



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



DISSERTAÇÃO

REDE NEURAL ARTIFICIAL APLICADA À PREVISÃO DE VAZÕES MÉDIAS
MENSAIS DA BACIA HIDROGRÁFICA DO RIO PIANCÓ

WANDERSON DOS SANTOS SOUSA

CAMPINA GRANDE – PB

Fevereiro de 2008



WANDERSON DOS SANTOS SOUSA

**REDE NEURAL ARTIFICIAL APLICADA À PREVISÃO DE VAZÕES MÉDIAS
MENSAIS DA BACIA HIDROGRÁFICA DO RIO PIANCÓ**

Dissertação apresentada ao Curso de
Mestrado em Meteorologia da
Universidade Federal de Campina Grande
em cumprimento às exigências para a
obtenção do Grau de Mestre.

Área de Concentração: Meteorologia de Meso e Grande Escalas

Orientador: Prof. Dr. Francisco de Assis Salviano de Sousa

CAMPINA GRANDE – PB

Fevereiro de 2008

S725r Sousa, Wanderson dos Santos.

Rede neural artificial aplicada à previsão de vazões médias mensais da Bacia Hidrográfica do Rio Piancó. / Wanderson dos Santos Sousa. - Campina Grande - PB: [s.n], 2008.

75 f.

Orientador: Professor Dr. Francisco de Assis Salviano de Sousa.

Dissertação (Programa de Pós-Graduação em Meteorologia) - Universidade Federal da Paraíba; Centro de Tecnologia e Recursos Naturais.

1. Previsão de vazão. 2. Hidrologia. 3. Gestão de recursos hídricos. 4. Vazão média. 5. Redes Neurais Artificiais. 6. Modelagem de relação não linear. 7. Bacia do Rio Piancó. 8. Meteorologia de meso e grande escala. I. Sousa, Francisco de Assis Salviano de. II. Título.

CDU: 556(043.3)

WANDERSON DOS SANTOS SOUSA


REDE NEURAL ARTIFICIAL APLICADA À PREVISÃO DE VAZÕES MÉDIAS
MENSAIS DA BACIA HIDROGRÁFICA DO RIO PIANCÓ

DISSERTAÇÃO APROVADA EM 26/02/2008

BANCA EXAMINADORA



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



Prof. Dr. ENILSON PALMEIRA CAVALCANTI
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Prof.ª Dra. JOSICLÊDA DOMICIANO GALVÊNCIO
Departamento de Ciências Geográficas
Universidade Federal de Pernambuco

DEDICATÓRIA

Aos meus queridos pais, Josadark e Marileide, e a minha irmã, Aila Taíse.

AGRADECIMENTOS

A Deus, pela sua presença constante em minha vida, sem a qual reconheço, não ultrapassaria as barreiras que se opuseram contra esse ideal.

À minha família, meus pais, Josadark Soares de Sousa e Marileide dos Santos Sousa, e minha irmã, Aila Taíse dos Santos Sousa, o berço de todos os meus conhecimentos mais valiosos.

Ao orientador Francisco de Assis Salviano de Sousa, que me acolheu em seu ambiente de trabalho, sempre prestativo e atencioso, contribuindo para a minha formação desde o início.

A Trantavahi Venkata Ramana Rao, pelo compartilhamento de sua expressiva sabedoria, oferecendo o melhor de si para que eu me realizasse profissionalmente.

Aos meus colegas Lincoln Eloi e Djane Fonseca, com os quais compartilhei dúvidas e soluções.

Aos funcionários, professores e alunos da Unidade Acadêmica de Ciências Atmosféricas, pelo auxílio, atenção e compreensão no meu trajeto, e pelos quais adquiri grande carinho.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES, pelo apoio financeiro durante o desenvolvimento desta pesquisa..

A todos que direta ou indiretamente, contribuíram para a elaboração desta dissertação.

SUMÁRIO

DEDICATÓRIA	v
AGRADECIMENTOS	vi
SUMÁRIO	vii
LISTA DE FIGURAS	ix
LISTA DE TABELAS	x
RESUMO	xi
ABSTRACT	xii
1 INTRODUÇÃO	13
2 FUNDAMENTAÇÃO TEÓRICA	15
2.1 Ciclo hidrológico	15
2.1.1 Precipitação	16
2.1.2 Infiltração	17
2.1.3 escoamento superficial	17
2.1.4 Evaporação	18
2.2 Modelagem hidrológica	19
2.2.1 Modelo chuva-vazão	21
2.3 Redes neurais artificiais	22
2.3.1 Histórico	24
2.3.2 Neurônio artificial	28
2.3.3 Função de transferência	29
2.3.4 Características da rede neural artificial	30
2.3.5 Processo de aprendizagem	32
2.3.6 Vantagens e desvantagens da RNA	33
3 REVISÃO BIBLIOGRÁFICA	36
4 MATERIAL E MÉTODOS	42
4.1 Área de Estudo	42
4.2 Dados	44
4.2.1 Vazão	44

