

**UNIVERSIDADE FEDERAL DA PARAÍBA**  
**Curso de Graduação em Engenharia Civil**

**GERMANO GONDIM RIBEIRO NETO**

**PREVISÃO DE VAZÃO NA BACIA HIDROGRÁFICA DO RIO JI-  
PARANÁ (RO) USANDO REDES NEURAIS ARTIFICIAIS**

**JOÃO PESSOA**

**2015**

**GERMANO GONDIM RIBEIRO NETO**

**PREVISÃO DE VAZÃO NA BACIA HIDROGRÁFICA DO RIO JI-  
PARANÁ (RO) USANDO REDES NEURAS ARTIFICIAIS**

**Trabalho de conclusão  
de curso de graduação  
em Engenharia Civil da  
Universidade Federal  
da Paraíba.**

**Orientador: Dr. Adriano Rolim da Paz**

**JOÃO PESSOA**

**2015**

## **AGRADECIMENTOS**

Agradeço inicialmente aos meus familiares em especial aos meus pais por todo apoio, incentivo e por todos os sacrifícios que fizeram para que eu pudesse ter as melhores oportunidades em educação.

Agradeço ao meu orientador, Professor Adriano Rolim da Paz pela ajuda, paciência, suporte, conselhos e total apoio durante a realização deste trabalho

Aos meus amigos do dia a dia acadêmico pelo apoio e incentivo, em especial a Alice Moreira, Amanda Farias, Ernani Lucena, Rosenai Pedro e Sergio Pereira.

Ainda agradecimento especial a Ingrid Lacerda pela companhia, ajuda e todo o apoio durante minha vida acadêmica.

## RESUMO

A técnica de previsão de vazão vem sendo amplamente utilizada nos últimos anos, sua aplicação abrange planejamento agrícola, energético, gerenciamento de reservatórios, sistemas de abastecimento, planejamento urbano, sistemas de alerta e emergência, entre muitas outras aplicações. Muito tem sido feito para criar modelos que pudessem responder a essas necessidades. O objetivo desta pesquisa foi desenvolver redes neurais artificiais do tipo MLP para serem aplicadas a previsão de vazão na bacia hidrográfica do rio Ji-Paraná situada no estado de Rondônia. Foram feitas análises estatísticas para determinação das variáveis preditoras e foram elaboradas diversas redes neurais artificiais, variando o número de neurônios na camada de entrada e na intermediária, para se determinar o melhor modelo. Ao fim foram comparados os resultados das medidas de desempenho e concluiu-se que os melhores modelos são os que apresentam maior número de variáveis de entrada relacionadas a chuva acumulada na bacia.

**Palavras-chave:** RNA, Previsão de vazão, Ji-Paraná

## **ABSTRACT**

The flow forecast technique has been widely used in recent years, its application covers agricultural, energy planning, management of reservoirs, water supplies, urban planning, and emergency alert systems, among many other applications. Much has been done to create models that could meet these needs. The objective of this research was to develop artificial neural networks of type MLP to be applied to prediction of flow in the catchment area of the river Ji-Paraná in Rondônia State. Statistical analyses were performed to determine the predictors and were elaborated several artificial neural networks, varying the number of neurons in the input layer and on intermediate to determine the best model. The rest were compared the results of performance measures and concluded that the best models are those with the highest number of input variables related to rain accumulated in the basin.

**Key Words:** ANN, flow forecast, Ji-Paraná

## LISTA DE FIGURAS

Figura 1- Célula neural biológica com a sequência da propagação do sinal.....	16
Figura 2 – Neurônio Artificial.....	19
Figura 3 – Gráfico das funções de ativação.....	20
Figura 4 – Representação ilustrativa de um perceptron.....	22
Figura 5 – Exemplos de redes feed-forward.....	23
Figura 6 - Generalização das RNA.....	27
Figura 7 – Localização da bacia hidrográfica do rio Ji-Paraná no estado de Rondônia.....	31
Figura 8 – Distribuição da precipitação pluvial média mensal (1998/2005) na bacia hidrográfica do rio Ji-Paraná.....	32
Figura 9 – Divisão da bacia hidrográfica do rio Ji-Paraná em 13 sub-bacias.....	33
Figura 10 - Coeficiente de correlação entre a precipitação média dos diferentes agrupamentos das sub-bacias com a vazão afluente da sub-bacia 13.....	36
Figura 11 - Coeficiente de correlação para os dados na forma de anomalia entre a precipitação média dos diferentes agrupamentos das sub-bacias com a vazão afluente da sub-bacia 13.....	36
Figura 12- - Coeficiente de correlação entre chuva acumulada em diferentes períodos de tempo e a vazão afluente a sub-bacia 13 sete dias a frente, considerando a chuva que ocorre sobre diferentes áreas.....	38
Figura 13 - Hidrograma da sub-bacia 13 com a divisão usada para os dados.....	39
Figura 14 - Medidas de desempenho de todos os grupos.....	43
Figura 15 - Gráfico de dispersão da rede com melhor desempenho para cada subgrupo.....	44
Figura 16 - Vazão prevista pela rede CE04SG06N06.....	48
Figura 17 - Vazão prevista pela rede CE06SG03N09.....	49

## LISTA DE TABELAS

TABELA 1– TIPOS DE REDES NEURAIAS ARTIFICIAIS.....	21
TABELA 2 – COMPARAÇÃO ENTRE LITERATURAS.....	30
TABELA 3 – ÁREAS E NOMES DAS SUB- BACIAS.....	33
TABELA 4 - DIVISÃO DOS GRUPOS.....	41
TABELA 5 – MEDIDAS DE DESEMPENHO.....	45

## LISTA DE SIGLAS

ANA – AGÊNCIA NACIONAL DE ÁGUAS

EMA – ERRO MÉDIO ABSOLUTO

EMR – ERRO MÉDIO RELATIVO

MLP – *MULTILAYER PERCEPTRON*

RNA – REDES NEURAIS ARTIFICIAIS

## LISTA DE SÍMBOLOS

b – Tendência ou bias do valor de saída do neurônio

CE – Coeficiente de Nash-Sutcliffe

D – Dado a ser expresso na forma de anomalia

Eavg – Erro médio quadrático

Ei – Valores das entradas

ej – Erro para o elemento processador

F – Função de ativação

Med – Média dos valores do conjunto dos dados

n – Vetor aplicado na entrada da rede

na – Valor na forma de anomalia

Nt – Número de vetores da matriz de treinamento

Qcali – Vazão prevista

Qcalmed – Valor médio das vazões previstas do conjunto de verificação

Qobi - Vazão observada

Qobmed – Valor médio das vazões observadas do conjunto de verificação

R – Coeficiente de correlação

R<sup>2</sup> - Coeficiente de determinação

S – Valor da resposta do neurônio

xmax – Maior valor que a variável a ser normalizada pode alcançar

xmin – Menor valor que a variável a ser normalizada pode alcançar

xnorm – Variável normalizada

xreal – Variável a ser normalizada

w – Pesos sináptico

## SUMÁRIO

1 – INTRODUÇÃO.....	10
1.2 – Justificativa.....	11
1.3 – Objetivo geral.....	11
1.4 - Objetivos específicos.....	11
2–REVISÃO BIBLIOGRÁFICA.....	12
2.1 – Modelagem Hidrológica.....	12
2.2 – Previsão de vazão.....	13
2.3 – Sistema de previsão e alerta.....	14
2.4 Redes Neurais Artificiais.....	14
2.4.1 – Visão geral.....	14
2.4.2 – Características Principais.....	16
2.4.3 – Histórico.....	17
2.4.4 – Neurônio Artificial.....	18
2.4.5 – Função de Ativação.....	20
2.4.6 – Tipos de RNA.....	21
2.4.7 – Perceptron.....	21
2.4.8 – Redes do tipo Perceptron de Multicamadas (MLP).....	22
2.4.9 – Treinamento.....	23
2.4.10 – Validação cruzada.....	25
2.4.11 – Arquitetura.....	26
2.4.12 – <i>Epochs</i> .....	25
2.5 – Exemplos de aplicações de redes neurais para previsão de vazão.....	27
3 – METODOLOGIA.....	30
3.1 – Área de estudo.....	30
3.1.1 – Divisão da bacia hidrográfica do rio Ji-Paraná.....	32
3.2 – Aplicação das redes neurais artificiais.....	34
3.2.1 Visão Geral.....	34
3.2.2 – Dados disponíveis.....	34
3.2.3 – Definição da variável de previsão.....	34
3.2.4 - Definição das variáveis preditoras.....	37
3.2.5 – Configurações testadas.....	39
3.2.6 – Arquitetura da rede neural artificial.....	40

3.2.8 – Medidas de desempenho.....	41
3.2.9 – Normalização dos dados.....	42
3.2.10 – Nomenclatura da rede neural artificial.....	42
4 – RESULTADOS E DISCUSSÕES.....	43
5 – CONCLUSÃO.....	50
6 – REFERÊNCIAS BIBLIOGRÁFICAS.....	52

## 1 – INTRODUÇÃO

Com o aumento populacional que o mundo vem passando nos últimos anos, surge o desafio de manter a produção de alimentos, energia e abastecimento de água para suprir os grandes centros urbanos. Além disso, a falta de planejamento urbano que assola a grande maioria das cidades brasileiras, somado ao déficit habitacional faz com que seja comum a existência de inúmeras comunidades de baixa renda instaladas em margens de rios. Estas além de sofrer com a falta de infraestrutura básica, são prejudicadas com inundações causadas por eventos extremos de cheia do rio.

Estas cheias causam não só prejuízos financeiros para essas populações mas também contribuem para a proliferação de diversos tipos de doenças, pois como em geral não existem planos de emergência para retirada delas antes dos eventos extremos, acabam por ficar em contato direto com água contaminada por longos períodos de tempo. O atendimento a essa demanda e a solução desses problemas vêm sendo amplamente estudados ao redor do mundo.

A previsão de vazões em rios tem sido foco de vários estudos nos últimos anos, sendo criados diferentes tipos de métodos e modelos que preveem de maneira satisfatória o comportamento das bacias hidrográficas. Avaliar estes processos permite gerenciar de forma mais adequada o uso da água, como irrigação agrícola, geração de energia elétrica e abastecimento.

O entendimento da interação entre os fenômenos e processos que envolvem o ciclo hidrológico permitiu a simulação do comportamento da água nas bacias hidrográficas, tornando possível a previsão de diferentes cenários hidrológicos em função de mudanças climáticas, ocupação do solo, quantidade e tipo de vegetação, surgindo assim o conceito de modelagem hidrológica, que abriu caminho para equacionamento dos processos físicos, representação, entendimento e simulação do comportamento hidrológico de uma bacia hidrográfica (TUCCI, 1998). Além disso estes modelos, chamados de modelo chuva-vazão, podem ser utilizados em sistemas de gerenciamento de reservatórios de abastecimento, hidrelétricas, hidrovias, além de sistemas alerta de emergência.

Uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos é a previsão de vazão em uma bacia

hidrográfica, podendo ser considerada como um dos principais desafios relacionados ao conhecimento integrado da climatologia e hidrologia (HAMLET et al., 2002; BARROS et al., 2003; TUCCI et al., 2003).

A previsão de vazão pode ser classificada como de curto, e longo prazo. A primeira, também denominada de previsão em tempo real, resume-se a uma antecedência de horas ou poucos dias, a de longo prazo pode ser utilizada para previsão de vazões com antecedência entre 1 e 9 meses e se relaciona com diversos fatores climáticos que podem influenciar as vazões futuras na bacia hidrográfica. (TUCCI, 2005).

Uma das formas de se prever vazão é pelos modelos empíricos, dentre eles as redes neurais artificiais (RNA) se destacam pela sua versatilidade e desempenho neste quesito. A RNA é formada por elementos chamados de neurônios que são distribuídos espacialmente e que quando conectados entre si representam uma função matemática. Esta pesquisa se insere neste contexto, avaliando a utilização de redes neurais artificiais para previsão de vazão na bacia hidrográfica do rio Ji-Paraná.

## **1.2 – Justificativa**

Estudos de previsão de vazão apresentam grande retorno socioeconômico pois podem contribuir para melhor planejamento agrícola e de abastecimento de uma região, além da possibilidade de integrar um sistema de alerta de emergência que possibilite as autoridades competentes a retirar as populações em zonas de risco com um intervalo de tempo seguro antes dos eventos extremos de enchentes

## **1.3 – Objetivo geral**

Analisar a capacidade e o desempenho de Redes Neurais Artificiais na previsão de vazão de curto prazo no rio Ji-Paraná.

## **1.4 - Objetivos específicos**

- 1) Identificar a correlação temporal entre a chuva antecedente e a vazão no exutório da bacia hidrográfica do rio Ji-Paraná.
- 2) Realizar previsões de vazão no rio Ji-Paraná a partir de informações de precipitação na bacia de drenagem da área estudada.

## 2–REVISÃO BIBLIOGRÁFICA

### **2.1 – Modelagem Hidrológica**

A simulação hidrológica pode ser empregada para várias aplicações como na análise de disponibilidade de água em um corpo hídrico, impacto das mudanças do uso do solo, análise da variabilidade hidrológica, previsão de vazões de curto e médio prazo, podendo ser empregado nos mais diversos tipos de bacias hidrográficas (COLLISCHONN, 2001).

Inicialmente os modelos de simulação hidrológica operavam de maneira simplória, muitas vezes desconsiderando os efeitos não lineares presentes nos problemas. Com o advento da computação, tornou-se possível processar um grande número de dados em pouco tempo, abrindo espaço para a concepção de modelos que simulassem o ciclo hidrológico levando em conta características não lineares do processo, aumentando assim a probabilidade de prever a ocorrência desses eventos extremos e os períodos em que provavelmente ocorrerão. Estes novos modelos foram denominados de modelos conceituais, pois utilizam em suas rotinas cálculos algorítmicos que simulam os processos físicos comuns a uma bacia hidrográfica tais como: precipitação, interceptação, evaporação, infiltração, escoamento superficial, escoamento subterrâneo, etc (MACHADO, 2005).

Os modelos conceituais apresentam resultados satisfatórios no que diz respeito à simulação de uma bacia hidrográfica, porém para a calibração dos mesmos é necessário o ajuste de um grande número de parâmetros e a coleta em campo de vários tipos de dados diferentes. A interação entre os parâmetros é muito complexa e o processo de calibração é lento, sendo feito por procedimentos de tentativa e erro acompanhado por um algoritmo que analise a eficiência desta etapa. Sendo assim, a qualidade dos resultados obtidos pelos modelos conceituais torna-se, de certo modo, subjetiva e dependente da experiência do usuário em relação ao modelo. A coleta em campo de determinados tipos de dados demanda, muitas vezes, equipes técnicas especializadas, o que onera consideravelmente o modelo e o torna mais dispendioso. Além disso é necessária a determinação dos principais processos físicos envolvidos no ciclo hidrológico da bacia estudada e representá-lo matematicamente. Esta etapa do processo

de elaboração de um modelo conceitual é de complexidade elevada e isso se torna mais crítico quando se considera a escala de tempo na modelagem, pois existe grande dificuldade em se analisar os processos físicos citados anteriormente em escalas horárias, diárias ou semanais, conforme a necessidade do modelo (MACHADO, 2005).

