

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS**

**PROGRAMA DE PÓS-GRADUAÇÃO EM
METEOROLOGIA**



DISSERTAÇÃO DE MESTRADO

Jurandir Ferreira Galdino

**Redes Neurais Artificiais Aplicadas Aos Totais Mensais
Precipitados Para Gerar Vazões Médias Mensais Na Bacia
Hidrográfica Do Rio Paraguaçu**

Campina Grande, Dezembro de 2013



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE-UFCG
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS- CTRN
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS - UACT
PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA - PPGM

DISSERTAÇÃO

**REDES NEURAIAS ARTIFICIAIS APLICADAS AOS TOTAIS MENSAIS
PRECIPITADOS PARA GERAR VAZÕES MÉDIAS MENSAIS NA BACIA
HIDROGRÁFICA DO RIO PARAGUAÇU**

Mestrando: Jurandir Ferreira Galdino

Orientador: Francisco de Assis Salviano de Sousa

Campina Grande

Dezembro 2013

Jurandir Ferreira Galdino

**REDES NEURAIS ARTIFICIAIS APLICADAS AOS TOTAIS MENSAIS
PRECIPITADOS PARA GERAR VAZÕES MÉDIAS MENSAIS NA BACIA
HIDROGRÁFICA DO RIO PARAGUAÇU**

Dissertação apresentada ao programa de Pós-Graduação em Meteorologia da Universidade Federal de Campina Grande em cumprimento às exigências para a obtenção do grau de Mestre em Meteorologia.

Área de Concentração: Meteorologia de Meso e Grande Escala

Subárea: Hidrometeorologia

Orientador: Francisco de Assis Salviano de Sousa

Campina Grande

Dezembro 2013

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

- G149r Galdino, Jurandir ferreira.
 Redes neurais artificiais aplicadas aos totais mensais precipitados para
 gerar vazões médias mensais na bacia hidrográfica do rio Paraguaçu /
 Jurandir Ferreira Galdino. – Campina Grande, 2013.
 61 f. : il. Color.
- Dissertação (Mestrado em Meteorologia) - Universidade Federal de
 Campina Grande, Centro de Tecnologia e Recursos Naturais.
- "Orientação: Prof. Francisco de Assis Salviano de Sousa".
 Referências.
1. Modelagem Hidrológica. 2. Redes Neurais Artificiais. 3.
 Climatologia do Nordeste do Brasil. I. Sousa, Francisco de Assis Salviano.
 II. Título.


CDU 551.58:556.51 (043)

JURANDIR FERREIRA GALDINO

REDES NEURAIS ARTIFICIAIS APLICADAS AOS TOTAIS MENSAIS
PRECIPITADOS PARA GERAR VAZÕES MÉDIAS MENSAIS NA BACIA
HIDROGRÁFICA DO RIO PARAGUAÇU

DISSERTAÇÃO APROVADA EM 20/12/2013


BANCA EXAMINADORA



FRANCISCO DE ASSIS SALVIANO DE SOUSA
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Prof. Dr. CARLOS ANTONIO COSTA DOS SANTOS
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Prof. Dr. RANYERE SILVA NOBREGA
Departamento de Ciências Geográficas
Universidade Federal de Pernambuco

Agradecimentos

Meus sinceros agradecimentos...

Primeiramente a Deus, por ter me dado capacidade e inteligência para concluir este mestrado.

À minha esposa, Rafaelly Gomes Barbosa e Galdino, com quem compartilhei toda elaboração deste trabalho, sem o incentivo dela, hoje eu não estaria aqui.

Aos meus pais, Jose Galdino Fernandes e Aurení de Freitas Fernandes, pelo amor, carinho e incentivo em acreditar no meu potencial. Aos meus irmãos, Juraci Galdino, Josenildo Galdino e Joelma Galdino, que estando ao meu lado em todos os momentos da minha vida, independentemente da situação e das dificuldades, sempre mim incentivaram.

A todos os amigos e colegas da turma do mestrado, pelo companheirismo, atenção, dedicação, apoio e incentivo nos momentos mais difíceis no decorrer do mestrado.

Ao meu orientador Dr. Francisco de Assis Salviano de Sousa, pelo incentivo, paciência e por sempre ter disponibilizado tempo para me ensinar e discutir os trabalhos.

A todos os professores do curso de pós-graduação em Meteorologia da Universidade Federal de Campina Grande, por todos os conhecimentos e experiências transmitidos, que muito contribuíram para a realização de meus trabalhos e que levarei comigo por toda a minha vida.

A CAPES (Coordenação de Aperfeiçoamento do Pessoal de ensino Superior), pelos recursos financeiros concedidos dando condições para realização deste trabalho.

Ao coordenador do Programa de Pós – graduação em Meteorologia Dr. Enilson Palmeira Cavalcanti e a secretária Divanete Rocha da Cruz pelo apoio e amizade.

Enfim, a todos aqueles que participaram de forma direta ou indireta da elaboração deste trabalho, muito obrigado.

Dedicatória

Dedico este trabalho, primeiramente a Deus o grande responsável por essa vitória. A todos meus familiares, em especial a minha esposa Rafaelly, Jose Galdino (pai), Aurení (mãe), Juraci, Joelma e Josenildo (irmãos) pelo carinho, incentivo e compreensão.

Lista de Figuras

Figura 1. Ciclo hidrológico. Fonte: Machado (2005).....	16
Figura 2. Tipo de chuva de acordo com sua formação. Fonte: Machado (2005).....	17
Figura 3. Esquema de um neurônio. Fonte: Dornelles (2007).....	20
Figura 4. Exemplos de arquiteturas. Fonte: Adaptado de (Kröse; Smarg, 1996).....	22
Figura 5. Modelo de RNA <i>feed-forward</i> recursivo com multi-passos.....	22
Figura 6. Célula de rede neural artificial. Fonte: Machado (2005).....	24
Figura 7. Postos pluviométricos e estações fluviométricas da Bacia Hidrográfica do Rio Paraguaçu.	38
Figura 8. Regressão para a previsão de 24 meses em Argoim, utilizando a função de transferência Tansig.....	49
Figura 9. Regressão para a previsão de 24 meses em Argoim, utilizando a função de transferência Logsig.....	50
Figura 10. Regressão para a previsão de 24 meses em Argoim, utilizando a função de transferência Tansig.....	51
Figura 11. Melhor Resultado na RNA.....	55
Figura 12. Dispersão das vazões médias mensais estimadas pela RNA, usando a função de transferência tansig2.....	56
Figura 13. Dispersão das vazões médias mensais estimadas pela RNA, usando a função de transferência logsig.....	57

Lista de Tabelas

Tabela 1 – Funções de transferências e respectivos gráficos.....	26
Tabela 2 - Relação das estações/postos pluviométricos utilizadas no estudo.....	42
Tabela 3 - Teste com diferentes algoritmos de treinamento.....	46
Tabela 4 - Teste com diferentes funções de transferência variando o número de neurônios, incluindo o coeficiente de regressão nas etapas de treinamento, validação e simulação.....	47
Tabela 5 - Análise estatística da precipitação média mensal usada na RNA.....	52
Tabela 6 – Teste da RNA <i>Feed-forward</i> com diferentes algoritmos de treinamento.....	54
Tabela 7 – Desempenho da RNA com base no coeficiente de eficiência (E) e na raiz do erro médio quadrático (REMQ).....	55

Lista de Siglas e Símbolos

Siglas

AB – Alta da Bolívia

AES - Análise de Espectro Singular

Af - Clima tropical chuvoso, sem estação seca

Am - Clima tropical chuvoso de monção, com breve estação seca

ANA - Agência Nacional de Águas.

ADALINE - *ADaptive Linear NEuron* (Neurônio Linear Adaptativo).

APA - Área de preservação ambiental.

ARIMA - Modelo autoregressivo Integrado de Média-Móvel.

Aw - Clima tropical chuvoso de savana, com estação seca de inverno (sub-úmido)

Aw' - Clima tropical chuvoso de savana, com estação seca de outono

Aw'' - Clima tropical chuvoso de savana, com duas estações secas

BA – Bahia

BSh - Clima semiárido

BHRP – Bacia Hidrográfica do Rio Paraguaçu

DPFT- Diferenças Primeiras de Função de Transferência

E – Coeficiente de Eficiência

EMQ - Erro Médio Quadrático

ENOS - El Niño/Oscilação Sul

GMDH - *Group Method of Data Handling*.

INMET - Instituto Nacional de Meteorologia

LTF – Função de transferência linear

MLP - Multilayer Perceptrons

MSE - Erro Médio Quadrático

NEB - Nordeste brasileiro

NSRBN - *Non Linear Sigmoidal Regression Blocks Networks*

OMM - Organização Meteorológica Mundial.

RNA(s) - Rede(s) Neural (is) Artificial (is).

REMQ - Raiz do Erro Médio Quadrático.

R - Coeficiente de Determinação ou regressão

r - Coeficiente de Correlação de Pearson

RR - Rainfall-Runoff

TSM - Temperatura na Superfície do Mar

VCAS – Vórtices Ciclônicos de Ar Superior.

VCAN - Vórtice Ciclônico de Altos Níveis

ZCIT – Zona de Convergência Intertropical.

ZCAS - Zona de Convergência do Atlântico Sul.

Símbolos

b - Bias

W_{ij} - Peso associado ao neurônio

a_{ij} - Vetor de entrada

x_j - Ativação total dos neurônios

Q_o - Vazão observada

Q_c - Vazão calculada

r - Coeficiente de Correlação de Pearson

R - Coeficiente de determinação ou Regressão

E - Coeficiente de Eficiência

k_c - Coeficiente de Compacidade

k_f - Fator de Forma

Resumo

Este trabalho teve o objetivo de modelar e gerar vazões médias mensais a partir de dados mensais de precipitação com base na técnica matemática de Redes Neurais Artificiais. A metodologia foi aplicada aos dados pluvio-hidrométricos da Bacia Hidrográfica do rio Paraguaçu – BA, localizada no Estado da Bahia ao Nordeste do Brasil. Foram utilizados 14 postos pluviométricos espacialmente distribuídos no âmbito da Bacia e um posto fluviométrico, chamado Argoim, na sua exutória. A rede feed-forward backpropagation, escolhida como a melhor para representar a modelagem chuva-vazão, utilizou em sua arquitetura o algoritmo de Retropropagação Levenberg-Marquardt, com 30 neurônios na camada intermediária e a função de transferência tangente hiperbólica sigmóide (tansig) nas camadas intermediárias e de saída. Dos resultados obtidos nesta pesquisa, a melhor correlação foi à função (tansig1) 0.999, com coeficientes de regressão de 0,999; 0,997 e 0,996. Na previsão para dois anos, os valores médios de regressão foram: 0,999 na fase de treinamento, 0,982 na fase de validação e 0,995 na fase de teste. Já o MSE médio dos 15 postos foi de 25,519, considerando os picos mais elevados de vazão. Quando se avaliou o desempenho de todo o processo de treinamento das RNAs com os menores MSE, foi possível identificar o melhor desempenho para a RNA 4. Essa RNA apresenta o maior coeficiente de eficiência 0,999 e o menor REMQ, igual a 5,051 m³/s.

Palavras-Chave: Modelagem hidrológica, redes neurais artificiais, climatologia do Nordeste do Brasil.

Abstract

This work aimed to model and generate monthly average streamflows data from monthly rainfall based on the mathematical technique of Artificial Neural Networks. The methodology was applied to data – pluvio-hydrometric of Paraguaçu Basin River - BA, located in the state of Bahia in northeastern Brazil. Were used 14 rain gauges distributed spatially within the basin and one stream station called Argoim. The backpropagation feed-forward network, chosen as the best to represent the rainfall-runoff modeling, used in its architecture the algorithm Backpropagation of Levenberg - Marquardt with 30 neurons in the hidden layer, and transfer function hyperbolic tangent sigmoid (tansig) in the intermediate layers and output of the model. Of the results obtained in this study, the best correlation was the function (tansig1) 0.999, with regression coefficients of 0.99, 0.997 and 0.996. In the forecast for two years, the average regression was 0.999 in the training phase, in the validation phase 0.982 and 0.995 in the test phase. Already the average MSE of the 15 stations was 25.519, considering the higher peak flows. When assessing the performance of the whole training process of ANNs with the lowest MSE was possible to identify the best performance for RNA 4. This RNA has the highest coefficient of efficiency 0.99 and lower REMQ equal to 5.051 m³/s.