4.2.2 Precipitação	45
4.3 Rna proposta	46
4.4 Índices de desempenho	49
5 RESULTADOS E DISCUSSÃO	51
6 CONCLUSÕES E SUGESTÕES	64
REFERÊNCIAS BIBLIOGRÁFICAS	66
APÊNDICE A	73
APÊNDICE B	78

LISTA DE FIGURAS

Figura 1	Ciclo hidrológico. Fonte: UFRB	16
Figura 2	Esquema dos constituintes da célula neural	24
Figura 3	Neurônio artificial projetado por McCulloch	25
Figura 4	Rede de perceptrons proposta por Roseblatt	26
Figura 5	Redes ADALINE e MADALINE	27
Figura 6	Estrutura do método Backpropagation	28
Figura 7	Estrutura de uma RNA em camadas	31
Figura 8	Localização da bacia do Piancó, destacando a área de estudo delimitada pelo posto Piancó	43
Figura 9	Hidrograma característico de uma bacia hidrográfica	45
Figura 10	Zoom do mapa do estado da Paraíba com as estações pluviométricas e fluviométrica para a região estudada	46
Figura 11	Hidrograma e hietograma em: (a) Piancó, (b) Santana dos Garrotes, (c) Boa Ventura, (d) Itaporanga, (e) Nova Olinda, e (f) Média dos postos, para o período estudado	53
Figura 12	Resultados obtidos utilizando a arquitetura RC310L2, divididos em três períodos, treinamento (a), validação (b) e teste (c)	59
Figura 13	Resultados obtidos utilizando a arquitetura RC315L, divididos em três períodos, treinamento (a), validação (b) e teste (c)	63

LISTA DE TABELAS

Tabela 1	Funções de transferências	30
Tabela 2	Precipitação em 1998 nas estações estudadas neste trabalho	53
Tabela 3	Melhores arquiteturas, considerando o coeficiente de determinação com valores maiores ou iguais a 90 por cento, para o período de teste	55
Tabela 4	Quantidade de arquiteturas, considerando os neurônios na camada intermediária	56
Tabela 5	Quantidade de inicializações por arquitetura	56
Tabela 6	Melhores arquiteturas, considerando o erro padrão de estimativa com valores menores que sete unidades, para o período de teste	57
Tabela 7	Média das inicializações dos parâmetros estatísticos em cada arquitetura	60
Tabela 8	Melhores arquiteturas pela média das inicializações, considerando o coeficiente de determinação com valores maiores ou iguais a 90 por cento, para o período de teste	61

RESUMO

A previsão de vazão em um sistema hídrico é uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos. Essa técnica pode ser considerada um dos principais desafios relacionados ao conhecimento integrado da climatologia e da hidrologia de uma bacia hidrográfica. O objetivo deste trabalho foi o de modelar a relação não-linear entre chuva e vazão na bacia hidrográfica do rio Piancó, no semi-árido paraibano, utilizando a técnica de Redes Neurais Artificiais (RNA). Aqui foi avaliada a capacidade da RNA modelar o processo chuva-vazão em base mensal. Considerou-se durante o treinamento da RNA a influência da arquitetura da rede e da inicialização dos pesos. No final do treinamento foi escolhida a melhor arquitetura, para modelar vazões médias mensais na bacia estudada, com base no desempenho do modelo. A arquitetura de RNA que produziu melhor resultado foi a RC315L com valores para o coeficiente de determinação, de eficiência e erro padrão da estimativa de 92,0 %, 77,0 % e 8,29 respectivamente.

ABSTRACT

The streamflow forecasting in a water system is one of the techniques used to minimize the impact of the uncertainties of the climate on the administration of the water resources. That technique can be considered one of the principal challenges related to the integrated knowledge of the climatology and of the hydrology of the river basin. The aim of this work was it of modeling the no-lineal relationship between rainfall and streamflow in the Piencó river basin, in the paraibano semiarid, using the technique of Artificial Neural Networks (ANN). Here the capacity of ANN was evaluated to model the process rainfall-runoff in monthly base. It was considered, during the training of ANN, the network architecture and, weights initialization influence. In the end of the training it was chosen the best architecture, to model the streamflow monthly mean in the studied basin, with base in the acting of the model. The architecture of ANN that produced better result was RC315L with values for the determination coefficient, efficiency coefficient and standard estimate error (SEE) equal to 92.0%, 77.0% and 8.29 respectively.