Uma alternativa aos modelos conceituais são os empíricos, que se utilizam de equações matemáticas para estabelecer uma relação estável entre as variáveis de entrada e saída, desconsiderando os parâmetros físicos relacionados à transformação de chuva em vazão de determinada bacia hidrográfica. Dentre todos os modelos empíricos, as Redes Neurais Artificiais (RNA) têm sido amplamente utilizadas como forma de se modelar sistemas não-lineares complexos com grande quantidade de dados, obtendo-se resultados promissores e satisfatórios.

## **2.2 – Previsão de vazão**

O modelo chuva-vazão é uma ferramenta que, através de uma abordagem resumida e simplificada dos processos do ciclo hidrológico, é capaz de avaliar a influência de uma precipitação qualquer sobre a geração de vazão de uma bacia hidrológica. Estes modelos são muito utilizados para o estudo de comportamento de fenômenos físicos hidrológicos; análise de consistência e preenchimento de falhas; previsão e vazão em tempo real; previsão de cenários de planejamento; sistemas de previsão e alerta; dimensionamento de obras hidráulicas, entre outros (TUCCI, 1998).

A previsão de vazão em uma bacia hidrográfica consiste na estimativa do escoamento em curso d'água, com antecedência temporal, e é uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos (TUCCI e COLLISCHONN, apud BRAVO et al, 2008).

## **2.3 – Sistema de previsão e alerta**

Anualmente a população brasileira sofre fortes prejuízos devido a eventos climático extremos que causam de secas prolongas a enchentes e deslizamentos de encostas. Em muitas regiões o período de chuva representa o caos e desespero para várias comunidades, que veem suas casas e bens sendo destruídos por inundações, além ficarem sob o constante risco de se contrair doenças que tem a água como vetor

de transmissão. Pouco tem sido investido em pesquisas e criação de um sistema e procedimentos para diminuir esses transtornos e prejuízos.

As técnicas e metodologias de redução dos impactos devidos as enchentes engloba ações políticas, equipes de estudo e projetos de engenharia, planejamento urbano, aspectos operacionais da ocupação e uso do solo. Boas ações políticas e planejamento urbano eficiente agem tanto na prevenção como minimização dos impactos gerados devido às enchentes. Esta prevenção pode ser feita de diversas maneiras tais como: medidas de manutenção da vegetação marginal dos cursos d'água; controle do uso de ocupação do solo através de um plano diretor bem elaborado; realização de estudos que possam simular a área de inundação para diferentes cenários de chuva e assim criar um mapa com as áreas de risco; medidas de controle do escoamento na fonte geradora, como aprofundamento dos cursos d'água, entre outros. Associado a essas medidas deve ser criado um sistema de alerta de emergência, que com base em dados históricos e modelos de previsão de vazão, ajudará as autoridades a decidirem com antecedência a retirada das populações sob zona de risco.

Como dito anteriormente um sistema de previsão e alerta eficiente traz grandes retornos socioeconômicos, permite o lançamento de um alerta de inundação, tornando possível a evacuação antecipada, realocação de cargas e mercadorias e uma gestão mais eficiente de toda infraestrutura afetada.

A tomada de decisão para envio antecipado de avisos de enchentes é a etapa mais complexa e difícil de um sistema de alerta e emergência, visto que é baseado em resultados de previsão de cheias. Estes resultados por sua vez são obtidos através de modelos hidrológicos que visam, de forma aproximada, representar os processos físicos que afetam o movimento da água na bacia hidrográfica estudada (MOORE et al, 2004). Uma das maneiras utilizadas para previsão de vazão integrada a este tipo de problema são as redes neurais artificiais que é o foco deste trabalho.

## **2.4 Redes Neurais Artificiais**

### **2.4.1 – Visão geral**

A inteligência computacional é definida como um conjunto de técnicas, modelos e algoritmos em sistemas computacionais que simulem as habilidades cognitivas humanas.

Este ramo abrange diversas outras áreas de conhecimento científico, tais como ciência da computação, matemática, biologia, entre outras. Dentro das diversas técnicas de inteligência computacional, a rede neural artificial vem sendo amplamente utilizada com sucesso na resolução de diversos tipos de problemas (VON ZUBEN, 1993).

Uma rede neural artificial é um modelo matemático empírico, com memória e processamento não linear que tem como inspiração o funcionamento das células do cérebro humano. Sua estrutura é formada por nós ou neurônios distribuídos em diferentes camadas e que, interconectados, representam matematicamente uma função.

As células cerebrais humanas funcionam basicamente recebendo pulsos eletroquímicos dos neurônios vizinhos por ligações de entradas e o somatório destes pulsos resulta em uma energia que gera um grau de ativação no neurônio. Diferentes tipos de graus de ativação vão originar respostas diversas que são transmitidas para o próximo neurônio também na forma de impulsos eletroquímicos (BRUMATTI, 2005). A constituição de um neurônio biológico se dá por um corpo central, diversos dendritos e um axônio. Os dendritos recebem sinais eletroquímicos de outros neurônios através das sinapses, que constitui o processo de comunicação entre neurônios. O corpo celular processa a informação e a envia para outro neurônio ou um músculo através do axônio. Uma representação esquemática de um neurônio biológico segue na figura 1.

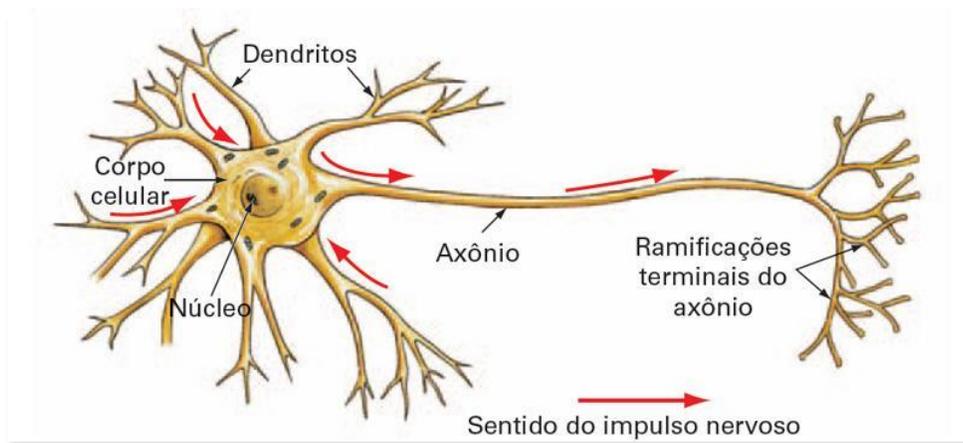


Figura 1- Célula neural biológica com a sequência da propagação do sinal (Fonte: CRISTINA, 2012).

As RNA foram desenvolvidas inspiradas neste processo, ou seja, são constituídas por vários elementos de processamento conectados entre si, onde cada elemento recebe e envia informações de forma semelhante a uma célula neural biológica. Com uma malha

infimamente menor de elementos do que a do cérebro humano, as RNA são capazes de aprender, executar operações não lógicas, transformações e comparações, descobrir relações ou regras e testar situações em paralelo de um problema específico (TAFNER et al., 1996).

Uma RNA trabalha com computação em paralelo que é uma maneira de se realizar diversos cálculos simultaneamente, para isso utiliza-se de vários elementos de processamento com o intuito de resolver o problema dividindo-o entre as unidades de processamento existentes. Estas características fazem com que essa ferramenta possa ser empregada em diversos ramos da ciência tais como: análise e processamento de sinais; classificação de dados; controle de processos; previsão de índices econômicos; previsão de chuva e vazão; reconhecimento de padrões em linhas de montagem.

#### **2.4.2 – Características Principais**

VON ZUBBEN (1993) caracteriza uma RNA como um modelo matemático que simula o funcionamento de uma célula neural, levando em conta as seguintes considerações fundamentais:

- A informação é processada em vários elementos chamados de neurônios;
- A informação é convertida em sinais que são propagados de um elemento a outro através de conexões;
- Cada conexão faz o ponderação do sinal transmitido através de um peso associado;
- Cada neurônio tem em sua entrada uma função de ativação que realiza uma soma ponderada dos sinais de entrada que determina a saída da informação.

As RNAs são caracterizadas por três aspectos básicos que são: arquitetura; algoritmo de treinamento; função de ativação.

### **2.4.3 – Histórico**

As redes neurais artificiais passaram por um interessante processo de evolução, marcado por um período de grande atividade seguido por anos de estagnação nas pesquisas e pelo ressurgimento do interesse científico como consequência do desenvolvimento de novas tecnologias e fundamentos teóricos (VON ZUBEN, 1993).

Os estudos dessa área se iniciaram em 1943 por McCulloch e Pitts que projetaram a estrutura que é considerada como a primeira RNA da história. Estes pesquisadores propuseram um modelo de neurônio como uma unidade de processamento binária e conseguiram demonstrar e provar que este sistema era capaz de executar diversas operações lógicas. Em 1949, D.O.Hebb apresentou uma hipótese que foi de grande importância para a evolução da teoria de aprendizagem em RNAs. Em seu estudo, ele propôs que determinadas conexões entre as células cerebrais tendem a se fortalecer enquanto que outras se enfraquecem e que este processo ocorre simultaneamente (MACHADO, 2005).

Rosenblatt, considerado como o pai da neurocomputação, em 1957 fez uma grande contribuição para essa área, quando introduziu o *perceptron*, uma nova abordagem para o desafio de reconhecimento de padrões. Ele também propôs um algoritmo para o ajuste dos pesos deste modelo e provou sua convergência quando os padrões são linearmente separáveis. Em 1960, Widrow e Hoff, introduziram o conceito de *leastmeansquare* (LMS) utilizado para formular a RNA *Adaline* (*Adaptive Linear Element*) (VON ZUBEN, 1993).

As pesquisas de redes neurais artificiais, tanto na forma de *perceptron* como em *adaline* passaram a enfrentar dois problemas fundamentais. O primeiro estava relacionado ao fato de grande parte destes estudos serem de ordem heurística, faltavam resultados práticos e teóricos que justificassem os investimentos e o interesse científico por essa área, isso acarretou uma redução na produção de novas ideias. O segundo problema foi a não obtenção de resultados à altura da expectativa gerada pelos cientistas da área, o que contribuiu também para a redução do financiamento para estes estudos (SILVA, 2005).

Em 1969, M.L.Minsky&A.Papert publicam o livro “*Perceptron*”, nele, os autores fizeram uma série de críticas severas ao estudo de RNA, alegando que este modelo

utiliza processos de aproximação empíricos e mostraram que o *perceptron*, apesar de ser capaz de executar operações booleanas, não é capaz de executar outras operações elementares. Esta publicação teve grande impacto no meio científico fazendo com que muitos projetos de pesquisas nesta área sofressem uma retração significativa com cortes de financiamento ou mesmo cancelamento total (BRUMATTI, 2005).

Só em 1974, com Paul Werbos, que houve uma retomada significativa nessa área, com o lançamento das bases do algoritmo de treinamento *backpropagation* (retro propagação) que em 1986, foi apresentado por Rumelhart, Hinton e Williams. Neste mesmo ano, Rumelhart e McClelland publicam o livro “*Parallel Distributed Processing: Explorations in the Microstructures of Cognition*” que se torna mais tarde o livro de maior influência na metodologia de aprendizado do tipo *backpropagation* (VON ZUBEN, 1993).

#### **2.4.4 – Neurônio Artificial**

O neurônio artificial é o elemento básico de uma RNA, também pode ser chamado de nó ou unidade de processamento. Sua estrutura foi idealizada matematicamente, de maneira que consiga receber informação, processar estímulos e transmitir uma resposta a outros elementos conectados a este. O neurônio artificial é constituído de três elementos básicos para o seu funcionamento.

- Conjuntos de Pesos;
- Somatório;
- Função de ativação.

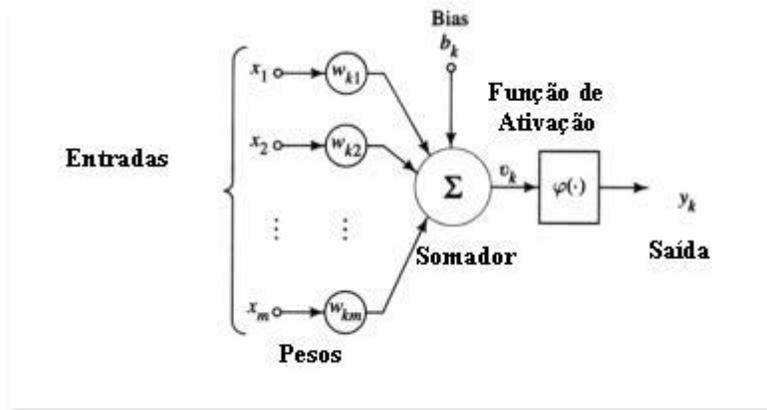


Figura 2 – Neurônio Artificial. Fonte: Haykin (2001).

Cada conexão tem um peso associada a ela que faz ponderação da informação recebida, sendo este processo responsável pelo aprendizado da RNA e foi inspirado no funcionamento de uma célula neural biológica. O somatório é responsável pela soma de todos os sinais ponderados e repassa essa nova informação para função de ativação que vai processar este somatório e gerar a resposta que pode ser ou não transmitida aos próximos neurônios. Muitas vezes, as funções de ativação apresentam características restritivas, isto significa que podem barrar a informação ao neurônio seguinte quando o valor do somatório não alcançar determinado patamar. Seu funcionamento é definido pela equação 1:

$$S = \varphi(\sum_{i=1}^n w_i x_i + b_k) \quad (1)$$

onde S é o valor da resposta do neurônio; F é a função de ativação;  $w_i$  são os pesos sinápticos;  $X_i$  são os valores das entradas que são processadas no neurônios;  $b_k$  é a tendência ou *bias* do valor de saída.

#### **2.4.5 – Função de Ativação**

A escolha da função de ativação está diretamente relacionada à capacidade que a RNA tem em solucionar o problema proposto. Existem diversos tipos de função de ativação, dentre elas pode-se citar:

- Função linear;
- Função tangente hiperbólica;
- Função sigmóide.

- Função degrau

Na figura 3 está indicada a representação gráfica das funções citadas acima.