Key-words: Hydrologic modeling, artificial neural networks, climatology of Northeast Brazil.

Sumário

Lista de Figuras.....	5
Lista de Tabelas.....	6
Lista de Siglas e Símbolos.....	7
Resumo.....	9
Abstract.....	10
1. Introdução.....	13
1.1 – Objetivo	14
1.2 – Objetivo Específico.....	14
1.3 – Justificativa.....	15
2. Fundamentação Teórica.....	16
2.1 – Precipitação.....	17
2.2 - Rede Neural Biológica.....	19
2.3 -. Redes Neurais Artificiais (RNAs).....	20
2.4 - Neurônio Artificial.....	24
2.5 - Funções de Transferência.....	25
2.6 – Características da Rede Neural Artificial.....	26
3. Revisão Bibliográfica.....	28
3.1 Sistemas meteorológicos atuantes no estado da Bahia.....	28
3.2 Características físicas de bacias hidrográficas.....	31
4. Material e Métodos.....	37
4.1 – Área de Estudo.....	37
4.2 - Dados utilizados na modelagem chuva-vazão.....	41
4.3 - Métodos para avaliação do desempenho das RNAs.....	43

5. Resultados e Discussão	44
5.1 - Escolha da arquitetura da rede neural.....	44
5.2 – Aplicações das RNAs à modelagem chuva-vazão	53
6. Conclusões	58
7. Referências	59

1. Introdução

A previsão de vazões é uma técnica de grande importância em todo o mundo, e em especial no Brasil, devido ao grande percentual de rios e mananciais do país. A sua utilização da água vai desde a irrigação, o fornecimento de água à população em quantidade compatível com suas necessidades, o turismo, a navegação até a geração de energia elétrica. Uma das principais informações necessária para a previsão de vazões é a informação da precipitação que ocorreu e que ainda irá ocorrer, em uma determinada bacia hidrográfica. Desta forma, os avanços no conhecimento da previsão de vazões vêm contribuindo também para que o homem aprimore seus conhecimentos sobre o ciclo hidrológico.

A bacia hidrográfica do rio Paraguaçu está localizada na região Nordeste do Brasil e é a principal fonte de abastecimento de água do estado da Bahia. Cerca de 75 municípios vivem em função desse rio, que deságua no sudoeste do recôncavo baiano, depois de nascer na Chapada Diamantina e banhar parte da região semiárida do Estado da Bahia.

Em geral, a previsão hidrológica pode ser feita principalmente através de quatro tipos de modelos: determinísticos chuva-vazão, físico, empírico e estocástico. A primeira procura representar os processos físicos de transformação de chuva em vazão, o modelo físico reproduz os processos físicos através de equações matemáticas, no modelo empírico os resultados são obtidos através de ajustes de funções matemáticas. O modelo estocástico baseia-se na descrição das propriedades estatísticas das observações que estão sujeitas as influências do meio ambiente

Em anos recentes, as Redes Neurais Artificiais (RNAs) tornaram-se extremamente conhecidas para previsão em várias áreas, incluindo finanças, carga elétrica e recursos hídricos. Embora o conceito de neurônios artificiais tenha sido proposto em 1943, por McCulloch & Pitts (1943).

As RNAs têm sido amplamente aceitas como uma forma de modelar sistemas não lineares complexos com grande quantidade de dados. Sendo esses modelos particularmente úteis em situações onde as relações dos processos físicos ainda não são

completamente compreendidas. Os modelos RNA podem ainda substituir os modelos matemáticos e estatísticos convencionais ou associar-se a eles.

Na modelagem chuva-vazão a precipitação é o principal dado de entrada das bacias hidrográficas para a estimativa de vazão, esses dados de chuvas podem ser obtidos diretamente em postos pluviométricos. A maioria das bacias hidrográficas brasileiras detém baixa densidade de pluviômetros e geralmente alguns desses estão inativos ou apresentam indisponibilidade de dados pluviométricos diários, mensais ou anuais. Essa realidade não é diferente para a Bacia Hidrográfica do Rio Paraguaçu BHRP-BA.

1.1 – Objetivo

O objetivo geral deste estudo foi o de utilizar a modelagem de Redes Neurais Artificiais com base em totais mensais precipitados para gerar vazões médias mensais na Bacia Hidrográfica do Rio Paraguaçu.

1.2 - Objetivos Específicos

- Identificar a climatologia na região da bacia do Rio Paraguaçu;
- Definir uma arquitetura de rede neural que melhor represente os dados de vazões observados no posto Argoim.
- Comparar os dados gerados pela modelagem com os dados observados na estação pluviométrica na exutória da bacia hidrográfica;

1.3 – Justificativa

O rio Paraguaçu, tem grande importância para a economia do Estado da Bahia. Nele, se pesca ao longo de todo o curso, principalmente Tucunarés, Traíras e Piaus, sendo que no baixo curso encontram-se Camarões, Robalos e Tainhas. Com a construção da barragem de Pedra do Cavalo, responsável pelo controle de suas cheias, ganhou mais uma utilização, a do abastecimento de água de todo o recôncavo, Feira de Santana e a grande Salvador. Cerca de 75 municípios vivem em função desse rio, que deságua no sudoeste do recôncavo baiano, depois de nascer na Chapada Diamantina e banhar parte da região semiárida do Estado da Bahia.

O processo de transformação chuva-vazão descreve a relação entre a chuva e a vazão de uma bacia hidrográfica, quantificando a transformação da chuva em vazão de um curso de água. Portanto, tem diversas finalidades práticas para a previsão de cheias, de recarga de reservatórios, da disponibilidade de água para abastecimento urbano ou irrigação, dentre outras.

Este estudo se justifica para contribuição do conhecimento da sociedade à aplicação do uso das RNAs na modelagem hidrológica da transformação chuva-vazão na bacia hidrográfica do Rio Paraguaçu, localizada no Estado do Nordeste (Brasil). Portanto, esta pesquisa foi realizada mediante os resultados da rede, comparados com os dados mensais precipitados na bacia hidrográfica do Rio Paraguaçu, para gerar vazões médias mensais com a finalidade de apontar possibilidades de melhorias e diminuições de erro de previsão.

2. Fundamentação Teórica

O ciclo hidrológico é o conjunto dos diversos caminhos percorridos pela água do planeta entre a superfície e a atmosfera, impulsionado fundamentalmente pela energia solar, gravidade e rotação terrestre. Os principais processos que compõem o ciclo hidrológico são a evaporação e transpiração das plantas que suprem a atmosfera de vapor d'água; a precipitação que devolve a água à superfície terrestre; infiltração, que retêm parte do volume precipitado e alimenta as plantas e os lençóis freáticos; e os escoamentos superficiais e de base que se encontram nos cursos de água mais estáveis formados pelos rios e seus afluentes os quais na sua maioria conduzem o escoamento aos oceanos (Figura 1) (MACHADO, 2005).




Figura 1. Ciclo hidrológico. Fonte: Machado (2005).

O desafio para os modelos chuva-vazão é conhecer como o ciclo hidrológico ocorre e obter, principalmente, a partir da precipitação; num certo momento, os volumes escoados.

2.1 – Precipitação

A precipitação é toda a água proveniente da atmosfera que atinge a superfície terrestre. Neblina, granizo, orvalho, geada, neve e chuva são as diferentes formas de precipitação da água. No nosso clima, a maior contribuição e a mais importante dessas formas é a chuva. As chuvas podem ser classificadas em: convectivas, orográficas e frontais ou ciclônicas (MACHADO, 2005). Na Figura 2 é possível identificar as configurações descritas abaixo.

- **Convectivas:** acontece quando o ar úmido junto ao solo é aquecido e se desloca verticalmente. Na atmosfera, condensa parte do vapor de água para formar nuvens e precipitar. São, geralmente, chuvas de pequena duração e grande intensidade agindo sobre pequenas áreas.
- **Orográficas:** ocorrem quando o ar quente e úmido que sopra do oceano para o continente encontra uma barreira montanhosa, o ar sobe, se resfria, ocorre condensação, forma-se nuvens e ocorre a precipitação. São chuvas de baixa intensidade, durações mais prolongadas em relação às convectivas e agem sobre médias áreas.
- **Frontais ou Ciclônicas:** resultam do encontro de uma massa de ar quente com uma massa de ar frio. São chuvas menos intensas, de maior duração e atingem grandes áreas.




Figura 2. Tipo de chuva de acordo com sua formação. Fonte: Machado (2005).

No Nordeste do Brasil (NEB) verifica-se desde o clima semiárido no interior da Região, com precipitação média inferior a 500 mm/ano, até o clima tropical chuvoso, observado na costa leste da Região. Na costa a precipitação acumulada é superior a 1500 mm/ano, já no clima úmido no norte do Maranhão observa-se precipitação superior a 2000 mm/ano. Isto ocorre em virtude da atuação de diferentes regimes pluviométricos. No norte da região semiárida a estação chuvosa principal é fevereiro, março e abril, no sul e sudeste as chuvas ocorrem, principalmente, durante os meses de dezembro a fevereiro e no leste nos meses de abril a junho (SANTOS 2006).

O máximo de precipitação no norte do Nordeste deve-se ao deslocamento da Zona de Convergência Intertropical (ZCIT) para latitudes mais ao sul, afetando as chuvas no NEB principalmente nos meses de fevereiro, março e abril. O máximo no sul da Região está relacionado à penetração de frentes frias oriundas das latitudes médias do hemisfério sul que alcançam latitudes mais baixas nos meses de novembro a fevereiro. O máximo de precipitação observado na costa litorânea leste da região está relacionado com a intensificação dos sistemas de leste que advectam umidade para o continente, e as frentes frias remanescentes que se propagam ao longo da costa (ALVES & KAYANO, 1991).

A distribuição da precipitação pluvial no Nordeste do Brasil está associada à interação entre a atmosfera, os oceanos e a fisiografia regional, como evidenciado em

determinados anos, e a Temperatura na Superfície do Mar (TSM) do Pacífico Equatorial. A influência é mostrada pelo fenômeno El Niño Oscilação Sul (ENOS). Este fenômeno é caracterizado por anomalias no padrão de temperatura da superfície do oceano Pacífico Equatorial que ocorrem de forma simultânea com anomalias no padrão de pressão atmosférica nas regiões de Darwin (Austrália) e de Taiti (Gruppelli, 2007). Os fenômenos El Niño (EN) e La Niña (LN) afetam a Circulação Geral da Atmosfera.

A irregularidade da precipitação pluviométrica no semiárido brasileiro resulta, não somente da variação dos totais pluviométricos, mas principalmente da duração e intensidade das chuvas. Em virtude desta variabilidade pluvial; a história do NEB está intimamente associada à história da seca. O déficit de água necessária à subsistência do homem, além de ser um problema climatológico se torna um problema econômico e social. Os efeitos da seca se apresentam sob várias formas, seja pelo aumento do desemprego rural, pobreza e fome, seja pela subsequente migração das áreas afetadas. Em outras ocasiões, em anos específicos se tem inundações em áreas ribeirinhas, desmoronamentos de terra em centros urbanos mais habitados, dentre outros.