1. INTRODUÇÃO

Nos últimos anos, o aumento da população, a necessidade de alimentos e energia, e o crescimento da atividade industrial têm aumentado significativamente a demanda por água. O atendimento a essa demanda constitui, atualmente, um dos problemas mais importantes em muitas partes do mundo.

Agravando a situação, os mecanismos climáticos que produzem as precipitações no semi-árido são complexos, principalmente quando aliados a fatores como orografia da região, sistemas atmosféricos de meso e grande escalas e a proximidade do mar, resultam em forte variabilidade espaço-temporal das precipitações que podem gerar eventos extremos como grandes cheias ou secas devastadoras. Felizmente, hoje já existe a possibilidade de se prever, com alguma antecedência, as probabilidades de ocorrência de eventos extremos e os períodos em que provavelmente ocorrerão. Essas informações podem ser usadas para minimizar os efeitos negativos desses eventos.

A previsão de vazão num sistema hídrico é uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos, podendo considerá-la um dos principais desafios relacionados ao conhecimento integrado da climatologia e hidrologia. A utilização de vazões previstas para a otimização de operação de reservatórios é sugerida por muitos autores (Hamlet et al., 2002; Barros et al., 2003), alguns entendem que o seu uso é preferível, embora com algum erro, a fazer o controle de reservatório sem previsões (Labadie, 2004).

Favoreto et al. (2001) mencionam que uma das áreas promissoras para grande aplicabilidade das Redes Neurais Artificiais é a previsão de séries hidrológicas, vazão e precipitação, nos seus mais diferentes usos. Santos e Filho (2003) apresentam alguns resultados que mostram a potencialidade da técnica.

O conhecimento antecipado da vazão de uma bacia hidrográfica é usado mais comumente para previsão de cheias, previsão de umidade do solo agricultável, previsão dos níveis de água de um rio navegável e no conhecimento da disponibilidade hídrica no abastecimento de água para irrigação e produção de energia elétrica (Tucci et al., 2003).

Atualmente muitos modelos hidrológicos estão sendo utilizados em estudos ambientais, modelos distribuídos ou concentrados, conceituais ou empíricos, discretos ou contínuos. O objeto de estudo da maioria destes modelos é a bacia hidrográfica ou bacia de drenagem, isso se deve ao fato da simplicidade que oferece na aplicação do balanço hídrico (Villela et al., 1975).

O modelo de Rede Neural Artificial (RNA) foi escolhido dentre os vários modelos existentes por ser um modelo empírico que tem sido amplamente aceito como uma forma potencialmente útil de se modelar sistemas não-lineares complexos com grande quantidade de dados. Esses modelos são particularmente úteis em situações onde as relações dos processos físicos ainda não são completamente compreendidas. Os modelos RNAs podem ainda substituir os modelos matemáticos e estatísticos convencionais ou associar-se a eles.

O objetivo deste estudo é o de propor um modelo baseado em técnicas de Redes Neurais Artificiais que sirva para simular e prever vazões médias mensais na estação fluviométrica localizada na cidade de Piancó, no semi-árido paraibano. Isso será possível a partir da elaboração de várias arquiteturas de RNA com base em dados de precipitação média mensal, a montante dessa estação, envolvendo, portanto, parte da bacia hidrográfica do rio Piancó.

O espaço de tempo considerado, mensal, é importante porque, além de ser ideal para o gerenciamento e planejamento dos recursos hídricos, nele pode-se desprezar a ocorrência de um evento isolado de tempestade e, ainda possibilita melhoria na representatividade da precipitação regional sobre a bacia hidrográfica.

Apesar da metodologia, RNA, não ser recente, ainda assim deverá contribuir como nova forma de abordagem de previsão hidrológica em bacias hidrológicas localizadas em regiões semi-áridas, com poucas disponibilidades de dados e de características físicas da bacia hidrográfica.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Ciclo hidrológico

Desde que a vida surgiu na Terra, há pouco mais de 3,5 bilhões de anos, a água foi fundamental como base da alimentação dos organismos e como meio de desenvolvimento de plantas e animais. A água é tão bem aproveitada que, ao longo de milhões de anos, o mesmo estoque original em movimento alimenta rios, lagos e aquíferos ou reservatórios subterrâneos no ciclo hidrológico. A água é a substância mais reciclável na natureza e faz parte essencial de todas as formas de vida dos reinos vegetal e animal, encontrando-se por toda a parte na crosta terrestre e na atmosfera.