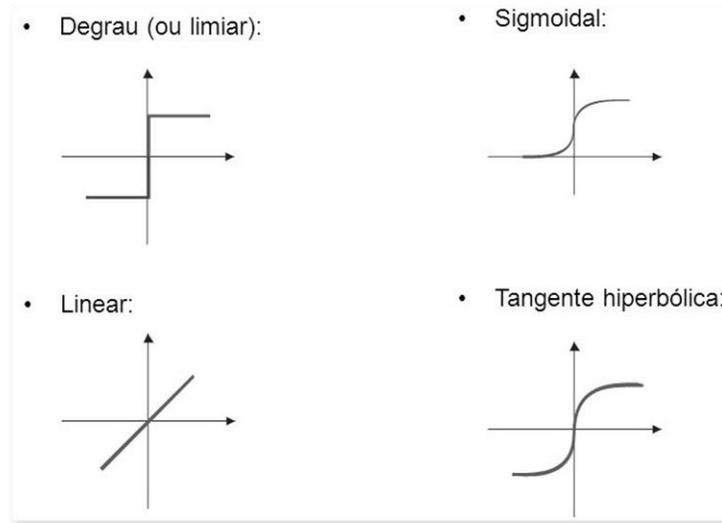


Figura 3 – Gráfico das funções de ativação (Fonte: SILVA, 2005 adaptado).

A função de transferência possibilita que uma RNA possa ter a capacidade de identificar relações, lineares ou não, entre as variáveis de entrada e saída. O modelo de cada unidade da rede pode incluir uma *não-linearidade* na sua saída, é importante frisar que esta não-linearidade deve ser suave, ou seja, diferenciável, diferentemente da sua função de ativação.

Para VON ZUBEN (1993):

A função de ativação representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade. Tendo em vista a simplicidade desejada para as unidades processadoras, geralmente define-se seu estado de ativação como uma função algébrica da entrada interna atual, independente de valores passados do estado de ativação ou mesmo da entrada interna

#### **2.4.6 – Tipos de RNA**

As RNA podem ser classificadas basicamente em relação a dois fatos, quanto ao tipo de treinamento a qual são submetidas e em relação a propagação da informação

dentro da rede. O treinamento pode ser supervisionado ou não supervisionado. A propagação da informação dentro de uma rede neural pode seguir dois aspectos; o primeiro e mais utilizado é quando o sentido é apenas positivo (*feedforward*), ou seja, quando a propagação ocorre da entrada para saída ou do tipo recorrente quando a informação se propaga em diversos sentidos entre as camadas da RNA. Segue na tabela 1 alguns exemplos mais comuns de RNA.

Tabela 1 - Tipos de Redes Neurais Artificiais

<b>Treinamento supervisionado</b>	
<b>Redes recorrentes</b>	<b>Redes de propagação Positiva</b>
Máquina de Boltzmann (BM)	Perceptron
Mean Field Annealing (MFA)	Adaline, Madaline
Cascade Correlation Recorrente (RCC)	Retro-propagação – Backpropagation (BP)
Aprendizado Recorrente em Tempo Real (RTRL)	Máquina de Cauchy (CM)
Filtro de Kalman Recorrente (EKF)	Artmap
<b>Treinamento não-supervisionado</b>	
<b>Redes recorrentes</b>	<b>Redes de propagação Positiva</b>
Grossberg Aditivo (AG)	Learning Matrix (LM)
Adaptive Resonance Theory (ART1)	Driver-Reinforcement Learning (DR)
Hopfield Simétrico e Assimétrico (DH/CH)	Memória Associativa Linear (LAM)
Memória Associativa Bidirecional (BAM)	Counterpropagation (CPN)

#### **2.4.7 – Perceptron**

O modelo *Perceptron* foi criado por Rosenblatt no final dos anos de 1950 e é o modelo de RNA com propagação positiva da informação mais simples possível, pode ser formado por diversos elementos na camada de entrada, conectados aos neurônios de uma única camada de saída, sua função de ativação apresenta uma saída limitada aos valores de -1, 0 ou 1. Sua aplicação resume-se principalmente à classificação de dados e identificações de padrões (VON ZUBEN, 1993). Sua representação esquemática segue na figura 4.

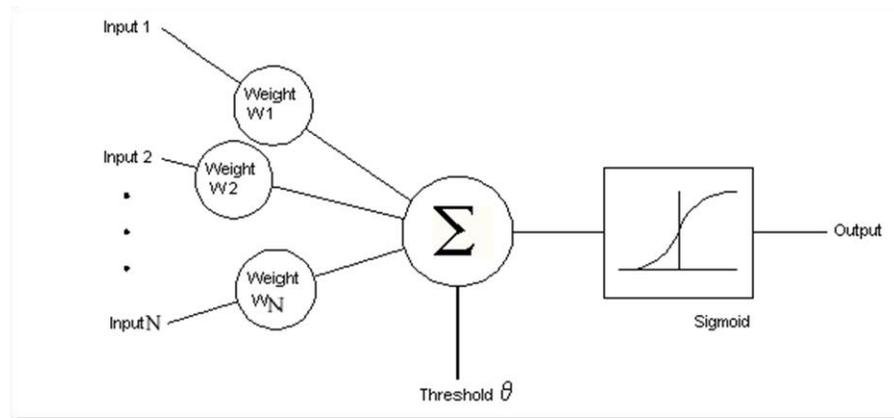


Figura 4 – Representação ilustrativa de um perceptron (Fonte: VON ZUBEN, 1993) adaptado.

#### **2.4.8 – Redes do tipo Perceptron de Multicamadas (MLP)**

Dentre os mais diversos tipos de RNA, as mais utilizadas são as *Multilayer Perceptron* (MLP), ou seja, perceptron de multicamadas. A característica principal deste tipo de RNA é ter os neurônios distribuídos em camadas e os sinais se propagando camada a camada em uma direção positiva. É usual que se tenha três camadas, sendo uma delas de entrada, uma intermediária ou oculta e uma de saída.

Uma característica marcante da perceptron de multicamadas é que todos os neurônios de uma camada se conectam com os neurônios da camada seguinte. Os dados de entrada da primeira camada são ponderados pelos pesos presentes nas conexões e são transformados em uma combinação linear para serem passados para a camada intermediária. Esta combinação produz um estímulo na função de ativação, emitindo uma resposta. A diferença básica entre uma RNA do tipo perceptron e uma MLP é que nesta última a resposta da função de ativação é a entrada para próxima camada, que por sua vez, pode ser ou não a camada de saída.

É interessante que a MLP não tenha muitos neurônios na camada intermediária, pois resulta em um maior número de conexões, conseqüentemente maior quantidade de pesos a serem determinados. Um número excessivo de pesos demanda maior número de dados para que etapa de treinamento aconteça de maneira mais eficiente. A MLP tem seu treinamento supervisionado e o algoritmo que utiliza para isso é o de retro propagação de erro (*error backpropagation*).

O *perceptron* de multicamada tem sido usado com sucesso na solução de problemas relacionados a altos graus de não-linearidade. Na figura 5 segue uma representação gráfica mostrando a diferença entre uma RNA do tipo *perceptron* e uma MLP.

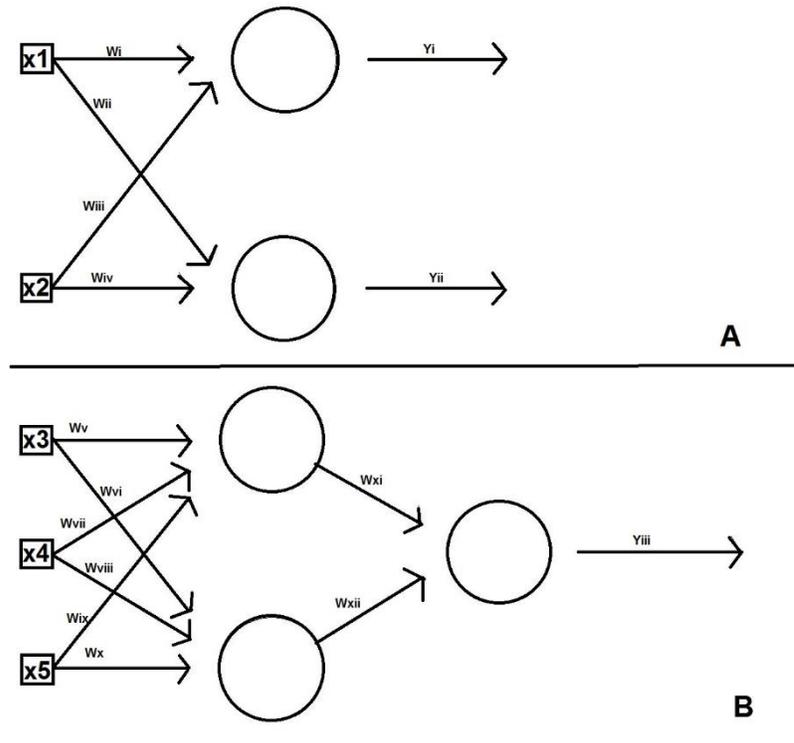


Figura 5 – Exemplos de redes feed-forward: (a) Perceptron; (b) MLP.

### **2.4.9 – Treinamento**

Uma das etapas mais importantes da elaboração de uma RNA é seu treinamento, este pode ser supervisionado ou não-supervisionado. O primeiro é o mais utilizado, refere-se a um método em que para cada saída obtida, compara-se com um valor desejado e quando a informação obtida pela RNA obtiver uma variação fora da aceitável, o algoritmo de treinamento muda os valores dos pesos das conexões e a operação é repetida até que o erro esteja dentro do intervalo aceitado. O método de treinamento não-supervisionado realiza uma organização de modo que haja classificação dos valores de entrada, para isso, segue critérios internos próprios definidos anteriormente. O tipo de treinamento utilizado para as redes neurais artificiais elaboradas neste estudo é apresentado no item 3.2.5 .

### **a) Treinamento Supervisionado**

No treinamento supervisionado, são inseridos na RNA os dados de entrada com sua respectiva saída esperada, é feita então alterações nos pesos internos comparando-se a saída encontrada pela rede com o valor desejado até conseguir um valor muito próximo do desejado. O procedimento é repetido até que a diferença entre os valores sejam menores que um determinado limiar predefinido. Existem diversos algoritmos para ajuste dos pesos da rede, baseados neste conceito, tais como: adaline (acrônimo em inglês para *alternative linear elemento*), madaline (Múltipla Adaline), retropropagação do erro, etc.

Segundo Rumelhart et al. (1986), o algoritmo de treinamento supervisionado mais utilizado é o retropropagação de erro (*backpropagation*). Esse processo é feito basicamente em duas etapas. Na primeira, os dados de entrada são apresentados e propagados através da rede, camada por camada e calculando a saída de cada neurônio. Durante esta fase, os pesos são fixados e calcula-se o erro por unidade de saída, comparando-se o resultado encontrado pela rede com o desejado. Na fase seguinte, é feita uma otimização não linear irrestrita, tendo os pesos sinápticos como variáveis de decisão, objetivando diminuir o somatório dos erros quadráticos dos neurônios de saída. Para algoritmo de retropropagação de erro tradicional, a otimização é feita baseada no método de gradiente descendente que considera apenas condições de primeira ordem a partir da função objetivo.

### **b) Treinamento não-supervisionado**

Os métodos de treinamento não-supervisionados funcionam sem que as saídas corretas sejam fornecidas, para isso capacitam as redes neurais para conseguirem encontrar correlações presentes nas variáveis preditoras e com o término do processo de aprendizagem, a rede neural passa a ficar hábil a classificar suas entradas em função das correlações aprendidas.

Os algoritmos desse modelo de treinamento se baseiam em métodos competitivos utilizados pelas redes de Kohonen, sendo assim após o recebimento de um determinado sinal de entrada, os neurônios competem entre si para determinar qual consegue a menor distância entre os correspondentes pesos sinápticos e as entradas.

#### **2.4.10 – Validação cruzada**

Uma dos desafios da elaboração de uma metodologia para o treinamento de redes neurais artificiais é a determinação do ponto de parada de treinamento. Uma das maneiras de solucionar este problema buscando uma otimização da capacidade da rede em generalizar, é a utilizar a técnica da regra de parada com base na validação cruzada.

A validação cruzada baseia-se em uma técnica estatística para validar o modelo obtido durante o treinamento da rede, para isso utiliza um conjunto de dados diferentes dos usados para aferir os parâmetros durante o treinamento (HAYKIN, 2001). O treinamento para quando o erro na validação decresce e alcança um valor próximo ao mínimo pré-estabelecido.

#### **2.4.11 – Arquitetura**

A definição da arquitetura de uma RNA consiste basicamente em determinar o número de camadas e o de neurônios em cada uma delas. Diversos estudos mostram que, para previsão de vazão, as RNA precisam apenas de três camadas no total, sendo assim, a etapa de definição de uma arquitetura resume-se a determinar o número de neurônios na camada de entrada e na intermediária, visto que, o número de saídas é consequência direta da natureza do problema a ser estudado. O número de neurônios de entrada deve ser determinado em função do tamanho do conjunto de dados disponíveis utilizados. A determinação da quantidade de neurônios na camada intermediária segue de forma diferente da camada de entrada, o número reduzido de neurônios nesta camada vai fazer com que a rede perca capacidade de se adaptar ao problema estudado. Quando ocorre o oposto, ou seja, existe um número excessivo de neurônios nessa camada, faz com a etapa de treinamento seja mais vagarosa e a RNA perde a capacidade de generalizar o problema, de forma que, quando são introduzidos valores distantes da média dos dados utilizados, o desempenho cai consideravelmente.

#### **2.4.12 – Epochs**

Epochs ou interações representam o número de atualizações ocorridas nos pesos e vieses, podendo ocorrer basicamente de duas formas, *on-line* e em *batch*. Para a interações do tipo *on-line*, cada linha da matriz de dados é introduzido individualmente

em determinada camada, para ocorrer o treinamento e atualização dos pesos e após esse ciclo é registrada uma interação.

A ferramenta mais difundida de elaboração de RNA é *Neural Network toolbox* do software MATLAB; nela, o processo de atualização dos pesos e registros das *epochs* são do tipo *batch*. Neste processo, todos os valores da matriz de dados são introduzidos de uma vez a determinada camada para só assim ocorrer o treinamento e consequentemente atualização dos pesos e contagem da interação. O erro deste processo passa a ser uma função de custo formada pelo somatório do médio quadrático da cada padrão individual como pode ser visto na equação 2 que segue abaixo:

$$E_{avg} = \frac{1}{2Nt} \sum_{Nt=1}^{Nt} \sum_{jeC} e_j^2(n) \quad (2)$$

onde  $Nt$  corresponde ao número de vetores da matriz de treinamento,  $e_j(n)$  corresponde ao erro para o elemento processador  $j$  quando o vetor  $n$  é aplicado na entrada da rede.

No início da etapa de treinamento, os erros são relativamente altos e as RNA não têm capacidade de se ajustar a funções mais complexas. Com a evolução do treinamento, tendo passado mais *epochs*, o erro diminui e passa a ser possível o mapeamento destas funções mais complexas.