2.2 - Rede Neural Biológica

O cérebro humano é considerado o mais fascinante processador baseado em carbono existente, sendo composto por aproximadamente 10 bilhões de neurônios, que se interconectam, formando uma grande malha de neurônios capaz de processar milhões de informações e realizar algo em torno de 60 trilhões de ligações sinápticas (CORRAR et al., 2007). Além disso, o cérebro humano é tido como um processador altamente complexo e que realiza processamentos de maneira paralela (MACHADO, 2005). Para isso ele organiza os neurônios, de forma que eles realizem o processamento necessário.

Todas as funções e movimentos do organismo estão relacionados ao funcionamento dos neurônios. Estas pequenas células estão conectadas através de sinapses e juntas formam uma grande rede chamada rede neural. As sinapses transmitem estímulos através de diferentes concentrações de Na^+ (Sódio) e K^+ (Potássio), e o resultado disto pode ser estendido por todo o corpo humano. Esta grande rede proporciona uma fabulosa capacidade de processamento e armazenamento de informação. Isso é realizado numa velocidade extremamente alta e não existe qualquer

computador no mundo capaz de fazer o que o cérebro humano faz. Neste aspecto, as redes neurais biológicas teriam unidades, os neurônios, que se comunicariam por meio de conexões entre si (CORRAR et al., 2007).

Os principais componentes dos neurônios (Figura 5) são:

- Os dendritos, que tem por função, receber os estímulos transmitidos pelos outros neurônios;
- O corpo do neurônio (corpo celular) que é responsável por coletar e combinar informações vindas de outros neurônios;
- Axônio, que é constituído de uma fibra tubular que pode alcançar até alguns metros, e é responsável por transmitir os estímulos para outras células.

Rede neural biológica




Figura 3 – Esquema de um neurônio. Fonte: Dornelles (2007).

2.3 – Redes Neurais Artificiais

As RNAs são compostas por unidades de processamento simples, denominadas neurônios, que computam determinadas funções matemáticas, geralmente não lineares, a partir de entradas recebidas. Estas unidades são dispostas paralelamente constituindo

camadas e são interligadas com as unidades de camadas vizinhas por conexões geralmente associadas a pesos. Por analogia às interligações dos neurônios no cérebro humano, as conexões entre unidades de uma rede neural são chamadas sinapses, sendo os pesos denominados pesos sinápticos.

Os pesos sinápticos ponderam as entradas recebidas por cada neurônio e são os responsáveis pelo armazenamento do conhecimento representado pela RNA. A solução de um problema com RNAs passa inicialmente por uma fase de aprendizagem, onde os pesos das conexões são ajustados até proporcionarem à rede a capacidade de representar o problema. Uma vez treinada, os pesos são fixados e a rede pode ser empregada como um modelo, estimando saídas a partir de um conjunto de dados de entrada.

Em 1943, a ideia da neurocomputação surgiu com o neurofisiologista McCulloch e o matemático Walter Pitts, fazendo as primeiras ligações com o cérebro humano. Em 1949, o psicólogo Donald Hebb demonstrou que a capacidade de aprendizagem em redes neurais vem da alteração da eficiência sináptica. Frank Rosenblatt (1962) mostrou o modelo dos perceptrons, onde os pesos das conexões eram adaptados a fim de se atingir a eficiência sináptica, hoje a base dos modelos atuais. Em seguida, Bernard Widrow e alguns estudantes desenvolveram um novo tipo de elemento de processamento chamado Adaline (rede linear adaptada), que utiliza uma lei de aprendizado diferente do perceptron (SOUSA, 2008).

Promessa de máquinas poderosas e previsões pouco confiáveis tiraram a credibilidade de muitos estudos e os avanços se tornaram pouco significativos durante um período de pesquisas silenciosas. Nos anos 80, o interesse pela neurocomputação emergiu com os artigos de John Hopfield, que relataram o uso de um algoritmo de aprendizado que estabilizava a rede binária simétrica com realimentação. Assim, Rumelhart e McClelland (1986), fizeram este campo de pesquisa explodir com a publicação do livro *“Parallel Distributed Processing”* (Processamento Paralelo Distribuído), em que introduziram o poderoso método *“backpropagation”* como algoritmo de aprendizado, sendo utilizado até hoje.

As RNAs são uma classe de modelos flexíveis não lineares que podem descobrir padrões adaptativos a partir dos dados. Teoricamente, tem sido demonstrado que, dado um número adequado de unidades de processos não lineares, as RNAs podem aprender com a experiência e estimar qualquer relação funcional complexa com alta precisão.

Existem inúmeros modelos de redes neurais que se diferenciam principalmente pela estrutura da rede, pelo algoritmo de aprendizagem, pelas funções de ativação

empregadas, pela recorrência, dentre outras características. Podemos citar aqui os modelos *Perceptron*, *feed-forward*, *GMDH (Group Method of Data Handling)*, *NSRBN (Non Linear Sigmoidal Regression Blocks Networks)*, dentre outros. Uma boa descrição sobre essas redes pode ser encontrada em Valença (2005), onde se encontram também, informações sobre os algoritmos de aprendizagem, Backpropagation, Combinatorial e Iterativo Multicamadas.




Figura 4. Algumas arquiteturas que apresentam dinâmicas diferentes no fluxo dos dados.

Embora muitos tipos de modelos de redes neurais tenham sido propostos, o mais popular para previsão de uma série temporal é o modelo feed-forward. A Figura 4 mostra um típico modelo de três camadas feed-forward utilizado para efeitos de previsões. A entrada para os nós será defasada de observações anteriores, enquanto a saída fornece as previsões para o valor futuro. Os nós ocultos com as funções não lineares de transferência são utilizados para processar as informações recebidas pelos nós de entrada.




Figura 5. Modelo de RNA feed-forward recursivo com multi-passos.

Para construir um modelo de previsão, a rede é processada através de três estágios: (1) o estágio de treinamento onde a rede é treinada para prever dados futuros, baseada em dados passados e presentes; (2) o estágio de testes no qual a rede é testada para parar o treinamento ou para manter-se em treinamento; (3) o estágio de avaliação, a rede deixa o estágio de treinamento e pode ser utilizada para a previsão futura dos dados e estimar os erros. Aqui o algoritmo *backpropagation*, desenvolvido por Rumelhart et al. (1986), será utilizado para o treinamento da rede.

As RNAs estão relacionadas a arquiteturas de sistemas com capacidade de processamento que se inspiram no funcionamento do cérebro humano e de seus neurônios, sendo assim um conceito da computação que visa trabalhar no processamento de dados de maneira semelhante ao cérebro. Assim, uma RNA é capaz de aprender a partir de exemplos, semelhantes à forma de aprendizagem dos seres humanos. As RNAs são técnicas computacionais úteis quando há necessidade de se reconhecerem padrões a partir do acúmulo de experiência ou de exemplos, e cuja representação é complexa. O grau de conhecimento da rede é na verdade função da quantidade de exemplos utilizados na etapa de aprendizado (CORRAR et al., 2007). De maneira geral, se pode definir uma RNA como um sistema constituído por elementos de processamento interconectados, neurônios, dispostos em camadas (entrada, intermediária(s), saída) e são responsáveis pela não linearidade e memória da rede.

Na computação tradicional o processamento das informações é serial (em sequência), diferentemente das redes neurais em que o processamento das informações pelos neurônios ocorre de forma paralela (ao mesmo tempo), o que lhe confere uma capacidade de processar grande quantidade de informações rapidamente (CORRAR et al., 2007).

O processo de introdução dos dados na rede é bastante simples, e este processo não requer do usuário conhecimentos sobre processos do aprendizado ou tecnologia envolvidos. Cabe ao usuário apenas fornecer os dados a serem levados em conta e indicar à rede o que ele quer que ela aprenda (CORRAR et al., 2007). A arquitetura das redes neurais requer grande experiência dos projetistas. A escolha do número de neurônios da camada de entrada é um fator que exige experiência e sensibilidade, sendo necessário analisar com bom senso as variáveis que irão influenciar ou que são relevantes na determinação dos dados de saída.

O ajuste de uma RNA na solução de um problema de modelagem chuva-vazão é um problema particular do ajuste de uma função a uma amostra de dados. Esse processo consiste em determinar uma arquitetura específica de rede que possibilite a previsão de dados fluviométricos com os menores erros de estimativas.

2.4 - Neurônios artificiais

Como mostrado na Figura 6 uma célula de rede é constituída pelos pesos, somatório e função de transferência. O seu funcionamento pode ser resumido pela seguinte sequência de ações: dados de entradas são fornecidos para a rede, esses dados são multiplicados por pesos, simulando sua entrada em uma célula neural, a seguir é feita a soma ponderada dos sinais de entrada, produzindo um nível de atividade que induz o estímulo na unidade de processamento que é a função de transferência, essa função vai emitir uma resposta ao estímulo recebido para os demais neurônios adjacentes. O neurônio artificial mostrado na Figura 6, ainda inclui a entrada de um elemento externo b , chamado viés (ruído aleatório). Isso significa que a combinação linear da unidade somatório deve ser aumentada em um termo para implementar o termo b .




Figura 6. Célula de rede neural artificial. Fonte: Machado (2005).

Matematicamente cada neurônio possui um peso associado W_{ij} para cada dado do vetor de entrada a_{ij} . O dado de entrada é então multiplicado por esse peso. Outro parâmetro também importante é o viés (b). A ativação total do neurônio é dada pela Equação (2.1) adaptada de Kröse e Smagt (1996).

$$x_j = \sum_{i=1} (w_i) a_i \quad (2.1)$$

Após o cálculo realizado pela Equação (2.1), o resultado passa então pela função de ativação (tansig, logsig e purelin), conforme o cálculo representado na Equação (2.2) adaptada de Kröse e Smagt (1996).

$$y_j = F \left(\sum_{i=1} (w_i) a_i \right) \quad (2.2)$$







2.5 - Funções de Transferência

A utilização da função de transferência permite às RNAs identificar em relações lineares e não lineares entre as variáveis de entrada e saída. Essa função diferencia a

decisão neural baseada no potencial interno do neurônio e determina o valor a serem enviados aos demais neurônios (SANTOS E FILHO, 2003).

Existem várias funções de ligação que podem ser utilizadas em redes neurais, dependendo do objetivo e tipo de variável em estudo. A Tabela 1 mostra seis funções de transferência, as mais utilizadas são as Log-Sigmóide, Linear e Tan-Sigmóide.

Tabela 1 – Funções de transferências e respectivos gráficos.

Funções de transferência	Gráfico/Função	Funções de transferência	Gráfico/Função
1. Tangente hiperbólica Sigmóide		4. Linear Limite Rígido	
2. Saturadas Lineares Simétricas		5. Positiva linear	
3. Linear Saturada		6. Logarítmica Sigmóide	

2.6 – Características da Rede Neural Artificial

A arquitetura das redes neurais pode ser classificada como estática, dinâmica, ou fuzzy, com uma ou várias camadas. Em rede simples, como a perceptron, a comunicação é unidirecional, possuindo um comportamento estático. Para o comportamento ser dinâmico, o fluxo de dados deve ser multidirecional, com os neurônios integrados, possuindo camadas misturadas. Cada neurônio da rede recebe um peso inicial, que se modifica de acordo com as interações de outros neurônios, dando início ao comportamento inteligente da rede.

Com a evolução das redes em busca de melhorias no desempenho e eficácia, suas estruturas ganharam mais elementos e possibilidades de comportamento. As redes “feedback” (recorrentes) são referenciadas como sistemas não lineares dinâmicos, pois existe uma realimentação de sinais já propagados na rede (LOKE, 1995). Algumas das vantagens das RNAs são (ASCE, 2000a):

1. Capacidade de reconhecer a relação entre as variáveis de entrada e saída sem explicitar considerações físicas;
2. Funcionam bem mesmo quando o conjunto de treinamento contém ruídos e estimativas de erros;
3. São capazes de se adaptar às soluções em longo prazo para compensar a evolução das circunstâncias;
4. Possuem outras características inerentes ao processo de informação e uma vez treinadas são fáceis de usar;

Outras vantagens são apontadas em SOUSA (2008):

5. As RNAs tomam suas próprias decisões embasadas nos conhecimentos adquiridos através de exemplos históricos;
6. Capacidade de generalização, mesmo com dados incompletos ou imprecisos as redes podem preencher as lacunas sem sofrer degradação; é algo como a

interpolação e extrapolação da estatística, porém operacionalmente muito diferente;

7. Adaptabilidade, uma vez construída uma rede eficiente em dada aplicação ela pode ser utilizada em tempo real, sem necessidade de alteração na arquitetura; basta apenas retreinar com base nos novos dados.