No Planeta Terra, dois terços da superfície, ou 71% é coberto por água. De toda a água existente na Terra, apenas 2,5% é doce, sendo que 70% estão nas geleiras polares assim restando 0,75% para dividir entre 6 bilhões de humanos. De acordo com a Organização das Nações Unidas (ONU), no último meio século, a disponibilidade de água por ser humano diminuiu 60%, enquanto que a população aumentou 50%.

Teoricamente, o Brasil não deveria se preocupar com a falta de água. O problema é a má distribuição geográfica. Infelizmente, 78% da água do país se concentra na região norte, a mais desabitada. Não há como sair dessa situação, a não ser a conscientização de poupar hoje para não faltar amanhã.

O ciclo hidrológico, Figura 1, é o movimento da água entre os continentes, oceanos e a atmosfera. Pode-se definir ciclo hidrológico como a seqüência fechada de fenômenos pelos quais a água passa do globo terrestre para a atmosfera, na fase de vapor, e regressa àquele, nas fases líquida e sólida. Essa seqüência é representada pelos seguintes componentes: precipitação, infiltração, escoamento superficial, evaporação, transpiração, evapotranspiração, sublimação e condensação.

O CICLO HIDROLÓGICO




Figura 1. Ciclo hidrológico. Fonte: UFRB.

2.1.1 Precipitação

Na atmosfera, o vapor de água condensado forma nuvens que dependendo das condições do clima pode ser transformada em chuva, neve ou granizo. Essa transformação provoca o que se chama de precipitação. A precipitação é a fonte de água que origina o ponto de partida para todas as análises hidrológicas de pequenas bacias hidrográficas. A precipitação pode ocorrer de várias formas: em forma pluvial, granizo, neve etc. As principais características pelas quais se pode identificar uma chuva são: intensidade, duração e frequência.

A precipitação ocorre sobre a superfície do planeta, tanto nos continentes como nos oceanos. Nos continentes, uma parte das precipitações é devolvida para a atmosfera, graças

à evaporação, outra parte acaba desaguando nos oceanos depois de percorrer os caminhos recortados pelos rios. Os oceanos, portanto, recebem água de duas fontes: das precipitações e do desaguamento dos rios, e perdem pela evaporação. Na atmosfera, o excesso de vapor sobre os oceanos é transportado para os continentes, em sentido inverso ao desaguamento.

A precipitação é alta na, zona equatorial, especialmente sobre as florestas tropicais. Nas regiões sob a influência das altas subtropicais, a precipitação é baixa. Já na zona temperada, existem regiões de precipitação relativamente alta, onde predominam os sistemas frontais. Na zona polar, as precipitações são baixas.

2.1.2 Infiltração

A infiltração da água no solo é um processo dinâmico de penetração vertical da água através da superfície do solo. A forma com que este processo ocorre depende, fundamentalmente, do tipo de solo e da quantidade de água disponível. Paixão et al. (2004) menciona que o conhecimento da taxa de infiltração da água no solo é de fundamental importância para definir técnicas de conservação do solo, planejar e delinear sistemas de irrigação e drenagem, bem como auxiliar na composição de uma imagem mais real da retenção da água e aeração no solo.

A diversidade de solos quanto à textura, a estrutura, o perfil vertical e horizontal e a variabilidade espacial é que torna a quantificação da infiltração um dos processos mais difíceis entre os processos do ciclo hidrológico.

Muitos fatores intervêm no processo de infiltração, dentre os principais temos: a umidade do solo, quanto mais saturado estiver o solo, menor será a infiltração; a permeabilidade do solo, quanto mais fino for o solo menor será a infiltração; a temperatura do solo; a ocupação do solo, pois os processos de urbanização e devastação da vegetação diminuem drasticamente a quantidade de água infiltrada; e a topografia, onde declives acentuados favorecem o escoamento superficial direto diminuindo a oportunidade de infiltração. Um solo seco tem maior capacidade de infiltração inicial devido ao fato de se somarem as forças gravitacionais e as de capilaridade (Villela et al. 1975).

2.1.3 Escoamento Superficial

Da precipitação que atinge o solo, parte infiltra, parte permanece retida nas depressões do terreno ou como película em torno das partículas sólidas, a parcela restante

escoa superficialmente. Das fases básicas do ciclo hidrológico, talvez a mais importante para o engenheiro seja exatamente essa, denominada escoamento superficial, que é a fase que trata da ocorrência e do transporte da água na superfície terrestre.