Contudo, fixar uma grande quantidade de interações durante o treinamento não necessariamente implica que a RNA terá melhor desempenho. No início do processo de treinamento, os pesos rapidamente se ajustam para uma situação genérica; esta situação é representada por uma curva que passa próxima a todos os pontos (Machado, 2005). A figura 5 ilustra o processo citado.

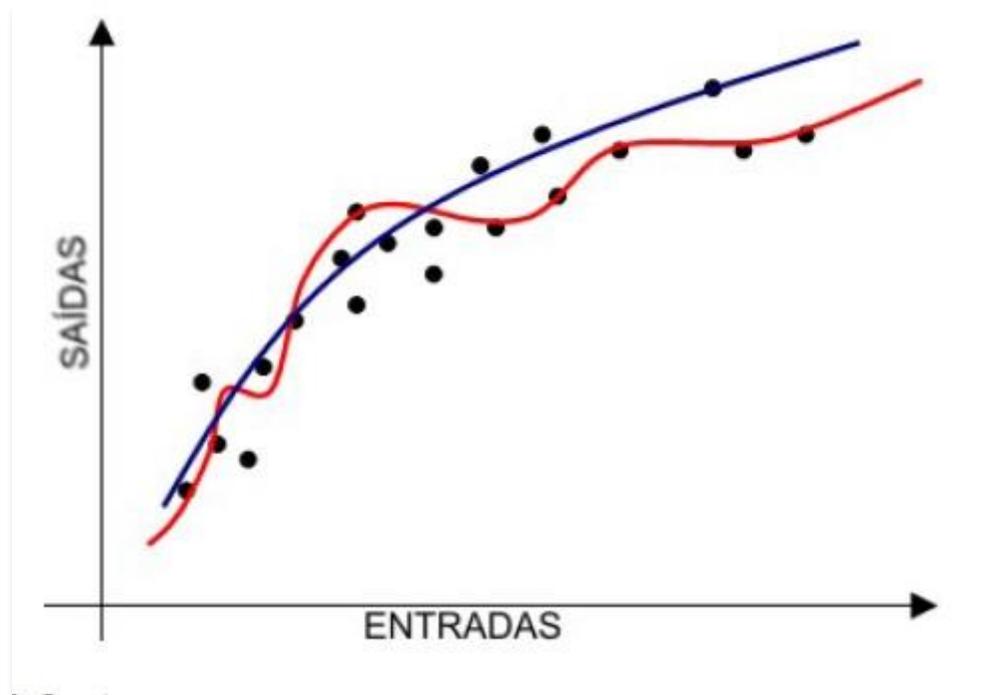


Figura 6 – Generalização das RNA. Fonte: Machado,2006.

Os pontos pretos vistos na figura 5 representam os dados que devem ser ajustados por determinada função da RNA. A curva azul representa os primeiros estágios do treinamento, após um maior número de interações, a RNA tende a aproximar os pontos pretos de maneira a formar a curva vermelha. Essa operação é conhecida como *overfitting* ou super ajustamento. BRAVO et al. (2008) explicam que o super ajustamento ocorre quando uma rede neural artificial reproduz ruídos existentes nos dados de treinamento, perdendo, dessa forma, a sua capacidade de generalização quando utilizados outros valores como dado de entrada. Este efeito é muito semelhante ao causado pelo número excessivo de neurônios na camada intermediária.

### **2.5 – Exemplos de aplicações de redes neurais para previsão de vazão**

BATISTA (2009) em sua dissertação de mestrado analisa a criação de dois sistemas distintos para a realizar a previsão em escala mensal de séries temporais de vazões fluviais do Rio Grande localizado no estado de Minas Gerais, sendo um deles RNA do tipo *perceptron* de multicamadas e o outro modelo foi o sugerido por Box & Jenkins. O autor chegou à conclusão de que, para este propósito, a rede neural obteve

melhor adequação e a arquitetura que apresentou melhor desempenho foi a com 12 neurônios na camada de entrada, 20 na intermediária e um na saída. O autor utilizou redes do tipo MLP com os neurônios da camada intermediária com função de ativação sigmóide e da de saída a função linear. O autor concluiu que é possível realizar o treinamento de uma RNA que utilize o retro propagação de erro com poucos dados, desde que estes sejam representativos para o espaço amostral e que a rede tenha sido devidamente modelada. Bravo et al. (2001) e Sarmiento (1996) diferente de Batista (2009) criticam o uso de uma grande quantidade de neurônios na camada intermediária.

GOMES et al.(2010) realizaram o estudo de previsão de vazão para 12 dias à frente da área a montante do reservatório Três Marias, no rio São Francisco. Foram utilizadas RNAs do tipo MLP e redes neurais compostas com blocos de regressões sigmóides não-lineares (NSRBN) para serem comparadas aos resultados do modelo estocástico PREVIVAZ. Para a MLP foi utilizado o algoritmo de treinamento supervisionado Levenberg-Marquardt com pesos iniciais gerados aleatoriamente e foi utilizado comoo dados de entrada a precipitação média sobre a bacia estudada. Na camada intermediária utilizou-se a função de transferência tangente-sigmóide e na camada de saída uma função linear. Para avaliar o desempenho utilizado apenas o erro médio relativo (EMR) na forma de porcentagem e as redes MLP com melhores resultados alcançaram o valor de 36,7 %. As pesquisadoras chegaram à conclusão que para previsões diárias a rede neural do tipo MLP obteve melhor desempenho que a NSRBN, já em comparação com o modelo PREVIVAZ, ambas as redes obtiveram melhor aproximação com os valores reais observados.

MACHADO (2005) em sua dissertação de mestrado faz previsões de vazão em escala mensal para bacia hidrográfica do rio Jangada, no estado do Paraná. Em sua pesquisa ele utiliza como dados de entrada a precipitação média, evapotranspiração potencial e vazão média mensal no mês anterior. Todas as redes elaboradas neste estudo tem três camadas, com a função de ativação na camada intermediária sendo a sigmóide e a da de saída a função linear. No estudo foram criados modelos em que variou-se o número de neurônios na camada de entrada entre 2 e 8, na camada intermediária esse variação foi entre 3 e 10. A análise do desempenho foi feito calculando-se o EMR na forma de porcentagem, coeficiente de correlação (R) e o erro

médio quadrático. O autor fez comparações em função do número de neurônios na camada intermediária e sim com o número de interações durante o treinamento e total de pesos e bias. A melhor, segundo o autor, foi a que obteve 30 interações e 57 pesos e bias.

SANTOS et al. (2003) estudaram o uso de redes neurais artificiais aplicada a previsão de vazões diárias com o intuito de integrar um sistema de alerta e emergência da bacia hidrográfica do rio Tamanduateí em São Paulo. Nesse estudo foram criados dois modelos de redes, o primeiro utiliza apenas dados de chuva média e acumulada e o segundo utiliza apenas a vazão do dia anterior. Foi utilizado o algoritmo de treinamento “*linear least squares simplex*” (LLSSIM) que é um algoritmo híbrido do tipo *feedforward*. A arquitetura das redes foi elaborada com três camadas e na intermediária variou-se o número de neurônios entre 1 e 20. O desempenho para os modelos que utilizaram apenas informações referentes a precipitação foi em média 0,35 para o coeficiente de determinação ( $R^2$ ), já para as redes que utilizaram dados de vazão esse valor ficou acima de 0,936.

LUNGU (apud ANMALA et al., 2000) analisou o processo de transformação de chuva em vazão na bacia hidrográfica de Botswana na África em escalas diárias, mensais e anuais. Ele concluiu que a previsão em escala mensal deve-se considerar processos do ciclo hidrológico tanto a longo quanto a curto prazos, facilitando a elaboração de uma RNA precisa.

É apresentado a seguir a tabela 2 que apresenta uma comparação resumida entre alguns estudos consultados ao longo desta pesquisa.

SOUSA et al. (2010) em seu trabalho sobre a utilização de redes neurais artificiais para previsão de vazão na bacia hidrográfica do rio Piancó indicaram a divisão dos dados para as etapas de treinamento, validação e verificação nas proporções de 60%, 20% e 20% respectivamente.

BRAVO et al. (2008) e GOMES et al. (2010) fazem referência a necessidade de realizar estudos estatísticos de análises de correlação como metodologia para determinação das variáveis preditoras a serem utilizadas pelas redes neurais.

Tabela 2 – Comparação entre literaturas

Autor	Área de estudo	Escala de Previsão	Tipo de rede	Melhor desempenho
SOUSA(2010)	Bacia hidrográfica do rio Piancó	1 mês	MLP	$R^2 = 0,94$
GOMES(2010)	Montante do reservatório de Três Marias	12 dias	MLP	EMR = 36,3%
MACHADO (2005)	Bacia hidrográfica do rio Jangada	1 mês	MLP	$R^2 = 0,83$
SANTOS et al (2003)	Bacia do rio hidrográfica Tamanduateí	1 dia	MLP	$R^2 = 0,936$
JAYAWARDENA (2001)	Bacia do rio Chao Pheaya (Tailândia)	7 dias	MLP	$R^2 = 0,623$
IMRIE (2000)	Bacia hidrográfica do rio Trent (Reino Unido)	Diária	MPL	$R^2 = 0,944$

Em relação às variáveis de entrada, é possível em alguns casos melhorar o desempenho de uma RNA apenas fazendo a escolha das variáveis corretas, para isso deve-se fazer análises estatísticas de correlação múltipla (MAIER e DANDY, apud BRAVO et al, 2008). Outros estudos sugerem abordagens mais complexas e elaboradas que permitem a determinação de relações não lineares entre as variáveis como foi o caso de BOWDEN et al (2005) que para isso utilizou de um sistema que combina *Partial Mutual Information* com *Self Organizing Map*. Já STOKELJ et al. (2002) sugeriu a análise de componentes principais e de espectro singular para determinação das variáveis de entrada (BRAVO et al, 2008).

### 3 – METODOLOGIA

#### **3.1 – Área de estudo**

O estudo foi concebido para a bacia hidrográfica do rio Ji-Paraná. Situada no estado de Rondônia, tem área aproximada de 75.400 km<sup>2</sup>, sendo tal rio um dos afluentes do rio Madeira, na Amazônia.

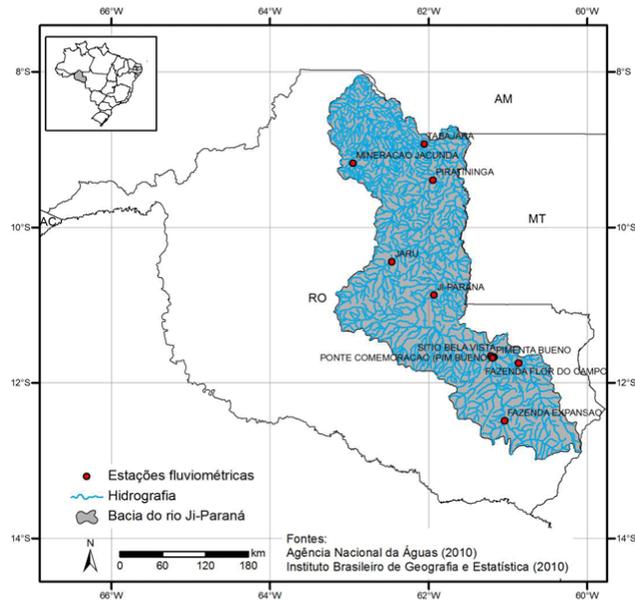


Figura 7 – Localização da bacia hidrográfica do rio Ji-Paraná no estado de Rondônia

O rio Ji-Paraná, popularmente conhecido como rio Machado, tem a segunda mais importante bacia hidrográfica do estado, sua nascente ocorre na região sudoeste de RO e tem sua foz no norte do estado onde encontra o rio Madeira. O rio Ji-Paraná é formado pela junção dos rios Comemoração ou Melgaço com o Apediá ou Pimenta Bueno, cuja confluência ocorre nas proximidades da cidade de Pimenta Bueno. Os afluentes, que dão origem ao rio estudado, têm suas nascentes na Chapada dos Parecis, no município de Vilhena. Os maiores afluentes do rio Ji-Paraná estão na margem esquerda e os principais são os rios Rolim de Moura, Muqui, Urupá, Jaru, Anari, Machadinho e Rio Preto.

O rio estudado possibilita, em alguns trechos, a navegação, servindo de via de escoamento da produção agrícola que ocorre ao longo do seu percurso, porém isso ocorre de maneira muito limitada, pois ao longo de sua rota existem cerca de 50 cachoeiras. Entre os meses de dezembro e março, o rio Ji-Paraná passa pelo período de cheia, nos meses fora deste intervalo ocorre estiagem e em algumas regiões o volume do rio diminui ao ponto de aflorar grandes maciços rochosos que permitem a transição de pessoas entre as margens. A figura 2 apresenta o comportamento da precipitação pluviométrica no período estudado.

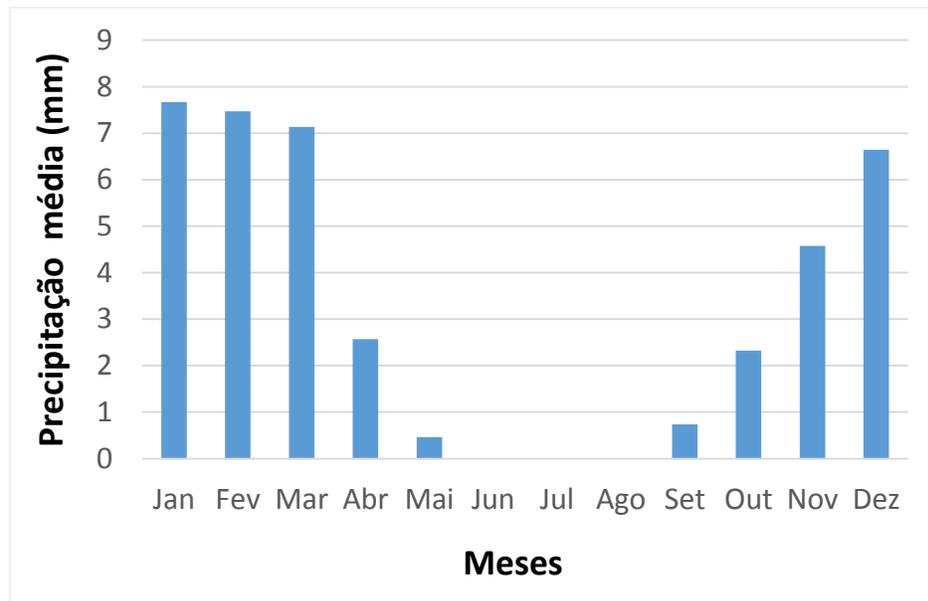


Figura 8 – Distribuição da precipitação pluvial média mensal (1998/2005) na bacia hidrográfica do rio Ji-Paraná

A bacia do rio Ji-Paraná foi escolhida por possuir uma boa densidade espacial de postos pluviométricos e fluviométricos, que fornecem uma série histórica de longa duração, e porque já é alvo de estudo do grupo de pesquisa ao qual este trabalho está vinculado, podendo-se usufruir de esforços anteriores quanto à seleção, preparação e análise dos dados necessários para este trabalho.