Mas como todos os modelos que estão em evolução, às RNAs também apresentam algumas desvantagens:

1. Treinamento demorado, dependendo da aplicação, pode demorar horas ou até dias;
2. Caixa-preta, não se pode conhecer o motivo pelo qual a rede tomou determinada decisão, pois seus critérios são encriptados nas camadas escondidas. Na realidade essa desvantagem já está sendo resolvida, pois, algumas ferramentas de extração de regras de redes estão sendo desenvolvidas (ALVES, 2001).
3. Resultados desconcertantes, se os dados não forem bem tratados e o treinamento não for suficientemente bom, a rede pode chegar a conclusões contrárias às regras, cabendo o bom senso do profissional em tratar tais casos.

3. Revisão Bibliográfica

3.1 Sistemas meteorológicos atuantes no estado da Bahia

O clima de uma região é uma resposta natural aos fenômenos oceânico-atmosféricos, à fisiografia, à distribuição dos continentes e oceanos, à latitude e altitude, podendo ser modificado ao longo do tempo através da ação humana. Na Bahia, a distribuição espaço-temporal da precipitação, por não ser uniforme, apresenta grande variabilidade climática. Isto acontece devido à ação de diversos sistemas atmosféricos que atuam na região, tais como: Zona de Convergência do Atlântico Sul (ZCAS), o Vórtice Ciclônico de Altos Níveis (VCAN), Brisas Terrestres, Ondas de Leste e Sistemas Frontais. A atuação desses sistemas determina períodos chuvosos nas sub-regiões do Estado (NOBRE 1988; MOLION, 1988; CHAVES, 1999; CAVALCANTI, 2001; MOLION; BERNARDO, 2002; VIANA, 2009).

A ZCAS tem papel importante na precipitação do sul do Nordeste durante os meses de setembro a fevereiro. Segundo Nobre (1988), nos anos considerados como chuvosos, a ZCAS situa-se mais ao norte e nos anos considerados secos, mais ao sul. Esse sistema é caracterizado por uma faixa de nebulosidade convectiva que se estende da região Amazônica até o Atlântico subtropical, esta nebulosidade é resultado da interação da convecção tropical com sistemas extratropicais, como os sistemas frontais (VIANA, 2009).

Os VCAN são sistemas de circulação ciclônica que atuam nos meses de novembro a fevereiro se originam através de sistemas de baixa pressão em escala sinótica, ocorrem de forma muito irregular em termos de seu posicionamento, produzem tanto chuvas intensas como estiagens. As chuvas ocorrem nas bandas de nebulosidade de sua periferia, enquanto no centro se verifica movimento subsidente, de forma a inibir a formação de nuvens e pode atuar durante meses (ARAÚJO et al., 2008). O tempo de vida dos vórtices pode durar apenas algumas horas ou perdurar por um período de até mais de duas semanas. Sua trajetória é irregular, quase sempre, deslocam-se de leste para oeste. Seu aparecimento está relacionado à circulação geral da atmosfera, com a Alta da Bolívia (AB), com a posição da ZCAS e com a penetração de Frentes Frias do sul. Tem como provável mecanismo dissipador o aquecimento do continente (ARAÚJO, 2006). Quando um vórtice penetra no Brasil, na maioria das vezes o faz próximo a Salvador-BA, produzindo pouca precipitação na região sul e central do Nordeste à medida que o vórtice se move em terra. Enquanto, a parte norte do Nordeste experimenta atividades convectivas fortes e em alguns casos até inundações (KOUSKY; GAN, 1981; KOUSKY; GAN, 1986).

As brisas marítimas e terrestres são sistemas atmosféricos característico de regiões litorâneas. Durante os dias ensolarados, a superfície do continente aquece mais rápido que a do oceano adjacente, provocando uma faixa de pressão mais baixa sobre o continente, propiciando o desenvolvimento de correntes ascendentes sobre o continente, as quais podem gerar nuvens convectivas. Como sobre o oceano a pressão continua alta, devido à menor temperatura da água à superfície, há a formação de movimentos ascendentes de ar na costa e subsidentes sobre o mar. O vento, à superfície, que sopra do oceano para o continente é denominado brisa marítima. Durante a noite a situação se inverte e o continente perde calor muito mais rápido que oceano. A faixa de baixa pressão se situa sobre o oceano e o movimento ascendente de ar associado à baixa pode

gerar nuvens convectivas. O vento passa a soprar do continente para o mar, constituindo a brisa terrestre (VIANA, 2009).

O grau de influência orográfica sobre a precipitação depende essencialmente da altitude e da orientação das vertentes em relação aos ventos predominantes, que transportam umidade, desta forma a instabilidade da atmosfera e disponibilidade de umidade são fatores que influenciam o comportamento pluviométrico (VIANA, 2009). Quando uma massa de ar se desloca encontra um sistema orográfico e é forçada a elevar-se, acarreta a queda da temperatura seguida da condensação do vapor d'água e formação de nuvens. A precipitação produzida sob essas condições denomina-se precipitação orográfica.

Os Distúrbios de Leste são sistemas que apresentam produção de chuvas, em geral, nos meses de maio a agosto, ao longo da costa leste, desde o norte do Rio Grande do Norte até a Bahia. Seu deslocamento se dá na direção leste-oeste em direção ao continente. Sua intensidade depende da Temperatura da Superfície do Mar (TSM), do cisalhamento do vento e dos efeitos da orografia e da circulação de Brisas Marítima e Terrestre, de forma a intensificar ou dissipar esse sistema. O principal período chuvoso ocorre nos meses de abril a junho (ARAÚJO, 2006; TANAJURA et al., 2010). As chuvas no litoral são ainda explicadas pela modulação dos ventos alísios e da Alta Subtropical, pelos vestígios de sistemas frontais e pela posição dos VCANs (TANAJURA et al., 2010).

Os Sistemas Frontais são regiões de descontinuidade térmica separando duas massas de ar de características diferentes. São delgadas zonas de transição entre uma massa de ar quente (menos densa) e uma massa de ar frio (mais densa). A penetração de sistemas frontais na Bahia ocasiona prolongados períodos de chuvas no centro-sul do Estado e desempenha um importante papel no seu regime de precipitação cujo máximo é atingido durante os meses de novembro a janeiro (ARAÚJO, 2006).

A precipitação no NEB, incluindo a Bahia, é fortemente influenciada pela variabilidade interanual, particularmente pelo El Niño/Oscilação Sul (ENOS) (MOLION e BERNARDO, 2002) e pelo dipolo do Atlântico. Segundo Chaves (1999) a variabilidade da precipitação sobre o sul do NEB está associada à variabilidade da TSM sobre o Atlântico. A TSM pode provocar anomalias positivas (negativas) de precipitação sobre esta região quando o Atlântico Tropical Norte e Sul apresentam-se com anomalias

positivas (negativas) e negativas (positiva), respectivamente, no período de dezembro a fevereiro. Particularmente, o semiárido do NEB é uma região bastante vulnerável a essa variabilidade, pois se as chuvas no período chuvoso são fracas, há um prolongamento do período de estiagem com fortes secas e grandes impacto na população, que muitas vezes depende da lavoura de subsistência (TANAJURA et al., 2010).

A precipitação do NEB também sofre influência de fenômenos de escala global como a Oscilação Madden-Julian (OMJ), Oscilação 30-60 dias, que consiste basicamente da propagação de uma onda atmosférica na direção zonal sentido leste ao longo do globo terrestre e em torno do Equador. Segundo Repelli et al. (2012) essa Oscilação provoca intensificações e deslocamentos nos sistemas meteorológicos, intensifica frentes frias no litoral baiano, e provoca deslocamentos ao sul do Equador da ZCIT sobre o Atlântico Ocidental e da Alta da Bolívia.

3.2 Características físicas de bacias hidrográficas

As bacias hidrográficas correspondem a uma área definida e fechada topograficamente num ponto de curso de água, de forma que toda vazão afluyente possa ser medida ou descarregada através desse ponto. As características topográficas, geológicas, geomorfológicas, pedológicas e térmicas, bem como o tipo de cobertura da bacia hidrográfica, desempenham papel essencial no seu comportamento hidrológico, sendo necessário serem medidas numericamente algumas dessas características (GARCEZ; ALVAREZ, 1988). As características físicas de uma bacia são elementos de grande importância em seu comportamento hidrológico. Existe, uma estreita correspondência entre o regime hidrológico os elementos: área de drenagem, forma da bacia hidrográfica, comprimento do rio principal, sistema de drenagem, declividade, relevo da bacia hidrográfica. Sendo assim, o conhecimento dessas variáveis permite obter informações de fluxo em seções transversais dos rios onde não dispõem de dados ou em regiões que por causa de fatores de ordem física ou econômica não seja possível à instalação de estações hidrométricas (VILLELA; MATTOS, 1975).

O formato da área plana de uma bacia hidrográfica de drenagem exerce influência no tempo de concentração, ou seja, no tempo decorrido pela água a partir dos limites da bacia hidrográfica até o seu exutório. Os índices que indicam a forma da

bacia hidrográfica estão associados a algumas formas geométricas conhecidas, como o coeficiente de compacidade e o fator de forma que estão relacionados ao círculo e ao retângulo, respectivamente. O coeficiente de compacidade das bacias hidrográficas é sempre um número superior à unidade, uma vez que o círculo é a figura geométrica de menor perímetro para uma dada área. Bacias hidrográficas que apresentam esse coeficiente próximo de um são mais compactas, tendem a concentrar o escoamento e são mais susceptíveis a inundações. O fator de forma constitui outro índice indicativo de maior ou menor tendência para enchentes de uma bacia hidrográfica, pois este índice está associado ao tempo de concentração da bacia hidrográfica. Bacias hidrográficas alongadas apresentam pequenos valores do fator de forma e são menos susceptíveis às inundações, haja vista ser pouco provável que uma chuva intensa cubra toda a sua extensão (VILLELA; MATTOS, 1975; SILVA et al., 2010).

O sistema de drenagem de uma bacia hidrográfica é formado pelo rio principal e seus afluentes e indica a menor ou a maior velocidade com que a água deixa a bacia hidrográfica. As características de uma rede de drenagem podem ser razoavelmente descritas pela ordem dos cursos d'água, densidade de drenagem, extensão média do escoamento superficial e sinuosidade do curso d'água. A ordem reflete o grau de ramificação ou bifurcação dentro de uma bacia, a densidade de drenagem fornece um indicativo da eficiência de drenagem da bacia hidrográfica (VILLELA; MATTOS, 1975).

As características do relevo de uma bacia hidrográfica estão associadas aos fatores meteorológicos e hidrológicos, pois a velocidade do escoamento está relacionada à declividade do terreno, já a temperatura e precipitação sofrem interferência da altitude da bacia. Portanto, se torna interessante conhecer informações a respeito do relevo e declividade da região onde se localiza a bacia, nesse contexto está inclusas variáveis como a elevação média da bacia hidrográfica e declividade do álveo. A declividade do álveo indica a velocidade do escoamento de um rio, pois quanto maior a declividade, maior essa velocidade (VILLELA; MATTOS, 1975). Além disso, a cobertura vegetal associada aos fatores geológicos também são fatores que influenciam no escoamento superficial, nas taxas de evaporação e na capacidade de retenção (GARCEZ; ALVAREZ, 1988).

