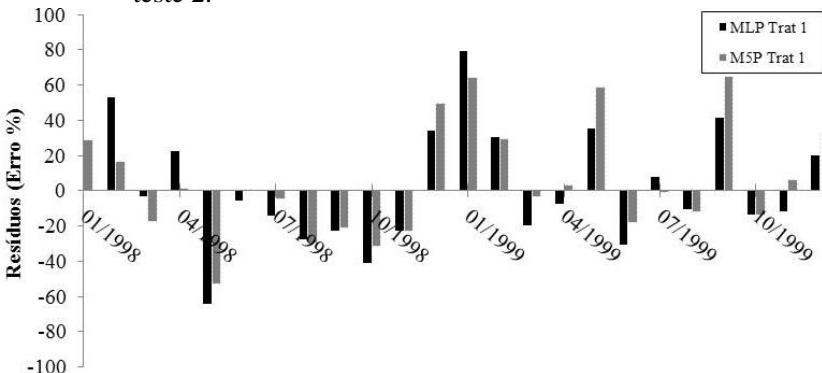
Na Figura 16, é possível notar o comportamento da vazão observada e simulada pela MLP e pela M5P tendo como entrada os vetores do tratamento 1 para o período de teste 2.

Figura 16 - Hidrograma observado e simulado pela MLP e pela M5P no tratamento 1 e no período de teste 2.



Os algoritmos MLP e M5P apresentaram comportamentos médios semelhantes ao do período de teste 1. De acordo com o NS de 0,699 e RMSE de 25,008 m<sup>3</sup>/s para a RNA e NS = 0,676 e RMSE de 20,898 m<sup>3</sup>/s para a M5P os desempenhos foram superiores ao encontrado para o período de teste 2. O comportamento dos resíduos pode ser observado na Figura 17.

Figura 17 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 1 e período de teste 2.

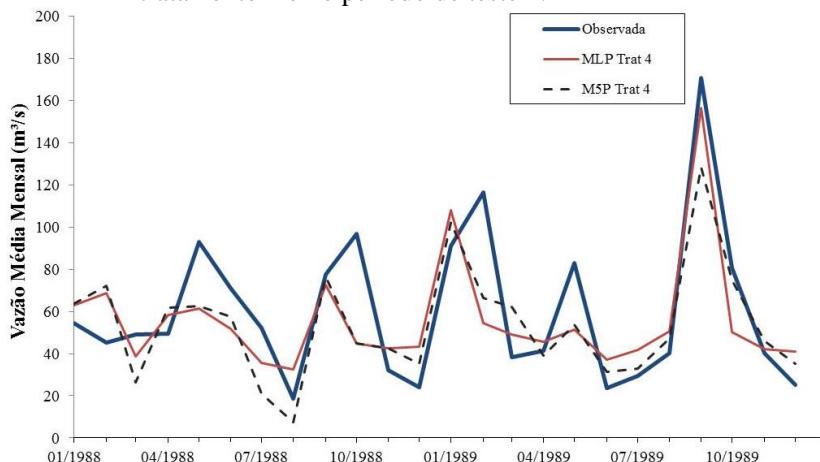


Em média, os resíduos da RNA (2,92) são menores que os do M5P (5,28) para o período de teste 2, porém apresentam maior variabilidade (CV% = 11,67) comparado aos da M5P (6,05%).

Os comportamentos da RNA e da M5P para o período de teste 2 foram distintos durante o período de teste, ora subestimando, ora superestimando as vazões médias mensais. As vazões no período de teste 2 são mais homogêneas que o período de teste 1, conforme visto na Tabela 1. A MLP e a M5P foram treinadas em um período de vazões heterogêneas. Isto pode explicar por que os modelos acompanham as variações no período de teste 1 e não no 2º período de teste.

O comportamento da vazão média do mês observada e simulada pela MLP e pela M5P está representada na Figura 18. Este tratamento teve como entrada dos modelos a precipitação das quatro estações e a vazão média do mês anterior, tratamento 4 e período de teste 1.