A cidade de Ji-Parana localizada as margens do rio com o mesmo nome sofre recorrentemente com problemas de cheia do mesmo. O problema mais recente que pode-se citar foi o cancelamento das festividades populares de carnaval deste ano de 2015, a medida tomada pela prefeitura visava economia de recursos públicos em caso da cidade ser atingida por novas enchentes (FERNANDES, 2015).

### 3.1.1 – Divisão da bacia hidrográfica do rio Ji-Paraná

A divisão utilizada para a bacia hidrográfica do rio Ji-Paraná foi feita em função da disponibilidade de dados pluviométricos e fluviométricos, segundo critérios e necessidades do estudo anterior de modelagem hidrológica distribuída desenvolvido para esta pesquisa (PAZ et al., 2011). Tal divisão da bacia foi adotada para este trabalho. A figura 8 apresenta a divisão da bacia hidrográfica estudada.

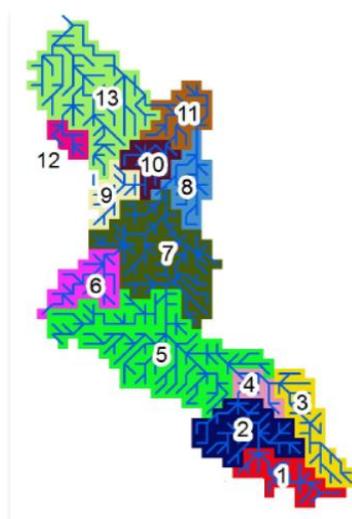


Figura 9 – Divisão da bacia hidrográfica do rio Ji-Paraná em 13 sub-bacias (a denominação das sub-bacias é apresentada na Tabela 2). Fonte: Paz et al (2011) adaptado.

A área estimada e o nome referente a cada sub-bacia do rio Ji-Paraná segue na tabela 3.

Tabela 3 – Áreas e nomes das sub-bacias

<b>Sub-bacia</b>	<b>Nome</b>	<b>Área (km<sup>2</sup>)</b>
Sub-bacia 01	Fazenda Expansão	3735,01
Sub-bacia 02	Cachoeira Primavera	6034,51
Sub-bacia 03	Fazenda Flor Campo	4828,47
Sub-bacia 04	Sítio Bela Vista	1692,40
Sub-bacia 05	Ji-Paraná	16585,40
Sub-bacia 06	Jauru	3882,65
Sub-bacia 07	São Mateus	11051,42
Sub-bacia 08	Buenos Aires	3529,67
Sub-bacia 09	União	2433,49
Sub-bacia 10	Piratininga	2557,58
Sub-bacia 11	Tabajara	3658,61
Sub-bacia 12	Mineradora Jacunda	1340,60
Sub-bacia 13	Norte da Bacia Ji-Paraná	12812,72

## **3.2 – Aplicação das redes neurais artificiais**

### **3.2.1 Visão Geral**

A metodologia para o desenvolvimento deste estudo foi dividido em seis etapas: (1) definição da variável de predição; (2) definição das variáveis de entrada ou preditoras; (3) escolha do tipo de RNA; (4) divisão e pré-processamento dos dados; (5) treinamento da RNA; (6) avaliação de desempenho da RNA. Os dados disponíveis e as etapas de aplicação das RNAs são descritas nos itens a seguir.

### **3.2.2 – Dados disponíveis**

Os dados de precipitação utilizados no presente estudo foram obtidos através de pesquisas anteriores em PAZ et al (2011) e PAZ et al (2013). Nessas pesquisas os dados diários de 36 pluviômetros foram coletados do banco de dados da Agência Nacional de Água (ANA) e foram interpolados pelo método do inverso do quadrado da distância para obter a chuva média sobre cada sub-bacia. Para este trabalho foram utilizadas essas séries de chuva média, conseqüentemente sem ocorrência de falhas nas séries.

As informações referentes à vazão afluente de cada sub-bacia apresentada no item 3.1.1 por muitas vezes apresenta falhas, sendo assim visando maior aproveitamento possível de dados foram utilizados os resultados obtidos pelo modelo hidrológico distribuído MGB-IPH, que foi previamente calibrado e validado para a bacia estudada. PAZ et al (2013) descrevem toda a metodologia deste processo e apresentam que os resultados de ajuste indicaram que o coeficiente Nash-Sutcliffe variou de 0,68 a 0,95 e o erro de volume ficou inferior a 0,9%.

No total foram utilizados 2922 dados de precipitação e vazão diária correspondendo ao período de 01/01/1998 até 31/12/2005.

### **3.2.3 – Definição da variável de previsão**

A variável de predição deste trabalho foi escolhida sendo a vazão no exutório da bacia hidrográfica do Rio Ji-Paraná, já o horizonte de tempo à frente do instante do dia da previsão foi determinado por meio de análises estatísticas de correlação linear simples.

Inicialmente, foi feito um agrupamento espacial das sub-bacias em quatro grupos, sendo o primeiro formado pela união da sub-bacia 1 (Fazenda Expansão) até a 5 (Ji-Paraná), o segundo grupo dado pela união da sub-bacia 6 (Jauru) até a 8 (Bueno Aires), e o terceiro grupo referente à união da sub-bacia 9 (União) até a 12 (Mineradora Jacunda) e o quarto constituído apenas pela sub-bacia 13 (Norte da Bacia Ji-Paraná). Esse agrupamento foi feito dessa forma a fim de evitar o uso da precipitação individual sobre cada uma das trezes sub-bacias, dessa forma podendo reduzir a necessidade de uma camada de entrada com um número elevado de neurônios. Outro motivo para escolha desse procedimento foi a necessidade de se ter informações sobre a precipitação na bacia drenante ao ponto de previsão, que pudesse representar diferentes tempos de contribuição e regimes de chuva.

Foram feitas duas abordagens para o cálculo das correlações lineares simples, a primeira utiliza para o cálculo os dados na sua unidade convencional, ou seja, precipitação em mm e vazão em m<sup>3</sup>/s e na segunda, visando ajudar na identificação de padrões de correlação, as informações de precipitação média de cada grupo descrito anteriormente e a vazão a jusante da sub-bacia 13 foram expressos na forma de anomalia segundo a equação 3:

$$na = \frac{Z - \mu}{S} \quad (3)$$

onde  $na$  é o valor na forma de anomalia;  $Z$  é o dado a ser expresso na forma de anomalia;  $\mu$  é a média dos valores do conjunto dos dados;  $S$  é o desvio padrão dos valores do conjunto dos dados.

Em seguida para as duas abordagens apresentadas foram feitas as correlações lineares simples, realizando defasagens sequenciais de um dia, e com esses resultados foram gerados gráficos com a finalidade de determinar a correlação máxima e conseqüentemente o horizonte de previsão a qual as redes neurais iriam trabalhar, como mostrado nas figuras 10 e 11.

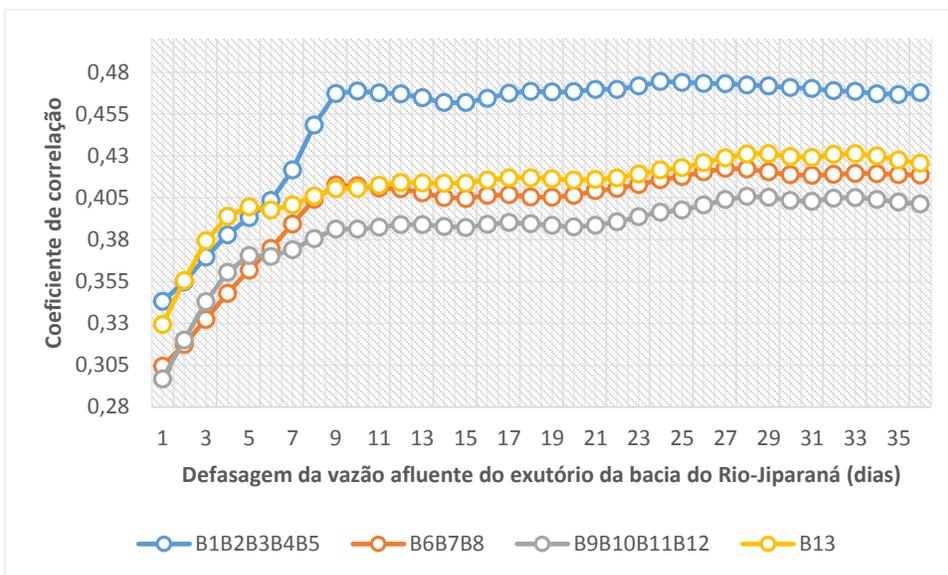


Figura 10 - Coeficiente de correlação entre a precipitação média dos diferentes agrupamentos das sub-bacias com a vazão afluyente da sub-bacia 13.

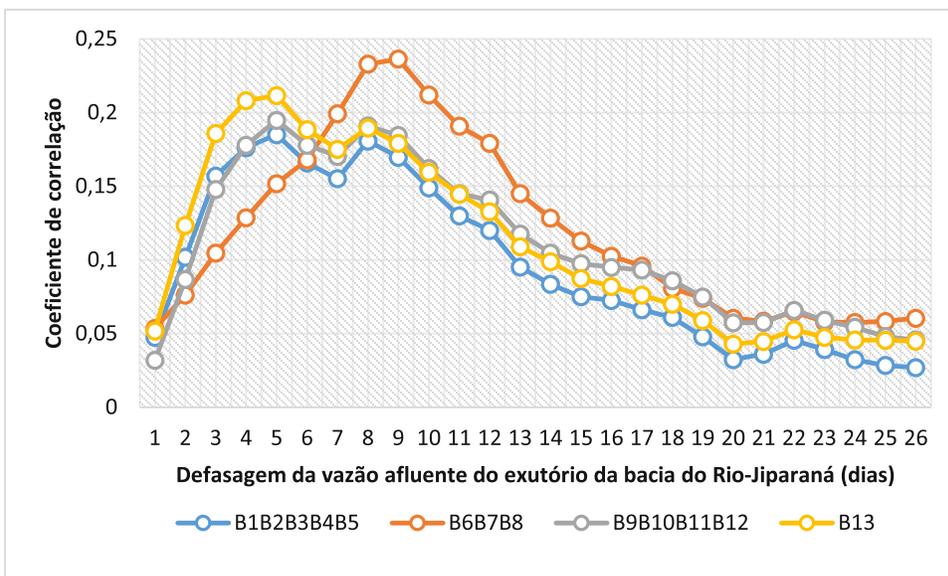


Figura 11 - Coeficiente de correlação para os dados na forma de anomalia entre a precipitação média dos diferentes agrupamentos das sub-bacias com a vazão afluyente da sub-bacia 13.

Como ilustrado na figura 9, para todos os agrupamentos de sub-bacias a correlação cresce com a defasagem do tempo alcançando seu ponto máximo entre o quinto e oitavo dia. Com base nestas informações foi adotado que o horizonte de previsão é defasagem de sete dias à frente do instante de previsão. Na nomenclatura utilizada  $t$  representa o dia a qual se realiza a previsão e  $t+7$  como o dia em que a vazão é prevista.

### **3.2.4 - Definição das variáveis preditoras**

Para a definição das variáveis de entrada, optou-se por uma metodologia mais prática que conseguisse identificar as variáveis mais influentes sem a necessidade de cálculos mais complexos. Procurou-se encontrar variáveis preditoras ou de entrada que tivesse alto grau de correlação com vazão a jusante da sub-bacia 13. Para isso foram refeitas as análises estatísticas de correlação linear simples, porém, dessa vez, foram geradas séries de precipitação acumulada em períodos de tempo variando de t-1 (precipitação acumulada de um dia) até t-12 (precipitação acumulada de doze dias) para todos os agrupamentos das bacias e ainda foram criados outros dois grupos, um formado pela união da sub-bacia um até a oito e o outro correspondente à junção espacial da sub-bacia nove até a treze. Em seguida foi feita a correlação entre essas variáveis e a vazão no exutório da sub-bacia 13 para o instante de tempo t+7. Os resultados são apresentados na figura 12.

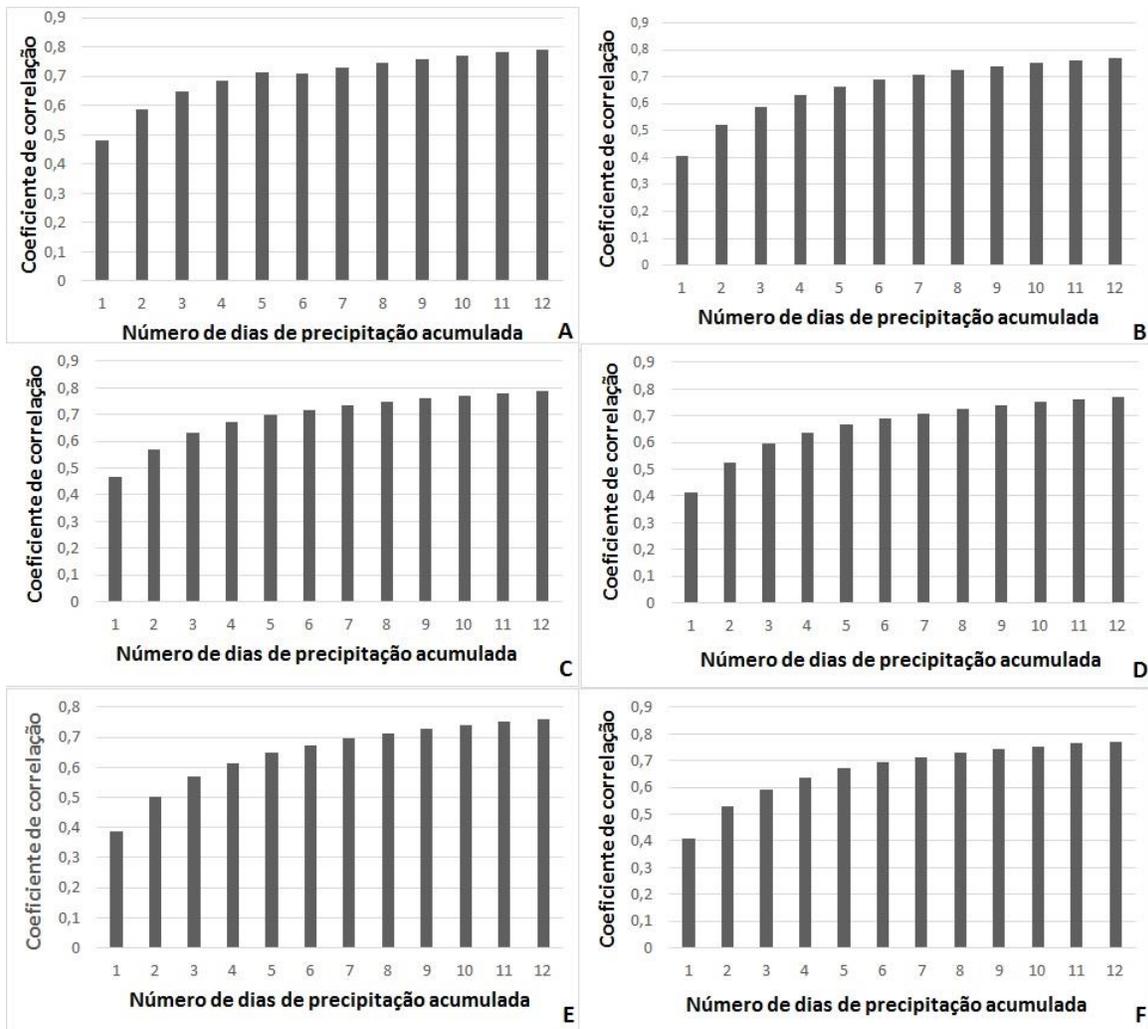


Figura 12- - Coeficiente de correlação entre chuva acumulada em diferentes períodos de tempo e a vazão afluente a sub-bacia 13 sete dias a frente, considerando a chuva que ocorre sobre diferentes áreas: a) Sub-bacia 1 até a 8; b) Sub-bacia 9 até a 13; c) Sub-bacia 1 até a 5; d) Sub-bacia 6 até a 8; e) Sub-bacia 9 até a 12; f) Sub-bacia 13.