Segundo Alves e Castro (2003) a sinuosidade dos canais é influenciada pela carga de sedimentos, pela compartimentação litológica, estruturação geológica e pela declividade dos canais. Assim, quando o valor do índice de sinuosidade é próximo de um os canais tende a ser retilíneo, caso seja acima de dois os canais serão tortuosos e os valores intermediários, entre um e dois, indicam formas de transição: regulares ou irregulares.

As características das bacias hidrográficas são importantes para que se tenha um planejamento bem sucedido da conservação, do fluxo de base, da infiltração, do escoamento superficial e da produção de água na região da bacia hidrográfica.

A relação entre chuva e vazão é altamente não linear. Haykan (1994) cita que as RNAs com três camadas são capazes de aproximar qualquer função com características não lineares. Conceitos preliminares de RNAs e sua adaptabilidade à hidrologia são bem explicados em ASCE (2000a) e uma lista exaustiva de referências sobre aplicações de RNA em hidrologia pode ser vista em ASCE (2000b). Sua aplicação em simulação e previsão de problemas de recursos hídricos tem mostrado grande habilidade e algumas das aplicações são mencionadas aqui.

O primeiro modelo matemático para um neurônio biológico foi proposto por McCulloch & Pitts (1943) na qual considera a saída do neurônio com uma resposta binária a um estímulo fornecido. Diversos autores citam a importância do modelo baseado em redes neurais e de sua ampla utilização facilitando conceitos por pesquisadores em varias áreas.

Segundo Crespo; Mora (1993) utilizou uma rede multicamadas “feedforward” para desenvolver um método de calculo para vazão a partir da precipitação, para vazões baixas, de maneira que se pudesse fazer uma melhor análise sobre o período seco. O algoritmo utilizado foi o “back-propagation”, utilizando um ajuste “on-line”. A função de ativação utilizada foi uma tangente hiperbólica. Na previsão de vazões não só a precipitação histórica é importante, mas também a evapotranspiração e a infiltração. Por isto, na entrada da rede foi utilizada a precipitação nos instantes de tempo t e $t-1$, e também o numero de dias de chuva no período.

Yang et al. (1999) apresentaram um procedimento para integração de três modelos para a previsão de enchentes. Os modelos utilizados foram à função de

transferência linear (LTF), modelo auto regressivo integrado de media móvel (ARIMA) e o modelo de RNA. Depois de ter feito o treinamento os três modelos foram comparados. Esse procedimento de integração é um novo procedimento para previsão de enchentes. Os resultados demonstram que esse procedimento não somente tem uma estrutura simples, mas também não incluem hipóteses anteriores. Sendo considerado como apropriado para previsão de vazão.

Em Valença (2000) apresenta um modelo de RNA difusa para prever um fluxo médio mensal da usina Hidrelétrica de Sobradinho. Este modelo proporciona uma melhor representação da previsão média mensal de entrada de água, quando comparados aos modelos de Box-Jenkins que são amplamente utilizados no setor elétrico do Brasil.

Tokar e Markus (2000) utilizaram RNA na modelagem do processo chuva-vazão em três bacias hidrográficas dos EUA, bacia do rio Fraser, no Colorado, Raccoon Creek, em Iowa e Little Patuxent em Maryland. Na bacia do rio Fraser os autores confrontaram os resultados obtidos com os resultados do modelo conceitual WATBAL, mensal. Em Raccoon Creek, confrontaram RNA e o modelo, também conceitual, SAC-SMA (sacramento), diário. No rio Little Patuxent, confrontaram os resultados da RNA com o modelo conceitual SCRR, também diário. Para todos os casos os resultados das RNAs foram mais precisos. As principais entradas utilizadas para as RNAs foram chuva, equivalente de neve derretida em água e temperatura.

Ramos e Galvão (2001) aplicaram as técnicas de redes neurais a um problema de modelagem hidrometeorológica de desagregação espacial da chuva, com o objetivo de avaliar a estabilidade oferecida pelo método. Os autores concluíram que o método apesar de poder fornecer bons resultados na fase de calibração, oferecendo altos coeficientes de correlação, o mesmo bom desempenho pode não acontecer na fase de validação. Os autores aconselharam, no uso dessa técnica, certos cuidados, como por exemplo, o de evitar ao máximo o excesso de parâmetros numa rede, motivo pelo qual ocorre o superajustamento. Indicaram a importância de se realizar um pré-processamento dos dados de entrada da rede neural antes de utilizá-los na calibração, bem como, a necessidade de se atribuir critérios de estabilidade para a escolha da melhor rede.

Olívio et al. (2002) aplicaram as técnicas de RNAs ao problema de previsão de cheias fluviais, o tipo de rede neural escolhido foi a “perceptron” de múltiplas camadas

e o algoritmo de treinamento usado no estudo foi o retropropagação do erro. Foi inserido à rede, como padrão de entrada, o nível de água do rio a montante de uma seção de interesse e esperou-se uma resposta adequada da rede neural a previsão de níveis fluviométricos para 4, 6, 8 e 10 horas de antecedência. Os autores concluíram que redes neurais se prestam para a previsão de cheias e que os resultados poderiam melhorar caso fossem utilizados dados de entrada mais apropriados.

Lima e Ferreira Filho (2003) aplicaram RNA na modelagem mensal chuvavazão na Bacia Hidrográfica do rio Acaraú no semiárido Cearense, Brasil. Os autores avaliaram varias RNAs com diferentes entradas, ditas modelos, e número de neurônio na camada intermediária. Além disso cada RNA foi treinada com números diferentes de dados. Os resultados são muitos satisfatórios com coeficientes de correlação em torno de 93% na validação, no entanto os autores não confrontam estes resultados com os resultados de outro modelo.

Almeida e Barbosa (2004) utilizaram RNAs com o objetivo de conhecer a previsão de secas hidrológicas para um horizonte de cinco dias. Este tipo de seca está normalmente defasado da seca meteorológica, dado que é necessário um período maior para que as deficiências da precipitação se manifestem no diversos componentes do sistema hidrológico. A rede neural possuía na camada de entrada onze neurônios e o algoritmo de treinamento usado nesse trabalho foi o do gradiente conjugado escalonado. Os resultados foram satisfatórios na previsão de vazão média diária para um horizonte de cinco dias e tal técnica auxilia na identificação de um possível início de evento de seca hidrológica.

Rajurkar et al. (2004) realizaram uma abordagem para modelar vazões diárias durante os eventos de inundação utilizando RNA, considerando dados diários de chuva e vazão de duas bacias hidrográficas de grande porte na Índia e cinco bacias hidrográficas utilizadas anteriormente pela Organização Meteorológica Mundial (OMM) para inter-comparação dos modelos hidrológicos operacionais. A precipitação - o processo de escoamento é modelado pelo acoplamento de um modelo simples (caixa preta) linear com a RNA. Os resultados mostraram que a modelagem produz resultados bastante satisfatórios para os dados de captação a partir de diferentes localizações geográficas.

Melesse e Hanley (2005) utilizaram uma RNA feed-forward usando o algoritmo back-propagation para três diferentes ecossistemas (florestas, pastagens e terras agrícolas utilizando fluxos de energia particionada, temperaturas do ar e do solo como variáveis de entrada para predizer o fluxo de carbono presente).

Segundo Cruz (2007) e Cruz et al., (2006) apresenta-se comparação de previsão de cheias utilizando-se o modelo de metodologia DPFT (Diferenças Primeiras de Função de Transferência), usando uma amostra de observações de eventos precipitação-vazão médio da bacia, que comparada com um modelo simples de RNAs, observou-se que a metodologia DPFT apresentou um desempenho superior ao modelo de RNAs, mostrando menor regularidade nos resultados.

Chokmani et al. (2008) realizaram um estudo de caso para o rio Fraser na Columbia Britânica comparando as RNAs com os modelos de regressão múltipla para previsão de vazões afetadas pelas condições de gelo. Os resultados mostraram que as RNAs são modelos mais bem sucedidos que os modelos de regressão para fins de estimativas de vazões de inverno.

Morais *et al.*, (2008) utilizaram o *SPI* com RNA para prever seca a partir de dados de uma única estação, onde foi analisado o desempenho de um tipo de rede neural para varias escalas temporais do *SPI*. Eles constataram que a escala de 12 meses (*SPI*-12) foi a mais adequada por apresentar menor variabilidade, uma vez que leva em conta o valor acumulado da precipitação, sendo, portanto, de mais fácil previsão.

Em outro estudo proposto por (Nasseri 2008), foi aplicado RNAs para a previsão de precipitação na bacia de Upper Parramatta localizada em Sydney, Austrália, com área aproximada de 112km². Os autores relatam à problemática e o consumo de tempo para encontrar e selecionar uma arquitetura de rede neural adequada. Para contornar tal questão, os autores propõem a utilização de algoritmos genéticos acoplado a uma rede neural tipo MLP para melhorar o desempenho da rede durante a fase de treinamento. O uso de algoritmos genéticos é voltado nesse trabalho para determinar os pesos correspondentes das conexões entre cada neurônio artificial.

Glezakos et al. (2009) utilizaram uma longa série temporal de médias mensais de precipitação de algumas bacias espalhados pela ilha de Chipre para o treinamento e testes de RNAs para a gestão dos recursos hídricos e para a estimativa do risco de

enchentes e modelagem. O modelo utilizado permitiu estimar o abastecimento de água médio anual para as bacias hidrográficas montanhosas diferentes.

Makungo et al. (2010) apresentaram um método de modelagem chuva-vazão Rainfall-Runoff (RR) e *Modelo de Equilíbrio de água* a fim de determinar a modelagem que melhor representasse a geração de vazões naturais modificadas a partir do método de regionalização do vizinho mais próximo, devido a falta de dados de vazões na área de estudo. Os autores, aplicaram os modelos em duas sub-bacias de quarta ordem (SQCs) que estão dentro da bacia hidrográfica do rio Nzhelele, situado na zona norte da região da província de Limpopo no Sul da África. As duas modelagens, no entanto, tendem a subestimar vazão de pico. Porém, apesar disso, as previsões obtidas revelaram que a modelagem pode ser utilizada para prever o escoamento em bacias hidrográficas.

4. Material e Métodos

4.1 – Área de Estudo

A bacia hidrográfica do rio Paraguaçu está localizada na região centro-leste do Estado da Bahia entre as coordenadas 11° 17' a 13° 36' de latitude Sul, e 38° 50' a 42° 01' de longitude Oeste e ocupa uma área de 55.317 km², cerca de 10,14% do território baiano.

O rio Paraguaçu (na linguagem indígena significa água grande, mar grande, grande rio), o principal da bacia, nasce na serra do Sincorá, nas fazendas Farinha Molhada, Paraguaçu e Brejões, no município de Barra da Estiva. A altitude da cabeceira é cerca de 1200 metros em relação ao nível do mar, percorre cerca de 500 km até a sua foz na parte oeste da Baía de Todos os Santos e tem sua desembocadura na baía de Iguape. É o sistema fluvial de domínio estadual mais importante da Bahia.

Em virtude de sua extensão a Agência Nacional de Águas ANA (2010) dividiu em três partes:

- Alto Paraguaçu, trecho a montante da confluência do rio Santo Antônio;
- Médio Paraguaçu entre a foz do Santo Antônio e a barragem de Pedra do Cavalo; e

- Baixo Paraguaçu, trecho a jusante da referida barragem.