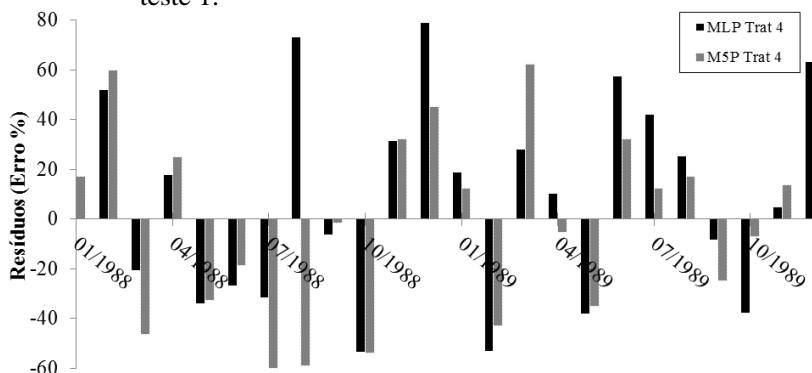
Figura 18 - Hidrograma observado e simulado pela MLP e pela M5P no tratamento 4 e no período de teste 1.



O tratamento 4 foi o que simulou a vazão com menores resíduos para o período de teste 1, sendo o mais adequado para representar a vazão da bacia hidrográfica do Alto Canoas. A MLP alcançou NS de 0,872 e RMSE de 23,205 m<sup>3</sup>/s, já a M5P obteve NS de 0,581 e RMSE de 22,735 m<sup>3</sup>/s.

O comportamento dos resíduos para o período de teste 1 está ilustrado na Figura 19.

Figura 19 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 4 e período de teste 1.

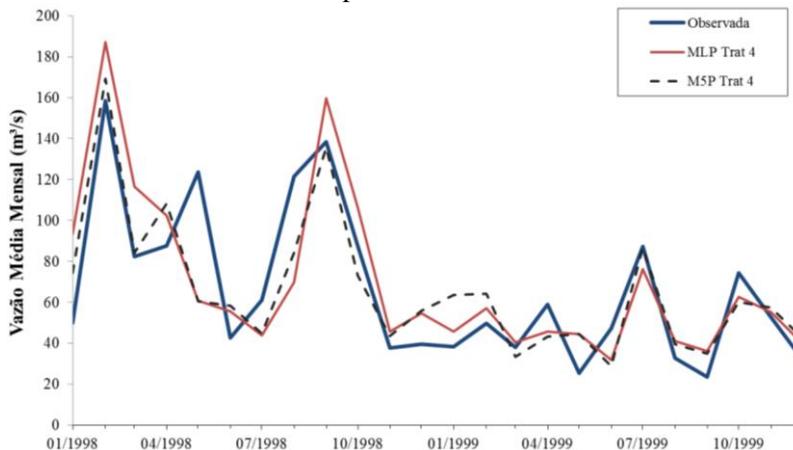


Em média os resíduos do período de teste 1 do algoritmo M5P foram menores (-0,82) comparados os da RNA (8,66), mas o comportamento dos resíduos foram contrários, sendo o coeficiente de variação da RNA 4,64% e da M5P -45,86%.

No tratamento 1, a MLP e a M5P apresentaram comportamento semelhante em quase todas as simulações, ou seja, seus erros são no mesmo sentido, tanto no período de teste 1 como no período de teste 2. A diferença está em que o tratamento 4 foi responsável por fazer com que os dois algoritmos apresentassem comportamento semelhante. O mecanismo que possibilitou isso foi a correlação hidrológica da  $Q_{t-1}$  com a  $Q_t$ , sendo recomendada sua inclusão.

No hidrograma da Figura 20 é demonstrado o comportamento da vazão média do mês observada e a simulada pela MLP e pela M5P para o período de teste 2.