Como representado na figura 9, o coeficiente de correlação entre a precipitação média (nos agrupamentos) diária acumulada e a vazão afluente da sub-bacia 13 no instante de tempo  $t+7$  aumenta com o período de acumulação, mantendo uma certa tendência a partir da acumulação para sete dias. Com isso, foi determinado que a variável preditora relacionada à precipitação acumulada é aquela referente ao intervalo de tempo de sete dias anteriores ao instante  $t$  de previsão.

### **3.2.5 – Configurações testadas**

Foram desenvolvidos seis modelos de rede neural artificial, cada um deles contendo seis variações em função do número de neurônios na camada intermediária. Os conjuntos de dados foram divididos em três grupos para cada uma das etapas de aprendizagem de uma RNA, sendo destinados 60% dos dados para o treinamento. Já as etapas de validação e verificação receberam cada uma 20% dos dados disponíveis. Essa divisão é feita dessa forma para viabilizar a utilização da validação cruzada como critério de parada durante o treinamento.

Os pesos são ajustados apenas em função do conjunto de dados do treinamento, gerando a necessidade de ter maior parte dos dados disponíveis. A alteração dos pesos é finalizada quando o erro no conjunto de validação alcança um valor mínimo pré-estabelecido que para este trabalho foi de 0,001. Também foi fixado que o número máximo de interações no treinamento igual a dez mil.

A divisão dos dados seguiu uma ordem temporal, como ilustra a figura 13, onde é exibido hidrograma da sub-bacia 13 com a divisão dos dados

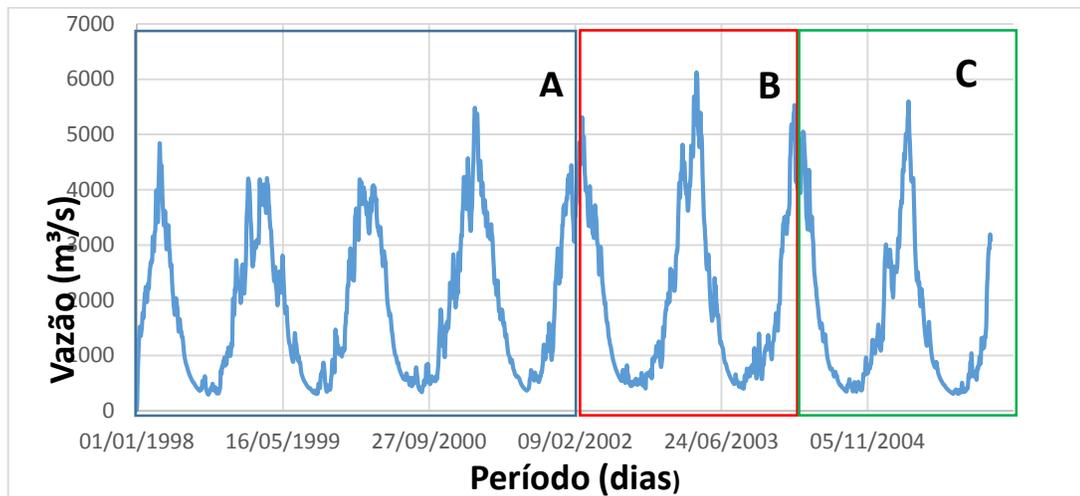


Figura 13 - Hidrograma da sub-bacia 13 com a divisão usada para os dados: A) Treinamento; B) Verificação; C) Validação.

Todas as RNAs desenvolvidas são do tipo *perceptron* de multicamada com o algoritmo de treinamento sendo *Scaled conjugate gradiente* (Gradiente escalado conjugado) que é uma variação do retropropagação do erro (*error backpropagation*). Com este algoritmo, a atualização dos pesos e bias é feita de acordo com o valor do gradiente escalado conjugado que é encontrada por meio do cálculo das derivadas de segunda

ordem da função de ativação durante o treinamento, como forma de orientação para o processo de otimização dos valores dos pesos e bias.

As funções de ativação utilizadas são sigmóide logarítmica (variação entre zero e um) e linear, para a camada intermediária e linear respectivamente. As equações das funções de ativação utilizadas são apresentadas a seguir:

$$\text{logsig}(n) = \frac{1}{1+e^{-n}} \quad (4)$$

$$\text{linear}(n) = n \quad (5)$$

A função de ativação sigmóide logarítmica é uma das mais utilizadas na elaboração de redes neurais artificiais, sendo definida como uma função estritamente crescente, que apresenta um bom equilíbrio entre o desempenho linear e não-linear.

### **3.2.6 – Arquitetura da rede neural artificial**

Além da definição das variáveis preditoras, a elaboração da arquitetura de uma RNA influencia na capacidade do modelo em simular a bacia hidrográfica estudada. Todas as redes desenvolvidas neste trabalho têm três camadas (uma de entrada, uma intermediária e uma de saída) e em sua última camada com apenas um neurônio. O número de neurônios na camada de entrada é tomado como igual ao número de variáveis preditoras consideradas em cada situação e na intermediária é determinado independentemente para cada rede desenvolvida.

Sendo assim, foram criados dois grupos de redes neurais artificiais, o primeiro deles apresenta quatro neurônios na camada de entrada, o segundo grupo utiliza seis neurônios na camada de entrada. Dentro de cada um destes grupos foram criados três subgrupos de RNA distintos com diferentes variáveis preditoras.

O número de neurônios na camada intermediária foi determinado variando em cada subgrupo de rede, iniciando-se com três neurônios até o total de dezoito alternando-os de três em três, assim neste estudo foram totalizadas trinta e seis redes neurais artificiais. Todas as RNAs foram criadas e treinadas utilizando a *Neural Network toolbox* do software MATLAB. Os subgrupos de um a três tem seis neurônios na camada de entrada e o de quatro a seis tem quatro. A definição das variáveis preditoras de cada um dos subgrupos é feita a seguir na tabela 4:

Tabela 4 – Divisão dos subgrupos

Grupo	Subgrupo	Variáveis Predictoras	
		Chuva média	Chuva Acumulada (7 dias)
06	01	B1 até B5; B6 até B8; B9 até B12; B13	B1 até B8 ; B9 até B13
06	02	B1 até B8 ; B9 até B13	B1 até B5; B6 até B8; B9 até B12; B13
06	03	B1 até B8; B9 até B13; B13	B1 até B8; B9 até B13; B13
04	04	B1 até B5; B6 até B8; B9 até B12 ; B13	-
04	05	B1 até B8 ; B9 até B13	B1 até B8 ; B9 até B13
04	06	-	B1 até B5; B6 até B8; B9 até B12 ; B13

### **3.2.8 – Medidas de desempenho**

Para a análise do desempenho dos resultados obtidos pela simulação das redes neurais foram utilizados três medidas de desempenho: Coeficiente de Nash-Sutcliffe (eq. 6) (CE); Erro médio absoluto (EMA) (eq. 7); Erro médio relativo (EMR) (eq. 8) e Coeficiente de determinação ( $R^2$ ).

$$CE = 1 - \frac{\sum_{i=1}^N (Q_{obi} - Q_{cali})^2}{\sum_{i=1}^N (Q_{oi} - Q_{obmed})^2} \quad (6)$$

$$EMA = \frac{1}{N} \sum_{i=1}^N |Q_{cali} - Q_{obi}| \quad (7)$$

$$EMR = \frac{1}{N} \sum_{i=1}^N |Q_{cali} - Q_{obi}| x \frac{1}{Q_{obi}} \quad (8)$$

$$R^2 = \frac{\sum_{i=1}^N (Q_{obi} - Q_{obmed}) x (Q_{cali} - Q_{calmed})}{[\sum_{i=1}^N (Q_{obi} - Q_{obmed})]^{0,5} x [\sum_{i=1}^N (Q_{cali} - Q_{calmed})]^{0,5}} \quad (9)$$

onde  $Q_{cali}$  é o valor previsto;  $Q_{obi}$  é o valor observado;  $Q_{obmed}$  é o valor médio dos valores observados do conjunto de verificação;  $Q_{calmed}$  é o valor médio dos valores observados do conjunto de verificação e  $N$  é o número de valores do conjunto de verificação.

### **3.2.9 – Normalização dos dados**

Em um neurônio artificial, o estímulo para a função de ativação é a combinação linear de todos os sinais que chegam até o mesmo neurônio. Porém, com exceção da função linear, todas as outras funções apresentam restrições quanto a saída gerada no

neurônio artificial. Em geral, as funções não produzem valores superiores a 1 e inferiores a -1.

Como o caso estudado apresenta variáveis fora deste intervalo, foi necessário realizar um processo de normalização dos dados, que consiste em uma transformação de uma escala real para uma escala compatível com a função de ativação utilizada. Como dito anteriormente, a função de ativação escolhida para os neurônios da camada intermediária ou escondida foi a sigmóide e para esta função todas as respostas são positivas. Em recursos hídricos, respostas negativas em RNA's são geralmente incoerentes com a realidade física dos problemas estudados. A normalização dos dados foi feita seguindo a recomendação de BRAVO et al. (2008) com a equação 6:

$$x_{norm} = 0.1 + 0.8x \left( \frac{x_{real} - x_{min}}{x_{max} - x_{min}} \right) \quad (10)$$

onde  $x_{norm}$  e  $x_{real}$  correspondem respectivamente a variável normalizada e seu valor real,  $x_{max}$  e  $x_{min}$  representam o maior e o menor valor que a variável a ser normalizada pode alcançar. Todas as variáveis de entrada passam pelo processo de normalização antes de serem introduzidos nas etapas de aprendizado das RNA's e ficam padronizadas no intervalo de 0,1 a 0,9.

### **3.2.10 – Nomenclatura da rede neural artificial**

A nomenclatura utilizada é padrão para todas as redes neurais desenvolvidas neste estudo e foi feita de tal forma que se possa identificar suas principais características apenas analisando o seu código. A nomenclatura é formada por doze caracteres, dos quais seis são letras e seis são números. As letras utilizadas significam informações da camada de entrada e intermediária, além do grupo à qual as variáveis preditoras pertencem sendo representada da seguinte forma: (1) CE (Camada de entrada); (2) SG (Subgrupo); (3) CS (Camada escondida). Por exemplo, uma rede com a nomenclatura CE06SG04CS06 é uma rede com seis neurônios na camada de entrada em que as variáveis preditoras pertencem ao subgrupo 4 e a camada escondida tem seis neurônios.

## 4 – RESULTADOS E DISCUSSÕES

O desempenho dos modelos das redes neurais testadas para a previsão de vazão para t+7 no exutório da bacia hidrográfica do rio Ji-Paraná segue nas figuras 14 e 15 e na tabela 5. Pode-se observar que a quantidade de neurônios na camada intermediária influenciou no desempenho das redes neurais testadas, mas os diferentes tipos de variável preditora foi o que teve maior peso nos resultados finais gerados pelas redes.

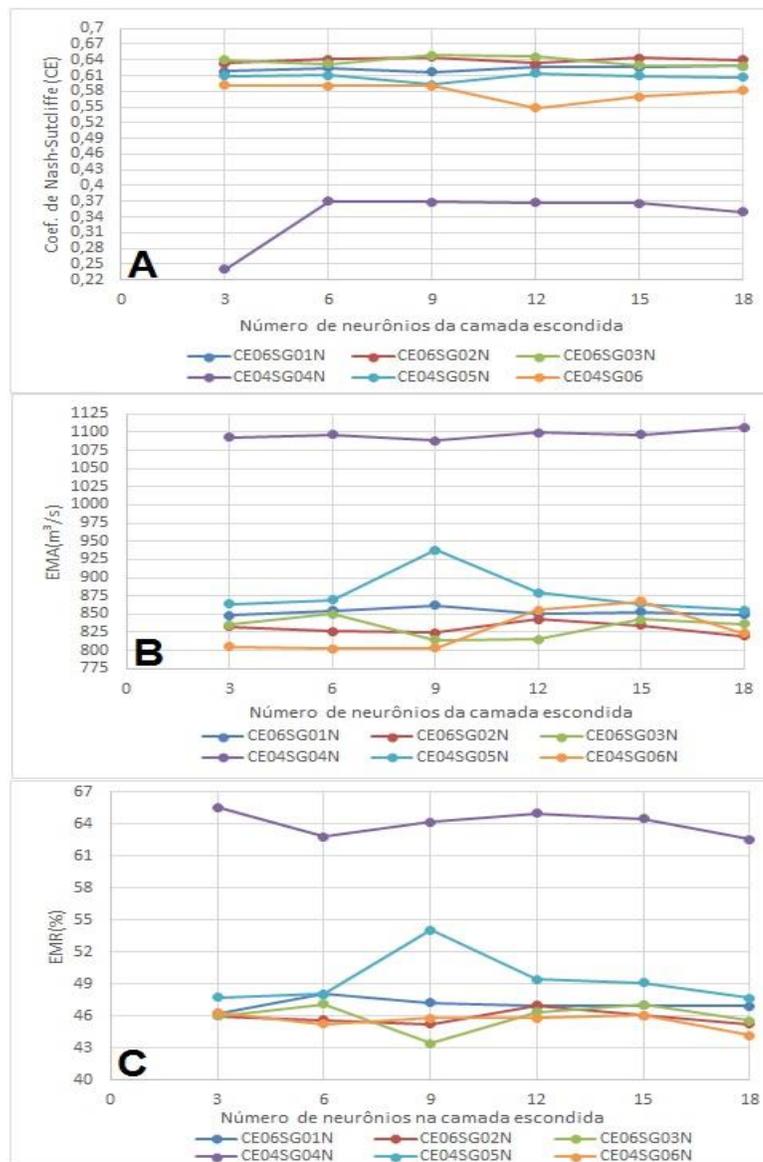


Figura 14 - Medidas de desempenho de todos os grupos.