Os principais afluentes são:

- Margem Direita: Rio Una e seus afluentes: Córrego da Jibóia, Riacho Santo Antônio e Rio do Jegue; Córrego Piolhinho; Riacho Pau-a-Pique; Riacho Caatinga do Miranda e seus afluentes; Riacho da Paloma e Tanque da Cancela; Riacho Santo Antônio e Riacho Fundo.
- Margem Esquerda: Rio Alpercata; Rio Santo Antônio e seus afluentes: Rio Tijuco, Riacho Preto, Riacho do Cerco; Rio Utinga e seus afluentes: Córrego Bom Sucesso e Riacho dos Patis; Riachos Canoa Brava, Grande, e Tupim com seus afluentes: Canoa e Cotia; Rio Santa Isabel, Rio Capivari com seus afluentes: Rio Saracura e seu contribuinte Riacho da Cana Brava e Riacho Águia Branca; Rio do Peixe com seus afluentes: Riacho Seco, Vitória, Congonha, Rios Cairu, Imbé, Jitirana, Paulista e Jundiá; Rio Paratigi afluentes: Rio Zabelê, Rio Curimataí, Ribeirão do Cavaco e finalmente o Rio Jacuípe (afluentes: Riacho do Maia e Rio Principal).



Figura 7 – Postos pluviométricos e estações fluviométricas da Bacia do rio Paraguaçu. FONTE: Mapa do sistema de transporte do estado da Bahia Escala. 1:2000000, DERBA, 1984.

As águas do rio são usadas para diversos fins, abastecimento público e doméstico em diversas cidades situadas na bacia através de poços artesianos ou mesmo adutoras instaladas ao longo da bacia, barramentos nas cidades de Pedra do Cavalo, Santo Antônio, Apertado e outros. Abastecimento industrial de indústrias metalúrgicas, têxteis, de celulose e beneficiamento mineral, dessedentação de animais com predominância de bovinos, seguido de suínos, equinos e caprinos, atividades de lazer e esportes náuticos na barragem de Pedra do Cavalo. No trecho estuarino próximo à foz, pesca em alguns trechos inclusive na zona estuarina e, além disso, o rio serve de corpo receptor de esgotos domésticos e industriais em diversos trechos da bacia hidrográfica (Agência da Bahia, 2010). O uso do solo da Bacia Hidrográfica do Rio Paraguaçu está relacionado às seguintes atividades:

- Agropecuária, associada à agricultura e ao extrativismo em toda a bacia hidrográfica;
- Exploração mineral principalmente no Alto do curso do rio;
- Pastagem: pecuária (bovino, eqüinos, caprinos, etc), em toda a bacia hidrográfica;
- Área de preservação ambiental: APA Lago de Pedra do Cavalo, através de Decreto nº 6.548, de 18/06/97;
- Ferrovias no trecho médio e baixo Paraguaçu, realizam transportes de minérios e substâncias químicas - nos municípios de Cachoeira, Castro Alves, Iaçú e se prolonga pela região sudoeste do Estado de Minas Gerais, onde se interliga com a rede ferroviária do leste;
- Rodovias: Os municípios têm ligação direta com Salvador, além de outras regiões através das: BR-324, que corta a parte nordeste da bacia; BR-242, que cruza a área em toda a sua extensão na direção leste-oeste; BR-116, que passa no trecho sudeste; BR-122 que liga Cafarnaum e Souto Soares à BR-242. Além disso, existem diversas estradas estaduais asfaltadas e carroçáveis, destacando-se as estradas BA-052 (Estrada do Feijão) que interliga a região leste a noroeste; BA-142, que liga Utinga a Barra da Estiva, passando por Andaraí e Mucugê; e a BA-046, que liga Morro do Chapéu a Bonito;
- Atividades industriais nas cidades de Feira de Santana e Cruz das Almas;
- Atividades turísticas nos municípios da região da Chapada Diamantina e do Recôncavo Baiano.

As fontes de poluição estão associadas a lançamento de efluentes domésticos “in natura”, disposição de lixo doméstico a céu aberto, exploração mineral, garimpos,

desmatamentos e atividades agropastoris. Sendo essas atividades impactantes nos processos erosivos, assoreamento das calhas dos rios e lançamento de praguicidas nos solos. O extrativismo vegetal também é uma fonte de poluição que ocorre em quase toda a bacia, principalmente nas regiões de Mucugê, Andaraí, Utinga, Barra do Estivo, Iraquara e Bonito. Esse último município representa o pólo cafeeiro mais importante na bacia do rio Paraguaçu. Outra fonte de poluição significativa é o uso indiscriminado de pesticidas no rio e seus afluentes. A falta de saneamento básico nas cidades situadas próximas às margens do rio Paraguaçu são fatores que vêm provocando impactos negativos na região. Na região do baixo e médio curso do rio Paraguaçu ocorre também o lançamento de efluentes das indústrias situadas em Feira de Santana, e do Centro Industrial de Subaé (Agência da Bahia, 2010).

O clima da bacia, segundo a classificação de Köppen, apresenta uma grande variação, desde o clima semiárido (BSh), na parte oeste da bacia, até o tropical chuvoso, sem estação seca (Af), nas proximidades de Salvador, com os índices pluviométricos oscilando entre 700 mm a 2100mm (ANA, 2010). Entre esses extremos há ainda, os seguintes tipos climáticos:

- Am – Clima tropical chuvoso de monção, com breve estação seca;
- Aw – Clima tropical chuvoso de savana, com estação seca de inverno (sub-úmido);
- Aw' – Clima tropical chuvoso de savana, com estação seca de outono;
- Aw'' – Clima tropical chuvoso de savana, com duas estações secas.

A temperatura média anual da bacia é, em geral, superior a 25°C, excetuando-se as ilhas mesotérmicas, localizadas em trechos da Chapada Diamantina. No município de Morro do Chapéu, por exemplo, devido à influência do efeito orográfico, a temperatura média anual gira em torno de 21°C. A variação da amplitude térmica média anual é pequena da ordem de 5,5°C. Entretanto, a amplitude diária é grande, com forte calor durante o dia e baixas temperaturas à noite devido ao efeito da altitude e da continentalidade.

A umidade relativa média é de 74% sendo janeiro o mês mais seco em função da elevação da temperatura chegando até os registros inferiores a 68% por exemplo, na

cidade de Itaberaba. Em contrapartida, os meses de maio a junho são os mais úmidos, ultrapassando a 80%, chegando a 86% em algumas cidades próximas ao litoral (ANA, 2010).

A bacia do Rio Paraguaçu apresenta variadas tipologias vegetais, que incluem desde a Caatinga em diversos estágios, que domina a maior parte do centro-leste da bacia, até os remanescentes de Mata Atlântica (Floresta Ombrófila) que ocupam as zonas de clima mais úmido. Além destas tipologias, verifica-se ainda a ocorrência de manchas dispersas de cerrado, campos rupestres além de fragmentos de florestas estacionais (decidua e semi-decidua), que ocorrem na vertente oriental da Chapada Diamantina, a leste dos limites com a Caatinga (ANA, 2010).

O baixo curso do Rio Paraguaçu se desenvolve em um vale encaixado de rochas cristalinas que sustentam um relevo abrupto, com altitudes de até 220 m. Sua atual extensão é de 16 km, iniciando logo a jusante da Barragem Pedra do Cavalo até chegar à desembocadura na Baía de Iguape. O baixo curso apresenta uma batimetria muito irregular, com várias depressões e bancos arenosos. Enquanto as depressões podem chegar a profundidades de 10m, um grande número de bancos de areia aflora no baixo mar de sizígia. Neste caso, o escoamento é limitado a um sistema de canais pequenos, rasos e meandantes, de difícil navegação.

A bacia do Rio Paraguaçu, segundo o Plano Diretor de Recursos Hídricos do Médio e Baixo Rio Paraguaçu (BAHIA, 1996), está numa região de transição de sistemas meteorológicos. As principais cheias são registradas entre novembro e fevereiro, e, portanto, devem estar associadas à atuação de Frentes Frias e VCAS (BAHIA, 2004). Por outro lado, o período chuvoso (outono-inverno) está associado à ZCIT, aos Distúrbios de Leste e às Brisas.

A temperatura média anual na região é de 24°C, com amplitude térmica anual de 5°C, sendo a média mensal mínima de 21°C e a máxima de 26°C. Os meses de novembro a março são os que apresentam maiores temperaturas e julho e agosto os menores. A umidade relativa do ar apresenta dois períodos distintos:

- O período chuvoso, de abril a setembro, com mais de 78%, chegando ao máximo de 85% em julho;

- O período seco, de outubro a março, com menos de 75%, baixando para o mínimo de 72% de novembro a janeiro (BAHIA, 1984).
- A vazão média anual no Rio Paraguaçu é de 83 m³/s (1947 a 2003),

4.2 - Dados utilizados na modelagem chuva-vazão

Foram considerados neste estudo, os dados pluviométricos de 15 estações/postos pluviométricos disponibilizados pela Agência Nacional de Águas (ANA), contendo todos os dados mensais entre o período de 1980 a 1990. Esses dados foram inseridos na entrada do modelo chuva-vazão. Todas as 31 RNAs foram treinadas utilizando o algoritmo Levenberg-Marquardt. A motivação pela utilização do algoritmo Levenberg-Marquardt no treinamento das RNAs se justifica por ser esta uma ótima técnica para aproximação de relações não lineares, por ser rápida e por ser uma técnica já utilizadas por outros autores como LIMA e FERREIRA FILHO (2003) e SPERB et al. (1999) no treinamento de RNA com propósitos semelhantes e que apresentaram bons resultados.

A Série temporal de vazão mensal da bacia hidrográfica do rio Paraguaçu utilizada na modelagem foi a da estação fluviométrica de Argoim, localizada em Rafael Jambeiro. Todos os postos pluviométricos utilizados na modelagem chuva-vazão contêm observações entre janeiro de 1980 a dezembro de 1990. Os dados pluviométricos e fluviométricos para a entrada e saída do modelo de RNA foram previamente normalizados utilizando a planilha do Microsoft Office Excel 2007. O período de 24 meses foi considerado para previsão da rede neural treinada. As localizações espaciais dos postos pluviométricos estão fornecidas na Tabela 2.

Tabela 2 - Relação das estações/postos pluviométricos utilizadas no estudo.

Ordem	Estações/Postos Pluviométricos	Código	Lat(°)	Long(°)	Alt(m)
1	Argoim	1239007	-12,58	-39,53	265
2	Fazenda Iguaçu	1241001	-12,93	-41,07	317
3	Fazenda Santa Fé	1239020	-12,52	-39,87	179
4	Iaçu	1240016	-12,76	-40,21	237
5	Itaeté	1240012	-12,99	-40,96	299

6	Porto	1241017	-12,50	-41,30	355
7	Utinga	1241026	-12,50	-41,21	357
8	Valença	1339038	-13,37	-39,08	59
9	Entroncamento Valença	51750000	-13,28	-39,32	139
10	Fertém	51190000	-12,76	-41,33	320
11	Ituberá	1339012	-13,81	-39,17	114
12	Nazaré	1339034	-13,03	-39,03	35
13	Nilo Peçanha	1339044	-13,6	-39,12	6
14	Tesouras	51840000	-13,49	-39,73	350
15	Weenceslau	1339027	-13,68	-39,48	135

4.3 - Métodos para avaliação do desempenho das RNAs

Para avaliar o desempenho das RNAs alguns parâmetros estatísticos foram estimados. Todas as equações foram descritas em termos de quantidade de vazão observada (Q_o), quantidade de vazão estimada (Q_c) e a média da vazão observada ($\overline{Q_o}$). Onde a variável, Q_o é equivalente à quantidade de precipitação observada no posto pluviométrico, Q_c e correspondente à quantidade de precipitação estimada na simulação da rede neural e N é o número de observações.

a) Erro Médio Quadrático (EMQ), adaptado de OYEBODE et al. (2010):

$$EMQ = MSE = \frac{\sum_{i=1}^N (Q_o - Q_c)^2}{N} \quad (1)$$

b) Raiz do Erro Médio Quadrático (REMQU), adaptada de Adamowski e Sun (2010):

$$REMQU = \sqrt{\frac{\sum_{i=1}^N (Q_o - Q_c)^2}{N}} \quad (2)$$

c) Coeficiente de Correlação de Pearson (r) segundo Sousa (2008):

$$r = \frac{N \cdot \sum (Q_o \cdot Q_c) - \sum Q_o \cdot \sum Q_c}{\sqrt{[N \cdot \sum Q_o^2 - (\sum Q_o)^2] [N \cdot \sum Q_c^2 - (\sum Q_c)^2]}}$$

(3)

d) Coeficiente de Determinação ou regressão (R) segundo Jia et al., (2011):

$$R = r^2 \text{ ou } R = r^2 \times 100(\%)$$

(4)

e) Coeficiente de Eficiência (E), adaptada de Nash et al., (1970):

$$E = 1 - \frac{\sum (Q_o - Q_c)^2}{\sum (Q_o - \overline{Q_o})^2}$$

5. Resultados e Discussão

5.1 - Escolhas da arquitetura da rede neural

Neste estudo utilizou-se uma RNA denominada feedforward com três camadas, uma camada de entrada, uma camada intermediária e uma camada de saída, haja vista que esse é o padrão para maior parte dos problemas e, além disso, se tem uma restrição na complexidade da arquitetura dos modelos (ALCÁZAR et al., 2008). Todos os neurônios da camada intermediária possuem uma função de transferência do tipo sigmóide. A função de transferência na camada de saída é a função linear. Na rede feedforward com multicamadas o sinal passa numa só direção. As redes multicamadas (Multilayer Perceptrons - MLP) são as mais simples e mais comumente utilizadas nas arquiteturas de RNAs (ADAMOWSKI; SUN, 2010). As MLP podem ser treinadas utilizando diferentes algoritmos de aprendizagem.