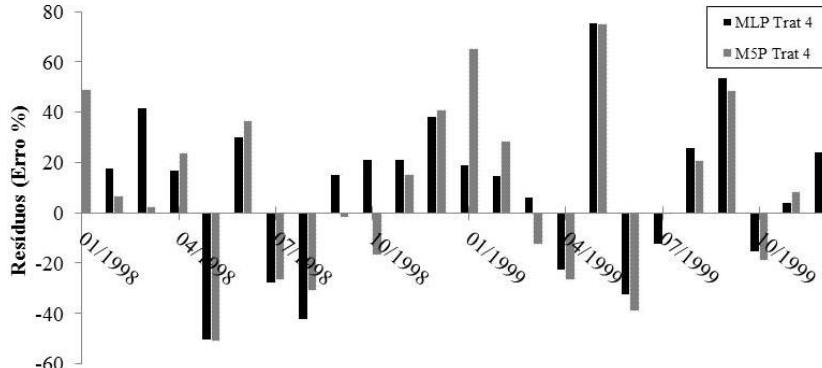
Figura 20 - Hidrograma observado e simulado pela MLP e pela M5P no tratamento 4 e no período de teste 2.



Para o período de teste 2 e tratamento 4 os modelos estudados apresentaram o melhor desempenho, sendo que a RNA alcançou NS de 0,752, RMSE de 22,684 m<sup>3</sup>/s e o algoritmo M5P obteve NS de 0,641 e RMSE de 22,735 m<sup>3</sup>/s.

O comportamento dos resíduos para o período de teste 2 está ilustrado na Figura 21.

Figura 21 - Resíduos calculados pelo erro%, entre a vazão observada e simulada pela MLP e M5P no tratamento 4 e período de teste 2.



O comportamento dos resíduos segue um padrão de distribuição próximo aos demais períodos e combinações de entrada.

O algoritmo M5P apresentou, em média, menor resíduo (9,56%), porém com maior coeficiente de variação (3,52%) comparado à RNA que a média de resíduos foi 12,86% e variação de 2,67%.

No período de teste 1 e 2, a MLP apresentou desempenho superior aos da M5P, estando de acordo com os resultados encontrados por Solomatine e Dusal (2003), que alcançaram melhores resultados com o uso da RNA, tendo RMSE de 19,402 m<sup>3</sup>/s e com a M5P encontraram o RMSE de 21,547. Da mesma forma, Bhattacharya e Solomatine (2006) concluíram que o desempenho de uma RNA apresentou resultados ligeiramente superiores aos da M5P para a modelagem de sedimentos.

Para o período de teste 2 o desempenho entre a MLP e a M5P apresentaram-se bons, e estes foram semelhantes. Tais conclusões também foram ressaltadas por outros estudos como os de Solomatine e Dusal (2003), Bhattacharya e Solomatine (2005), Etemad-Shahidi e Mahjoobi (2009), que investigaram o uso de RNA e da M5P para modelagem chuva vazão.

Escarião et al. (2012) concluíram que os modelos reproduzem de forma satisfatória a série histórica e que ficam evidentes as diferenças nas vazões simuladas, demonstrando que o modelo escolhido influencia diretamente nos resultados.

## 2.4 CONCLUSÕES

Dos modelos de RT avaliados, o modelo que melhor representou a vazão média diária do mês da bacia hidrográfica do Alto Canoas foi o algoritmo M5P, seguido do *Decision Stump* e *REP Tree*.

A poda se fez necessária para a construção da árvore de regressão pelo algoritmo *REP Tree*. Para o algoritmo M5P a necessidade da poda se mostrou inconclusiva, visto que a mesma foi responsável pelo melhor desempenho em metade dos tratamentos.

Para o período de teste 1, o melhor conjunto de vetores de entrada dos modelos foi a utilização das estações pluviométricas localizadas no interior da área de estudo (P1, P2). Já para o período de teste 2 o melhor conjunto de vetores de entrada foi o uso da precipitação das quatro estações pluviométricas e a vazão média do mês anterior (P1, P2, P3, P4, Q<sub>t-1</sub>).