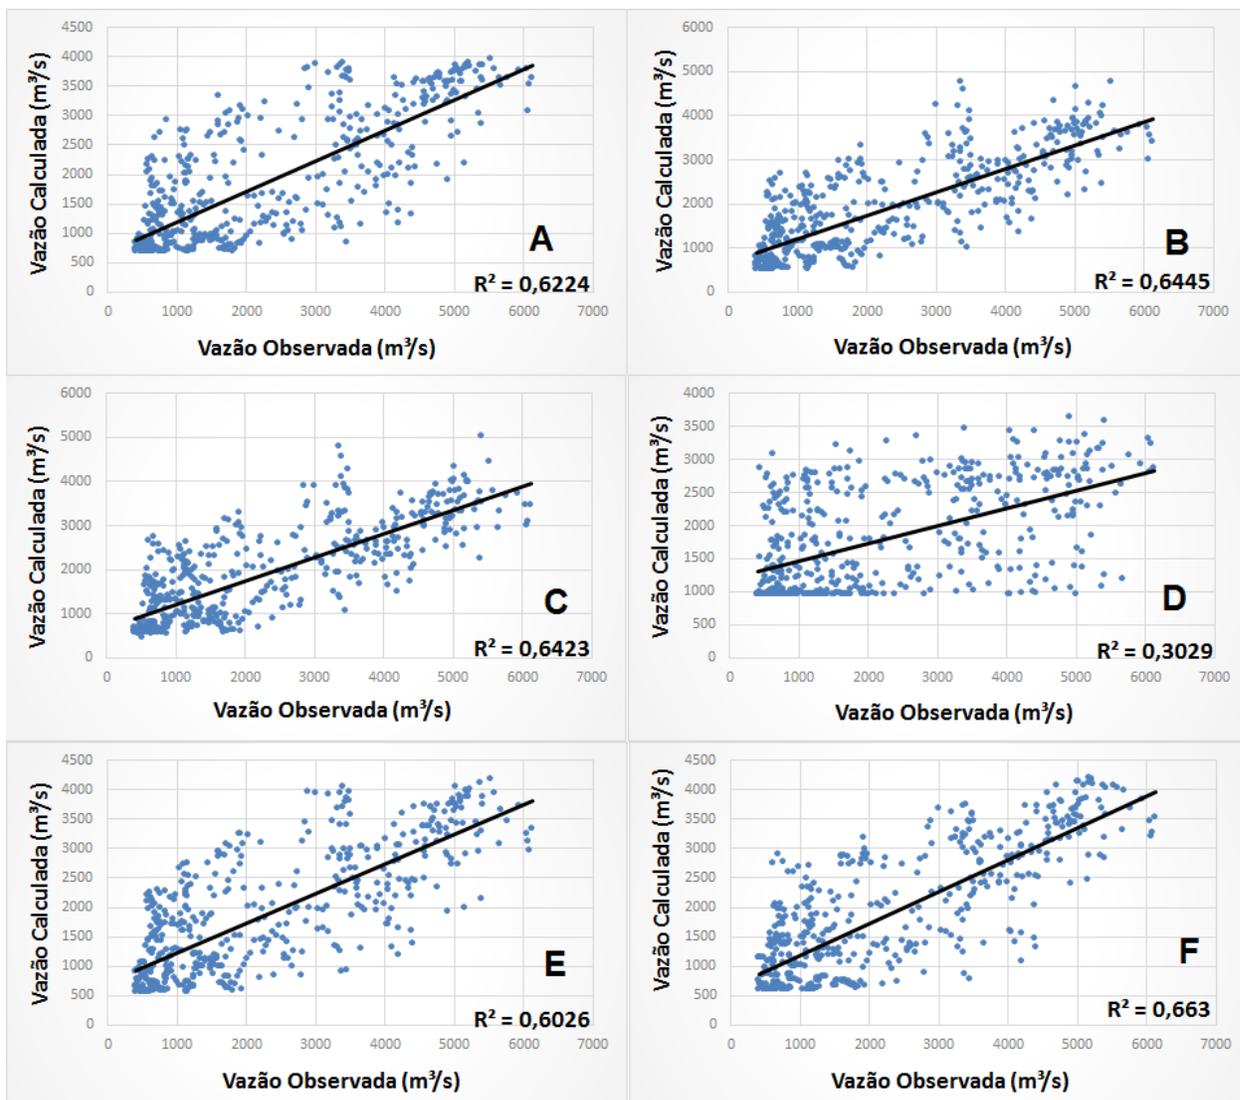


Figura 15 - Gráfico de dispersão da rede com melhor desempenho para cada subgrupo: A) CE06SG01N03; B) CE06SG02N18; C) CE06SG03N09; D) CE04SG04N09; E) CE04SG05N03; F) CE04SG06N06.

Tabela 5– Medidas de desempenho

Código	CE	EMA	EMR
CE06SG01N03	0,62	848,60	46,24
CE06SG01N06	0,62	855,04	48,07
CE06SG01N09	0,62	862,51	47,25
CE06SG01N12	0,63	850,30	46,93
CE06SG01N15	0,63	853,26	46,96
CE06SG01N18	0,63	849,15	46,91
CE06SG02N03	0,63	832,76	45,96
CE06SG02N06	0,64	826,21	45,59
CE06SG02N09	0,64	824,71	45,21
CE06SG02N12	0,63	843,21	47,01
CE06SG02N15	0,64	834,79	46,03
CE06SG02N18	0,64	820,07	45,20
CE06SG03N03	0,64	835,41	45,95
CE06SG03N06	0,63	850,10	47,07
CE06SG03N09	0,65	814,43	43,40
CE06SG03N12	0,65	814,95	46,36
CE06SG03N15	0,63	842,89	47,03
CE06SG03N18	0,63	836,86	45,54
CE04SG04N03	0,24	1092,86	65,58
CE04SG04N06	0,37	1096,37	62,82
CE04SG04N09	0,37	1087,88	64,16
CE04SG04N12	0,37	1099,16	65,00
CE04SG04N15	0,37	1096,48	64,49
CE04SG04N18	0,35	1106,86	62,55
CE04SG05N03	0,61	864,02	47,72
CE04SG05N06	0,61	869,73	48,05
CE04SG05N09	0,59	937,95	54,08
CE04SG05N12	0,61	879,03	49,43
CE04SG05N15	0,61	863,61	49,13
CE04SG05N18	0,61	855,20	47,65
CE04SG06N3	0,59	805,42	46,28
CE04SG06N6	0,59	802,48	45,22
CE04SG06N9	0,59	803,19	45,78
CE04SG06N12	0,55	855,52	45,81
CE04SG06N15	0,57	867,20	46,06
CE04SG06N18	0,58	823,39	44,17

Analisando as redes com quatro neurônios na camada de entrada pode-se notar que o subgrupo 4 foi o que apresentou os piores resultados dentre todas as redes desenvolvidas. Isso pode ser explicado pelo fato das variáveis de entrada serem apenas a chuva média sobre cada agrupamento de bacias e este tipo de informação apresenta uma baixa correlação com a vazão do exutório da sub-bacia 13 (Norte da bacia do Ji-Paraná) quando comparado com a chuva acumulada, isto pode ser verificado analisando as figuras 10 e 11. O desempenho menos satisfatório das redes do subgrupo 4 já era esperado, uma vez que o processo de transformação de chuva em vazão não se dá apenas com a precipitação que incide sobre a bacia em um dia, sendo na verdade resultado da contribuição da pluviosidade de vários outros períodos.

O melhor desempenho para este subgrupo foi para a arquitetura com nove neurônios na camada intermediária, onde foi alcançado para o erro médio absoluto o valor de 1087,88 m<sup>3</sup>/s com as vazões previstas variando em média 64% em relação as vazões observadas e coeficiente de determinação(R<sup>2</sup>) igual a 0,3029, contudo quando se analisa apenas o período menos chuvoso, o EMA cai para 507,31 m<sup>3</sup>/s.

O pior desempenho para as redes com seis neurônios na camada de entrada ficou com o subgrupo 1, que é o que utiliza mais variáveis relacionada a chuva média. Seu desempenho ainda foi superior ao da arquitetura CE04SG04N09 apresentada anteriormente. Dentre as redes do subgrupo 1 os melhores resultados ficaram com a CE06SG01N03 que obteve EMA de 848,6 m<sup>3</sup>/s, erro médio relativo de 46,2% e R<sup>2</sup> de 0,62, quando ainda analisado o período menos chuvoso o erro médio absoluto cai para 457,941 m<sup>3</sup>/s diminuindo em 53,6%.

As arquiteturas que obtiveram o melhor desempenho foram os pertencentes ao subgrupo três e seis que são exatamente as arquiteturas em que foram utilizadas mais variáveis relacionadas à chuva acumulada. O melhor desempenho para o EMA dentre todas as redes foi em CE04SG06N06 com valor de 802,48 m<sup>3</sup>/s que considerando novamente apenas o período menos chuvoso, este valor cai para 433,33m<sup>3</sup>/s representando uma diminuição de cerca de 54%. Já o melhor desempenho para erro médio relativo e coeficiente de Nash-Sutcliffe foi para rede CE06SG03N09 que obteve os valores de 0,6492 e 43,4% respectivamente, além disso obteve o segundo melhor

desempenho para o EMA com 814,43 m<sup>3</sup>/s e 440,53 m<sup>3</sup>/s para o período menos chuvoso. O comparativo entre as vazões previstas com a observada para as redes CE04SCG06N06 e CE06SG03N09 nas etapas de treinamento, validação e verificação segue nas figuras 16 e 17.

Analisando os resultados do coeficiente de determinação apresentados na figura 15, pode-se perceber que o melhor desempenho ficou novamente com a rede pertencente ao subgrupo 6 e os resultados menos satisfatórios ficaram com as redes pertencentes ao subgrupo 4. O R<sup>2</sup> é muito importante na análise de desempenho de um sistema, pois consegue facilmente indicar o quanto determinado modelo se aproxima dos valores desejados, sendo assim é importante se ter uma faixa de valores aos quais se possa classificar a eficiência do modelo desenvolvido. MORIASI et al. (2007) afirmam que, modelos com valores de R<sup>2</sup> acima de 0,5 são aceitáveis, levando isso em consideração apenas o subgrupo 4 não alcançou este patamar.

Entre as duas redes com melhor desempenho comentadas anteriormente é preferível utilizar a CE04SG06N06 para a previsão de vazão no exutório da bacia hidrográfica estudada, uma vez que, apresenta menor número de neurônios na camada intermediária consequentemente melhor capacidade de generalização.

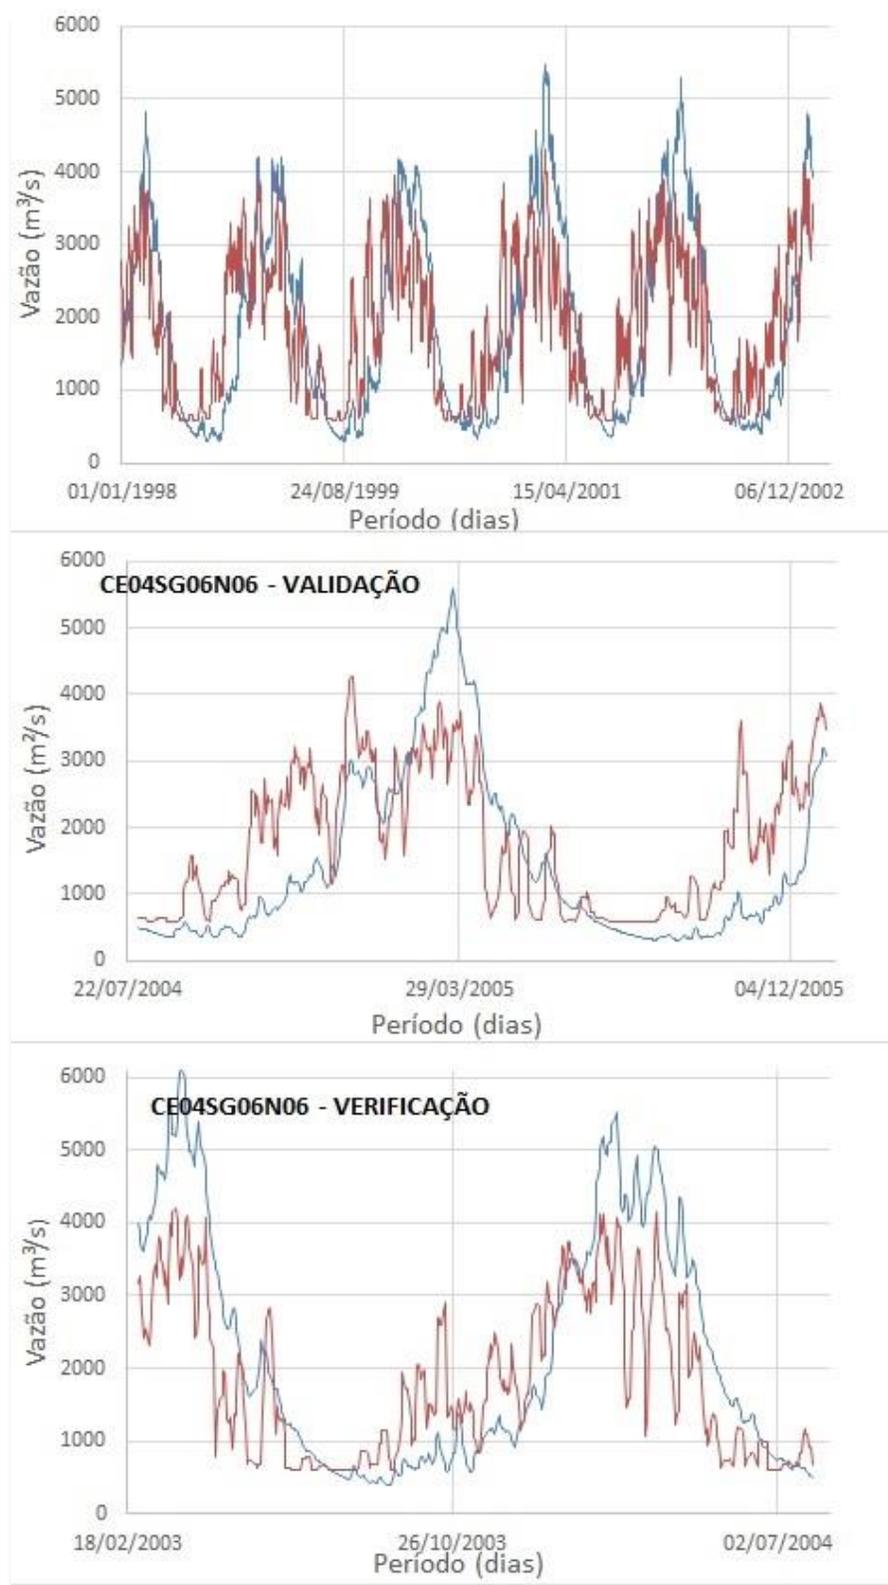


Figura 16 - Vazão prevista pela rede CE04SG06N06. Tracejado azul vazão observada; Tracejado vermelho vazão prevista.