Para o processo de aprendizagem da RNA os dados mensais de chuva de 15 postos pluviométricos no período de janeiro de 1980 a dezembro de 1990 foram divididos da seguinte forma 60% para treinamento, 20% para validação e 20% para simulação. Todo o processo feito na RNA foi desenvolvido no software MATLAB. O MATLAB possui uma biblioteca de funções específicas para criar, treinar e simular a RNA. Para avaliar a influência dos elementos proposto no treinamento da RNA foram testados vários algoritmos no próprio MATLAB que cria as RNA, manipula os dados, simula, calcula as estatísticas dos resultados e armazena todas as respostas num arquivo de saída.

A escolha da arquitetura da RNA foi realizada em duas etapas. A primeira etapa consiste em estabelecer o tipo de algoritmo de aprendizagem através da análise dos erros. Os tipos de algoritmos a serem testados foram:

Trainbfg - BFGS retropropagação quase-Newton;

Trainbr - Regularização Bayesiana;

Traincgb - Gradiente conjugado de retropropagação;

Traincgf - Gradiente conjugado de retropropagação;

Traingd – Gradiente descendente de retropropagação;

Trainгда – Gradiente descendente de retropropagação com regra de aprendizagem adaptativa;

Traingdm - Gradiente descendente com retropropagação de momentum;

Traingdx - Gradiente descendente com retropropagacao de momentum e regra de Aprendizagem adaptativa;

Trainlm - Retropropagação de Levenberg-Marquardt;

Trainoss - Retropropagação de passo secante;

Trainr - Aprendizagem com formação de funções elementares de ordem aleatória;

Trainrp - Retropropagação resiliente;

Trainscg - Gradiente de retropropagação conjugado e escalado;

A segunda consiste em variar as funções de transferência sigmóide tangente hiperbólica (*tansig*), sigmóide logarítmica (*logsig*) e linear (*purelin*) nas camadas intermediárias e de saída. Ainda, nessa etapa variam-se também o número de neurônios da camada escondida que seguiu as recomendações " $2n+1$ ", segundo (Lippmann, 1987; Hecht-Nielsen, 1990), " $2n$ " (Wong, 1991), " n " (Tang e Fishwick, 1993) neurônios escondidos para melhorar a previsão, onde n é o número de nós de entrada.

Após o treinamento se inicia a fase de teste da RNA onde será realizada uma comparação entre os valores observados e previstos, que é feita através de medidas de erros. Desta forma, a RNA que apresentar melhor desempenho será a utilizada na previsão das séries mensais de vazão.

Para verificação do melhor algoritmo de treinamento montou-se uma rede feedforward variando o número de neurônios na camada escondida e treinou-se com cada algoritmo disponível no Matlab2009a. Os desempenhos de cada algoritmo estão disponíveis na Tabela 3.

Algoritmos	Melhor Validação	R(todos)
trainlm	0,078	0,200
traingdm	0,881	0,707
traingdx	0,968	0,998
traingda	0,568	0,855
trainoss	0,906	0,0461
trainrp	0,875	0,987
trainbfg	0,888	0,985
trainbr	0,877	0,980
traincgb	0,077	0,0460
traincgf	0,880	0,0444
traingd	0,900	0,0440
trainr	0,871	0,878
trainscg	0,850	0,700

Tabela 3. Teste com diferentes algoritmos de treinamento.

A Tabela 4 mostra o desempenho de várias redes, com variações do número de neurônios na camada escondida e também das funções de transferência (ou função de ligação) nas duas camadas, escondidas e de saída, respectivamente. Dentre os resultados mostrados na Tabela 4 abaixo, o melhor desempenho foi obtido usando a rede com 12 neurônios na camada escondida, associada à função Tansig.

Tabela 4 – Teste com diferentes funções de transferência variando o número de neurônios, incluindo o coeficiente de regressão nas etapas de treinamento, validação e simulação.

Rede	Funções de Transferência	Neurônios	Treino R	Validação R	Teste R	Todos R
1	Tansig	04	-0,705	-0,811	0,762	-0,226
2	Tansig	08	-4,808	-2,404	0,896	0,782
3	Tansig	10	0,797	-9,616	0,231	0,773
4	Tansig	12	0,999	0,982	0,995	0,997
5	Tansig	14	0,999	0,962	0,9777	0,985
6	Tansig	16	0,312	0,078	0,078	0,200
7	Tansig	18	0,837	0	-5,048	0,806
8	Purelin	04	2,965	0,881	0,570	0,707
9	Purelin	08	0	-0,881	0,804	-0,206

10	Purelin	12	0	0	0,982	-0,854
11	Purelin	20	1,72	0,841	0,980	0,806
12	Purelin	22	-0,815	-0,986	-0,161	-0,802
13	Purelin	24	0,865	-4,087	0,731	0,806
14	Purelin	26	0,859	-2,644	0,705	0,806
15	Logsig	14	0,982	0,930	0,937	0,953
16	Logsig	6	-1,602	-1,322	0,867	0,730
17	Logsig	9	0,922	0,568	0,349	0,855
18	Purelin	10	0,287	0,846	7,211	0,323
19	Purelin	12	-0,869	0,906	0,897	0,0461
20	Tansig	12	0,880	0,954	0,970	0,848
21	purelin	14	0,589	0,972	0,950	0,616
22	Tansig	10	0,993	0,875	0,925	0,987
23	Tansig	11	0,931	0,994	0,987	0,982
24	Logsig	12	0,983	0,759	0,955	0,931
25	Purelin	13	0,988	0,946	0,967	0,928
26	Logsig	14	0,873	0,575	0,927	0,859
27	Logsig	15	0,996	0,974	0,915	0,992
28	Logsig	16	0,996	0,980	0,874	0,992
29	Logsig	18	0,991	0,921	0,880	0,988
30	Tansig	24	0,813	0,791	0,669	0,748
31	Tansig	30	0,936	0,127	0,489	0,711

Foram obtidas 31 arquiteturas de RNA *feed-forward*, conforme mostrada na Tabela 4 acima, com duas camadas, camada intermediária e de saída, variando a quantidade de neurônios de 04 a 30 na camada intermediária e alternando as funções de transferências *tangentes sigmóide*, *logarítmica sigmóide* e *purelin* nas duas camadas. Apenas foram consideradas as arquiteturas que apresentaram coeficiente de regressão representativo de toda etapa de treinamento (R todos) superior ou igual a 0,90. O critério utilizado na seleção de cada um dos modelos das RNAs foi através do

coeficiente de correlação entre os dados calculados e observados para o período de validação. A maioria das RNAs obtidas apresentavam funções de transferência *logsig/purelin* atuantes na camada intermediária e de saída, respectivamente, no total foram 31 RNAs.

A maioria das arquiteturas utilizou a função de transferência *tansig* na camada intermediária, Tabela 4. O maior valor do R (todos) foi 0,997 identificado na rede 4 com 12 neurônios em sua camada intermediária, seguido das RNAs 22,23,27,28,29,15,24 e 25 com valores de coeficiente de regressão igual a 0,999 para todo o treinamento. As figuras relacionadas abaixo mostra a performance da rede em relação a variação do erro de regressão em cada fase para a estação de Argoim. As figuras exibem os gráficos das regressões para cada uma das fases de treinamento, validação, teste e regressão no processo de previsão para 24 meses, respectivamente, na estação de Argoim.




Figura 8 - Regressão para a Previsão de 24 meses em Argoim, utilizando a função de transferência Tansig.

A Figura 8 mostra a simulação efetuada na RNA identificada como melhor modelo de previsão chuva-vazão para a rede 4. Pode ser visto que os picos de vazão estão quase todos concentrados sobre a reta. O melhor comportamento na fase de treinamento ficou em torno de 99,95% e coeficiente de correlação no processo de validação foi de aproximadamente 96,2%. De acordo com os valores da Tabela 7 pode ser identificado como o melhor coeficiente de eficiência, 0,999 e melhor erro de regressão entre os valores observados e previstos.




Figura 9 - Regressão para a previsão de 24 meses em Argoim, utilizando a função de transferência logsig.

A Figura 9 mostra a simulação da rede 15 efetuada pela RNA. Nota-se que quando se alterna a função de transferência e se varia a quantidade de neurônios na camada intermediária os resultados do treinamento não foram muito influenciados. O treinamento foi 99,9% e o coeficiente de correlação de validação foi igual a 98,2%, quase idêntico ao mostrado na Figura 8 com outro tipo de função de transferência.




Figura 10 - Regressão para a previsão de 24 meses em Argoim, utilizando a função de transferência Tansig.

A Figura 10 mostra a simulação da rede 5 feita na RNA. Quando se aumenta a quantidade de neurônios na camada intermediária e não se varia a função de transferência, observa-se que os dados de picos de vazão utilizados no treinamento foi igual 98,2% e o coeficiente de correlação de validação igual a 93%. Quando se compara esses valores com os dos modelos anteriores nota-se que os resultados não foram bons. A Figura 10 mostra picos de vazão não concentrados sobre a reta, obtendo assim erros consideráveis entre os valores observado e previsto.

Nesta simulação as respostas das redes utilizadas estão na Tabela 5, onde R são valores de correlação entre a variável observada e a variável estimada pela rede, que foram calculadas através das formulas estatísticas. Nessa Tabela é possível verificar que as funções de transferência *tansig1*, *tansig2* e *logsig* apresentaram coeficientes de regressão acima de 0,996. Portanto, essas funções foram utilizadas nos treinamentos da RNA.

Tabela 5 – Análise estatística da precipitação média mensal usada na RNA.

Função de transferência	Estatísticas		
	REMQ (mm)	R	E
Tansig 1	5,051	0,999	0,999
Tansig 2	9,613	0,997	0,994
Logsig	8,482	0,996	0,994

O índice de Eficiência ou Coeficiente de Eficiência (E), adaptada de Nash et al., (1970), pode variar de -1 a 1. Quando um índice é igual a 1 corresponde a uma relação perfeita entre a vazão estimada e a observada. Em síntese, quanto mais próximo de 1 o modelo atingir, mais preciso será.

Para avaliação da progressão do erro entre valores observado e previsto, utilizou-se a Raiz do Erro Médio Quadrático (REMQ), adaptada de Adamowski e Sun (2010). Quanto menor o erro ou mais próximo de zero melhor será o ajuste dos dados ao modelo obtido.