A MLP e a M5P apresentaram resultados ligeiramente superiores, quando utilizada apenas a precipitação das estações pluviométricas localizadas no interior da área de estudo. A adição da  $Q_t$  proporcionou melhor desempenho dos algoritmos MLP e M5P.

A MLP apresentou desempenho ligeiramente superior ao utilizar a precipitação pontual ao invés de ponderar pela área de contribuição.

Para a simulação da vazão média diária do mês para a bacia do Alto Canoas, a RNA conseguiu simular a vazão de forma mais próxima à vazão observada em todos os tratamentos. Porém, a M5P mostrou-se uma alternativa interessante ao uso de RNAs, pois a mesma apresentou desempenho semelhante para o período de teste 2.

## 2.5 REFERÊNCIAS

**BATISTA, A. L. F. Modelos de séries temporais e redes neurais artificiais na previsão de vazão.** 2009. 79 f. **Dissertação** (Mestrado em Engenharia de Sistemas) –Universidade Federal de Lavras, Lavras, 2009.

**BHATTACHARYA, B.; SOLOMATINE, D. P.** Machine learning in sedimentation modelling. **Neural networks**, v.19, p. 208-214, 2006.

**BHATTACHARYA, B.; SOLOMATINE, D. P.** Neural networks and M5 model trees in modelling water lever discharge relationship. **Neurocomputing**, v.63, p.381-396, 2005.

**BRAGA JR., B. P. F. et al.** MELRAD: modelo estocástico linear para previsão de cheias com radar. In: **VIII Simpósio Brasileiro de Recursos Hídricos**, Foz do Iguaçu, PR, v. 2, 1989, p. 13- 22.

**BREIMAN, L. et al.** **Classification and Regression Trees**.Boca Raton, Florida, EUA: Chapman & Hall/CRC, 1984. 358 p.

**CASTRO, T. N. Modelo de previsão sazonal de chuva para o estado do ceará baseado em redes neurais artificiais.** 2011. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Ceará, Fortaleza, 2011.

DANCEY, C.; REIDY, J. **Estatística Sem Matemática para Psicologia: Usando SPSS para Windows**. Porto Alegre, Artmed, 2006.

ESCARIÃO, R. D. et al. Influência do modelo hidrológico na avaliação da sensibilidade dos recursos hídricos a cenários de mudanças climáticas em região semiárida. **Revista Brasileira de Recursos Hídricos**. v. 17, n.3, p. 81-91, 2012.

ETEMAD-SHAHIDI, A.; MAHJOOBI, J. Comparison between M5' model tree and neural networks for prediction of significant wave height in lake superior. **Ocean engineering**. v.36, p.1175-1181, 2009.

FIGUEIREDO, K. et al. Modelo de previsão de vazão com informação de precipitação utilizando redes neurais. **Revista brasileira de recursos hídricos**. v.12, n.3, p. 69-82, 2007.

GOMES, O. M. et al. Análise geoestatística da precipitação pluvial do estado da Paraíba. **Revista Brasileira de Geografia Física**. n.04, p. 692-702, 2011.

HAGAN, M. T.; MENHAJ, M. Training feed-forward networks with the Marquardt algorithm. **IEEE Transactionson Neural Networks**.v.5, n.6, p.989-993, 1994.

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

HEATH, G. E. **Training, testing and validating data set in Neural Network**.2010. Disponível em:  
[http://www.mathworks.com/matlabcentral/newsreader/view\\_thread/295781#917734](http://www.mathworks.com/matlabcentral/newsreader/view_thread/295781#917734). Acesso em: 04 de jul.2013.

HSU, K. L.; GUPTA, H. V.; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. **Waterre sources research**, v. 31, n.10, p. 2517-2530, 1995.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part 1– A discussion of principles. **Journal of Hydrology**. v.10, n.3, p.282-290, 1970.

- OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M. R. O desempenho das redes neurais artificiais (RNAs) para simulação Hidrológica Mensal. **Revista Brasileira de Recursos Hídricos**. v.19, n.2, p. 251-265, 2014.
- OLIVEIRA, G. G. et al. Simulações hidrológicas com diferentes proporções de área controlada na bacia hidrográfica. **Revista Brasileira de Recursos Hídricos**. v.18, n. 3, p. 193-204, 2013.
- QUINLAN, J. R. **C4.5: Programs for machine learning**. São Francisco: Morgan Kaufmann.1993.
- QUINLAN, J. R. Learning with continuous classes.In N. Adams, & L. Sterling (Eds.). **Proceedings of the Fifth Australian Joint Conference on Artificial Intelligence**. Hobart, Tasmania. Singapore: Worls Scientific, 1992, p. 343-348.
- RIAD, S. et al. Rainfall-runoff model using na artificial neural network approach. **Mathematical and computer modelling**. n.40, p. 839-846, 2004.
- SANTOS, C. C.; PEREIRA FILHO, A. J. Modelagem hidrológica urbana por meio de redes neurais artificiais: uma aplicação para a bacia do Rio Tamanduateí em São Paulo, SP. **Revista Brasileira de Meteorologia**. v.18, n. 2, p. 149-159, 2003.
- SOLOMATINE, D. P.; DULAL, K. N. Model trees as analternativeto neural networks in rainfall-runoff modeling. **Hidrological sciences-journal- dessciences hidrologiques**.v.48, n.3, p.399-411, 2003.
- SOUSA, W. S.; SOUSA, F. A. S. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio Piancó. **Revista Brasileira de Engenharia Agrícola e Ambiental**.v.14, n.2, p. 173-180, 2010.
- WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining practical machine learning tool and techniques**. 3<sup>o</sup>ed. Elsevier. 2011. p. 629.

Zia, H; Harris, N; Merrett, G.; Rivers, M. Predicting discharge using a low complexity machine learning model. **Computers and Electronics in Agriculture**, v.118, p.350-360, 2015.

## CONSIDERAÇÕES FINAIS

Os modelos orientados a dados mostram-se capazes de simular o processo chuva-vazão da bacia hidrográfica do Alto Canoas. Os melhores índices de desempenho foram superiores aos que usualmente se encontra para modelos hidrológicos de base física. As RNAs tendem a apresentar os melhores resultados, quando comparadas com as RT.

Foi possível concluir quais os vetores de entrada da MLP apresentaram maior correlação com a vazão e produziram os melhores desempenhos para a modelagem em escala diária. Dessa forma, para futuros estudos será possível otimizar os processamentos, tendo como vetores de entrada apenas os mais relevantes.

Devido à alta correlação entre a vazão do dia anterior com a vazão do dia atual, foi possível utilizar de uma arquitetura denominada de *closed-loop*, a qual possibilitou a simulação da vazão diária à longo prazo com eficácia na maioria dos tratamentos. Esta arquitetura associada a uma das RNA mais requisitadas permite que a rede associe os dados como sendo de uma série histórica, dados não estacionários, e obtenha bom desempenho.

O algoritmo da árvore modelo se mostrou como sendo a árvore de regressão com melhor desempenho para a simulação da vazão média mensal (vazão média diária do mês), comparado aos algoritmos *REP Tree* e *Decision Stump*. A poda é extremamente necessária para a construção da árvore pelo algoritmo REP Tree, já a árvore modelo se mostrou sensível a poda em alguns testes, sendo necessária sua avaliação sempre.

A eficácia da árvore modelo (M5P), em um dos períodos de teste foi semelhante aos índices produzidos pela MLP, sendo uma alternativa interessante ao uso de redes neurais artificiais.

Apesar dos modelos orientados à dados produzirem poucas informações hidrológicas sobre a bacia hidrográfica estudada, se mostraram ferramentas que produzem previsões de vazão diária e mensal (vazão média diária do mês) de forma rápida e com simulações próximas aos valores observados, sendo estes modelos de grande importância e relevância.