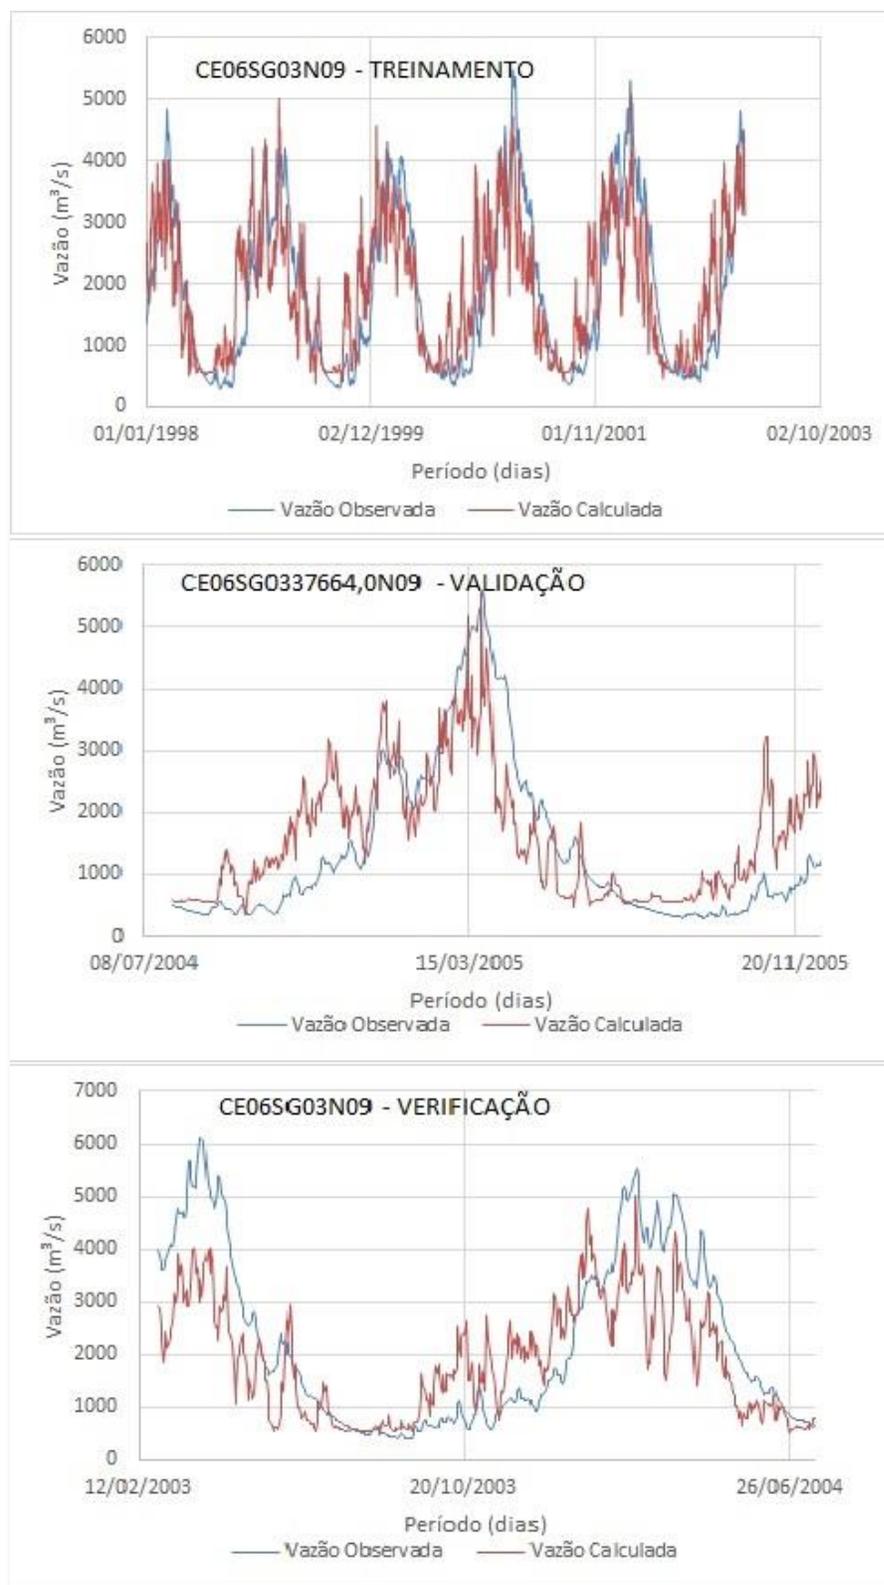


Figura 17 - Vazão prevista pela rede CE06SG03N09. Tracejado azul vazão observada; Tracejado vermelho vazão prevista.

## 5 - CONCLUSÃO

O presente estudo teve como objetivo principal a criação de modelos de previsão de vazão no exutório da bacia do rio Ji-Paraná para um horizonte de sete dias à frente, para isso utilizando redes neurais artificiais.

Ao longo do estudo foram aplicadas metodologias que analisassem as melhores variáveis preditoras para alimentar os neurônios da camada de entrada. Visando criar um sistema de previsão mais independente de outros fatores como medições de vazão, previsões de chuva e variações de temperatura, os modelos criados consideraram variáveis de entrada relacionadas a precipitação média e acumulada sobre as sub-bacias.

Com base nos resultados obtidos percebeu-se que o erro tende a ser maior nas redes em que existem mais dados de entrada relacionados com a chuva média e não a acumulada. Isso mostra que a geração de vazão no exutório da bacia hidrográfica estudada para sete dias à frente está mais correlacionada com a chuva acumulada do que a precipitação média diária, pois o processo de transformação de chuva em vazão depende também de outros fatores como infiltração no solo e perdas por evaporação, sendo assim modelos que consideram o aporte de precipitação de vários outros dias tem melhor capacidade de previsão, uma vez que a geração de escoamento superficial não depende apenas da chuva ocorrida em um dia.

Pode-se perceber também que em geral, as redes com maior número de neurônios na camada intermediária apresentaram desempenho inferior as demais. Isso se deve ao fato destes tipos de arquiteturas terem uma menor capacidade de generalização e, analisando o conjunto de dados da etapa de verificação percebe-se que este apresenta valores de vazão superiores aos encontrados nas etapas de treinamento e validação, conseqüentemente para as redes com maior número de neurônios na camada intermediária torna-se mais difícil a previsão, uma vez que sua capacidade de generalização é inferior.

O desempenho em relação ao coeficiente de determinação das redes neurais artificiais desenvolvidas ao longo deste trabalho apresentaram resultados satisfatórios, mesmo sendo inferiores a outros modelos analisados na revisão bibliográfica, uma vez que, foram apenas utilizadas variáveis relacionadas a chuva no instante  $t$  e acumulada

para t-7 o que dificultou uma maior precisão dentro das previsões. Ainda assim, as medidas de erro quando comparadas apenas para o período menos chuvoso obtiveram melhores resultados, mostrando que as redes tiveram maior dificuldade em prever eventos mais extremos de vazão na bacia hidrográfica estudada.

## 6 – REFERÊNCIAS BIBLIOGRÁFICAS

ANMALA, J.; ZHANG, B.; GOVINDARAJU, R S. Comparison of ANNs and empirical approaches for predicting watershed runoff. *Journal of Water Resources Planning and Management*, Reston: ASCE, v. 126. n.3, p. 156-166, May/June 2000.

BATISTA, André Luiz França. Análise e previsões de vazões utilizando modelos de séries temporais e redes neurais artificiais. 2009. 79p. Dissertação (Mestrado em engenharia de Sistemas) – Universidade Federal de Lavras, Lavras.2009.

BOWDEN, G.J.; DANDY, G.C.; MAIER, H.R. 2005. Input determination for neural network models in water resources applications. Part 1 – background and methodology. *J. Hydrol.*, v 301, p 75–92.

BRAVO, J.M.; Pedrollo, O.C.; Collischonn, W.; Paz, A.R.; Uvo, C.B. Revista Brasileira de Recursos Hídricos, v. 13, p. 77-88, 2008.

BRUMATTI, M. Redes neurais artificiais. Departamento de engenharia elétrica, Universidade Federal do Espírito Santo, Vitória (ES).2005.

COLLISCHONN, W. Simulação hidrológica de grandes bacias. 2001. 182f. Dissertação (Doutorado em recursos hídricos) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre.2001.

CRISTINA, A.O.M; Desenvolvimento de biossensores não invasivos para captação de sinais eletroencefálicos baseados em alginato, com potencial utilização em recém-nascidos.2005. 72f. Dissertação (Mestrado em engenharia biomédica) – Faculdade de Ciências e Tecnologia, Universidade de Coimbra, Coimbra. 2005.

FAVORETO, R. S.; Rohn, M. C.; Mine, M. R. M. A técnica de rede neural artificial aplicada na previsão de vazão. In: Simpósio Brasileiro de Recursos Hídricos e Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa: Gestão de

Recursos Hídricos – O desafio da prática, 5, 2001, Aracaju. Anais... Aracaju: ABRH. CD Rom.

GOMES, Luana Ferreira Costa & MARIA, Suzana Gico Lima Montenegro. Modelo Baseado na técnica de redes neurais para previsão de vazões na bacia do rio São Francisco. Revista Brasileira de Recursos Hídricos, volume 15. 2010.

HAMLET, A. F.; Huppert, D.; Lettenmaier, D. P. Economic value of long-lead streamflow forecasts for Columbia River hydropower. Journal of Water Resources Planning and Management, v.128, n.2, p.91-101, 2002.

HAYKIN, Simon. Redes Neurais. Princípios e prática. Porto Alegre, RS: Bookman, 2001.

HSUGUPTA, H. V.; SOROOSHIAN, S. Artificial neural network modeling of the rainfall runoff process. Water Resources Research. V.31, n.10, p. 2517-2530, Oct. 1995.

JAYAWARDENA, A.W; FERNANDO, T.M.K.G; River flow prediction: na artificial neural network approach. Regional Management of Water Resources. V. 268. 2001.

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

MAIER, H.R.; DANDY, G.C. 1997. Modelling cyanobacteria (blue-green algae) in the River Murray using artificial neural networks. Math. and Comp. in Simulation, v 43, p 377-386.

MOREIRA, I. A. Modelagem hidrológica chuva-vazão com dados de radar e pluviômetros. 2005. 76f. Dissertação (Mestrado em engenharia hidrológica) – Setor de Tecnologia, Universidade Federal do Paraná, Curitiba. 2005.

MORIASI, D. N.; Arnold, J. G.; Liew, M. W. Van; Binger, R. L.; Harmel, R. D.; Veith, T. (2007), Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50, 885-900.

MOORE, R.J.; BELL, V.A.; JONES, D.A. Forecasting for flood warning. Elsevier. 2004

MACHADO, F. W. Modelagem chuva-vazão mensal utilizando redes neurais artificiais. 2005. 129f. Dissertação (Mestrado em recursos hídricos) – Setor de Tecnologia, Universidade Federal do Paraná, Curitiba.2005.

PAZ, A.R.; BUARQUE, D.C.; COLLISCHONN, W.; VICTORIA, D.C.; ANDRADE, R.G. (2011). Discretização de modelos hidrológicos de grande escala: grade regular x mini bacias. In: XIX Simpósio Brasileiro de Recursos Hídricos, Maceió, ABRH.

PAZ, A.R.; MARÇAL, C.L.D.; BAPTISTA, V.S.; VICTORIA, D.C.. Análise de sensibilidade da evapotranspiração anual calculada pelo modelo hidrológico MGB-IPH relativa ao parâmetro capacidade de armazenamento do solo In: XX Simpósio Brasileiro de Recursos Hídricos, 2013, Bento Gonçalves.

PAMELA FERNANDES. Temendo nova cheia, Prefeitura de Ji-Paraná cancela carnaval popular. Disponível em: <http://g1.globo.com/ro/rondonia/noticia/2015/01/temendo-nova-cheia-prefeitura-de-ji-parana-cancela-carnaval-popular.html> >. Acesso em: 14 de fev. 2015.

RUMELHART, D.; HINTON, G.; WILLIAMS, R. Learning representations by backpropagation errors. *Nature*, London, v.323, p.533-536, 1986.

SANTOS, C. C.; PEREIRA, A.J.F. Modelagem hidrológica urbana por meio de redes neurais artificiais: Uma aplicação para a bacia do rio Tamanduateí em São Paulo. *Revista Brasileira de Meteorologia*, vol. 18, no 2, pp. 149-159, 2003.

SARMENTO, F.J. Modelagem de séries hidrológicas através de redes de neurônios. *Revista Brasileira de Recursos Hídricos – RBRH*, vol. 1, no 2, pp. 19-31, 1996.

SILVA, R. M. Redes Neurais Artificiais aplicadas à detecção de intrusão em redes TCP/IP. 2005. 139f. Dissertação (Mestrado em Engenharia Elétrica) – Departamento de engenharia elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro. 2005.

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.

STOKELJ, T.; PARAVAN, D.; GOLOB, R. 2002. Enhanced artificial neural network inflow forecasting algorithm for run-of-river hydropower plants. *J. WaterResour. Plann. Manag.*, v 128, n 6, p 415-423.

TAFNER, M, A., XEREZ M. de, RODRIGUES FILHO, I. W. Redes neurais, introdução e princípios de neurocomputação. Blumenau:EditoraEko, 1996.

TUCCI, C. E. M.; Collischonn, W. Previsão de vazão. In: Tucci, C. E. M.; Braga, B. (org.) *Clima e recursos hídricos no Brasil*. Porto Alegre: ABRH, 2003. p.281-348.

TUCCI, C. E. M., Brun, G., 2001. Previsão em tempo real do volume afluente ao reservatório de Ernestina. In *Revista Brasileira de Recursos Hídricos*. V.6, n.2, p.73 – 79.

TUCCI, C. E. M. Modelos hidrológicos. Porto Alegre: Ed. Da Universidade: ABRH, 1998. 669p.

VON ZUBEN, Fernando José. Redes Neurais Artificiais, Apostila da disciplina Inteligência Artificial em Aplicações Industriais, Unicamp, São Paulo (SP), 39p. 1993.