5.2 – Aplicações das RNAs à modelagem chuva-vazão

Para verificação do melhor algoritmo de treinamento para a rede *feed-forward*, disponíveis no MatLab 2009a, foi considerada uma rede com 30 neurônios na camada escondida, correspondente à quantidade de postos, função de transferência *logsig* na camada intermediária e *purelin* na camada de saída. A função de adaptação para o treinamento foi a *Trainlm*. Nessa arquitetura apenas o algoritmo de aprendizagem sofreu variações conforme Tabela 6. Na Tabela 6 é possível verificar que o algoritmo *trainlm* (Retropropagação de Levenberg-Marquardt) apresentou o menor erro médio quadrático normalizado (25,52) e maior coeficiente de determinação (0,99) para um tempo de interações de 1 segundo. O algoritmo de aprendizagem com formação de funções elementares de ordem aleatória (*traingdx*) apresentou erro médio 92,42 e coeficiente de regressão de 0,997. Porém, o tempo de execução da RNA foi em torno de 8 segundos, Tabela 6.

Desse modo, para essa pesquisa foi utilizado o algoritmo com o melhor desempenho e maior coeficiente de regressão, ou seja, o *trainlm*, conforme OYEBODE et al., (2010). Esse algoritmo é considerado uma ótima técnica para aproximação de relações não lineares (MACHADO, 2005).

Tabela 6 – Teste da RNA *Feed-forward* com diferentes algoritmos de treinamento.

Algoritmos	R (todos)	Tempo	Épocas (número de iterações)
Trainbfg	0,806	1 seg	1
Trainbr	0,616	1 seg	10
Traincgb	0,707	1 seg	17
Traincgf	0,748	1 seg	8
Traincgp	0,711	2 seg	6
Traingd	0,323	0 seg	2
Traingdm	-0,226	1 seg	1
Traingda	0,953	0 seg	13
Traingdx	0,806	8 seg	14
Trainlm	0,997	8 seg	12
Trainoss	0,848	0 seg	16
Trainr	0,855	0 seg	2
Trainrp	0,987	0 seg	10
Trainseg	0,777	13 seg	10

Quando se avalia o desempenho de todo o processo de treinamento das redes com menores MSE foi possível identificar o melhor desempenho para a RNA 4. Essa

RNA apresenta o maior coeficiente de eficiência 0,999 e o menor REMQ 5,05 m³/s, conforme pode ser visto na Tabela 7.

Tabela 7 – Desempenho da RNA com base no coeficiente de eficiência (E) e na raiz do erro médio quadrático (REMQ).

Redes	Funções de transferência	E	REMQ
4	Tansig 1	0,999	5,051
5	Tansig 2	0,994	9,613
15	Logsig	0,994	8,482

Os dados pluviométricos das 15 estações em estudo no processo de treinamento, validação e simulação na RNA 4, com 12 neurônios em sua camada intermediária e função de transferência tansig1, no período de 1980 a 1990, apresentaram bons resultados e foi considerado o melhor modelo de previsão de vazão em Argoim, Figura 11. Nesse caso o coeficiente de regressão foi igual a 99,95%.




Figura 11 – Melhor resultado na RNA

A Figura 12 apresenta os resultados para as fases de treinamento, validação, simulação para a rede 5, com 14 neurônios em sua camada intermediária e função de transferência tansig2 no período estudado. O coeficiente de regressão foi de 0,997 e a raiz do erro médio quadrático (REMQ) igual a 9,613 m³/s. Apresenta também erro nos picos de vazão, quando comparado com os dados observados.




Figura 12 - Dispersão das vazões médias mensais estimadas pela RNA, usando a função de transferência tansig 2.

A Figura 13 quando apresenta os resultados para os processos de treinamento, validação e simulação da rede 15, com 14 neurônios na camada intermediária. O valor do coeficiente de regressão R² foi igual a 0,996, menor que o caso anterior. Quando a função de transferência foi alterada para logsig, verificou que o erro entre valores observado e previsto diminuiu para 8,482m³/s.




Figura 13 - Dispersão das vazões médias mensais estimadas pela RNA, usando a função de transferência logsig.

6. Conclusão

No processo de escolha dos tipos de arquitetura, a rede neural do tipo *feed-forward*, disponíveis no MatLab 2009a, apresentou o melhor desempenho no processo, com tempo de interação razoável nas diversas arquiteturas.

As funções de transferências, *tansig* e *logsig* presentes nas camadas intermediárias e de saída da RNA, foram as que apresentaram os melhores resultados. Para se avaliar o desempenho de todas as RNAs foram utilizadas quatro estatísticas: Coeficiente de determinação (R^2), Coeficiente de Eficiência (E), Erro médio Quadrático (MSE) e Raiz do Erro Médio quadrático(REMQ). A RNA escolhida para a modelagem chuva-vazão contém 14 neurônios na camada intermediária e função de transferência *tansig* nas camadas intermediária e de saída. Na previsão para os dois anos, os valores médios de regressão foram iguais a 0,999 na fase de treinamento, 0,982 na validação e 0,995 na fase de teste. Já o MSE médio dos 15 postos pluviométricos foi de 25,519 mm.

O critério de seleção para escolher as melhores arquiteturas foi o de avaliar o desempenho de generalização da RNA através de análises estatísticas entre os dados

estimados e observados para o período de teste. Para uma melhor avaliação, considerou-se o coeficiente de determinação (R^2) com valores maiores ou iguais a 90%; esses resultados foram apresentados na Tabela 4.

De forma geral, a escolha de outros algoritmos de propagação, números de neurônios diferentes ou uso de outras funções de transferência podem melhorar a eficiência da previsão. Em particular, para modelos de previsão de longo prazo são necessárias mudanças mais significativas, tais como: nova arquitetura, mudanças na forma de entrada dos dados e criação ou modificação dos algoritmos de aprendizagem.

7. Referências

ALVES, J. M. B.; KAYANO, M. T. Estudos Preliminares da Precipitação no Sul do Ceará durante a Pré-Estação das Chuvas. **Climanálise**, 6, p. 42-50, 1991.

Almeida, R.; Barbosa, P.S.F. Previsão de secas hidrológicas com base em um modelo de redes neurais artificiais. In: **VII Simpósio de Recursos Hídricos do Nordeste**. São Luís, MA, 2004.

ANA – Agência Nacional de Águas. Disponível em <<http://hidroweb.ana.gov.br>>. Acesso em 06/05/2012.

ARAÚJO, L. E. **Análise estatística de chuvas intensas na Bacia Hidrográfica do Rio Paraíba**. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Campina Grande, 2006.

BAHIA. **Plano Diretor de Recursos Hídricos da Bacia Hidrográfica do Rio Paraguauçu**. Documento Síntese. Superintendência de Recursos Hídricos. Governo do Estado da Bahia, p.195, 1993.

BATISTA, A.L.F. River flow analysis and forecasting using time series and artificial neural networks models. 2009. 79p. **Dissertation** (Master Program in Systems Engineering) – Federal University of Lavras, Lavras.

CHOKMANI, K.; Ouarda, T.B.M.J.; Hamilton, S.; Ghedira, M. H.; Gingras, H. **Comparison of ice-affected streamflow estimates computed using artificial neural networks and multiple regression techniques.** *Journal of Hydrology*, v. 349, p. 383-396, 2008.

CRESPO, J. L.; Mora, E. Drought estimation with neural networks. *Advances in Engineering Software*, nº 18, pp. 167 – 170, 1993.

GARCEZ, L. N.; ALVAREZ, G. A. **Hidrologia.** São Paulo: Edgard Blücher, 2ª edição, 1988, 291p.

GLEZAKOS, T. J.; A. Tsiligridis, T. A.; Iliadis, L. S.; Yialouris, C. P.; Maris, F. P.; Ferentinis, K. P. Feature extraction for time-series data: **An artificial neural network evolutionary training model for the management of mountainous watersheds.** *Neurocomputing*, V. 73, p. 49-59, 2009.

GUEDES, S. V.; Roni. **Previsão de Seca na Bacia Hidrográfica do Açude Epitácio pessoa com base em Redes Neurais artificiais.** Dissertação do Curso de meteorologia da Universidade federal de Campina Grande, Paraíba em 25/02/2011.

LANA, X.; Serra, C.; Burgueno, A. **Patterns of monthly rainfall shortage and excess in terms of the standardized precipitation index.** *Int. J. Climatol.* 21, 1669 1691, 2001.

LIMA, C.H.R.; Ferreira Filho, W.M.; **Análise de modelos de Redes Neurais aplicada ao processo chuva-deflúvio no semiárido.** In: Simposio Brasileiro de Recursos Hídricos, 15.,2003, Curitiba. Relação de Trabalhos. Curitiba: ABRH, 2003.

MELESSE, A. M.; Hanley, R. **Artificial Neural Network Application for Multi Ecosystem Carbon Flux Simulation,** *Ecological Modeling* 189, 305–314, 2005.

MARCUS F.M. Cruz, Lucas D.Rodrigues, Bruno R.Versiani. **Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais** – *Revista Brasileira de Recursos Hídricos* – Volume 15 n.1 Jan/Mar 2010, 121 - 132.

MORAIS, B. S.; Lins, R. O. C.; Silva, G.B.L. **Previsão de seca usando redes neurais artificiais,** IX Simpósio de Recursos Hídricos do Nordeste, Salvador, Bahia, 2008.

MACHADO, F. W. **Modelagem Chuva-Vazão mensal utilizando redes neurais artificiais**, Dissertação de Mestrado em Engenharia em Recursos Hídricos e Ambiental, Universidade Federal do Paraná, 2005.

MACEDO, H. J. ; Maria. **Análise do Índice Padronizado de Precipitação (SPI) na Caracterização das Secas do Semiárido Brasileiro. 2010**. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Paraíba.

OLIVO, A. A.; Silva, J. D. S.; Vijaykumar, N. L. **Previsão de cheias fluviais usando redes neurais artificiais**. VI Simpósio de Recursos Hídricos do Nordeste. Maceió/AL, 2002.

PEREIRA, M. C. N. **Composição do Comitê da Bacia Hidrográfica do Rio Paraguaçu-BA: Análise da origem geográfica e do setor econômico representado por seus membros como fatores intervenientes na gestão participativa de recursos hídricos**. Dissertação (Mestrado em Desenvolvimento Sustentável), Universidade de Brasília, Brasília, 2008.

RAMOS, A.M.; Galvão, C.O. (2001). **Estabilidade de redes neurais em modelagem hidrometeorológica**. In: XIV Simpósio Brasileiro de Recursos Hídricos - V Simpósio de Hidráulica e Recursos Hídricos dos países de língua oficial portuguesa: gestão de Recursos Hídricos – O desafio da prática. Aracaju / SE, 2001

SOUSA, W. S.; SOUSA, F. A. S. **Rede Neural Artificial Aplicada à Previsão de Vazões Médias Mensais da Bacia Hidrográfica do Rio Piancó**, *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 14, n. 2, p. 173-180, 2010.

TOKAR, A. S.; Markus, M. **Precipitation – runoff modelling using artificial neural networks and conceptual models**. *Journal of Hydrologic Engineering*, Reston: ASCE, V. 5, n. 2, p. 156 – 161, Apr. 2000.

UVO, C. R. B. **A zona de convergência intertropical (ZCIT) e sua relação com a**

precipitação na região norte e nordeste brasileiro. Dissertação de Mestrado em Meteorologia. INPE. São José dos Campos, 1989.

YANG, C.C. Chang, L. C.; Chen, C. S. **Comparison of integrated artificial neural network with time series modeling for flood forecast.** **Journal of Hydroscience and Hydraulic Engineering**, Vol. 17, nº 2, 1999.

VALENÇA, M; Ludemir, T. ***Monthly streamflow forecasting using an Neural Fuzzy Network Model.*** IEEE - Neural Networks. Proceedings. Sixt Brazilian Symposium on, 2000.