Diversos são os fatores que influenciam o escoamento superficial, dentre os quais se podem destacar os de natureza climática e fisiográfica. Dentre os fatores de natureza climática, destacam-se a intensidade, a duração da chuva e a precipitação antecedente, ou seja, a condição de umidade da bacia. Como fatores de natureza fisiográfica, ou seja, mais ligados às características físicas da bacia, pode-se apontar a área da bacia de contribuição; a conformação topográfica da bacia (declividades, depressões acumuladoras e retentoras de água, forma da bacia), condições da superfície do solo e constituição geológica do subsolo (existência de vegetação, florestas, capacidade de infiltração, permeabilidade do solo, natureza e disposição das camadas geológicas) e as obras de controle e utilização da água à montante (irrigação ou drenagem do terreno, canalização ou retificação de cursos d'água, construção de barragens).

Geralmente os estudos de precipitação são aplicados à quantificação do escoamento superficial, que explica grande parte da vazão dos cursos d'água. Apesar disso, denomina-se, escoamento superficial tanto o excesso de precipitação que ocorre logo após uma chuva que se desloca livremente pela superfície do terreno, como o escoamento de um rio, que pode ser alimentado tanto pelo excesso de precipitação como pelas águas subterrâneas.

Raudikivi (1979) menciona que toda a água que chega aos rios através do escoamento superficial ou através do escoamento de base é transportada pela rede de drenagem até alcançar novamente os oceanos reiniciando-se o ciclo hidrológico. Mas para que o ciclo hidrológico não se altere, é preciso preservar as florestas, nas quais os mananciais ficam protegidos, e os oceanos, de onde evapora boa parte da água que abastece, mais tarde, rios, lagos, e mananciais. Com isto, se gera um grande desafio para a humanidade, visto que o homem não economiza, polui, envenena e não preserva os ecossistemas.

2.1.4 Evaporação

A transferência de água da superfície do Globo para a atmosfera, sob a forma de vapor, dá-se por evaporação direta, por transpiração das plantas e dos animais e por sublimação, passagem direta da água da fase sólida para a de vapor. A energia solar é a

fonte da energia térmica necessária para a passagem da água das fases líquida e sólida para a fase do vapor, dando também origem as circulações atmosféricas que transportam vapor de água e deslocam as nuvens.

A evaporação é medida em milímetros (mm), e um mm de água evaporada corresponde a um litro de água que se evaporou de uma superfície de um metro quadrado de área, durante um certo intervalo de tempo. Para essa medição usam-se os evaporímetros que podem ser de diferentes tipos, por exemplo, atmômetros e tanques de evaporação. A razão da evaporação depende de muitos fatores, os mais importantes são: a radiação incidente, a temperatura, a velocidade do vento, a humidade, a estabilidade do ar e a disponibilidade da água.

O estudo da evaporação e da evapotranspiração reveste-se de especial importância, mesmo quando são considerados apenas aspectos puramente meteorológicos. O vapor d'água age como um eficiente meio de transporte meridional de energia, interferindo no balanço energético em escala planetária. As áreas que atuam como fontes importantes do vapor d'água atmosférico, tais como a zona tropical dos oceanos e as florestas tropicais, representam sumidouros de energia. Reciprocamente, as porções da atmosfera que atuam como sumidouros de vapor d'água são, concomitantemente, fontes de energia, face ao calor latente liberado quando do vapor d'água à fase líquida ou sólida (Varejão-Silva, 2001).

2.2 Modelagem hidrológica

Um modelo hidrológico pode ser definido como uma representação matemática do fluxo de água e seus constituintes sobre alguma parte da superfície e/ou subsuperfície terrestre. Há uma estreita relação entre a modelagem hidrológica, a biológica e a ecológica, pois o transporte de materiais pela água é influenciado por atividades biológicas que podem aumentar ou diminuir a quantidade desses materiais na água, e o regime do fluxo de água pode afetar diversos habitats. Além disso, a hidrologia está estreitamente relacionada às condições climáticas e, portanto, modelos hidrológicos e atmosféricos deveriam estar acoplados, sendo que, na prática, um estreito acoplamento torna-se bastante difícil, uma vez que modelos atmosféricos trabalham com resolução espacial muito maior que as utilizadas na modelagem hidrológica (Maidment, 1993).

Um modelo pode ser considerado como uma representação simplificada da realidade, auxiliando no entendimento dos processos que envolvem esta realidade. Esses estão sendo cada vez mais utilizados em estudos ambientais. De maneira geral, um modelo é um sistema de equações e procedimentos compostos por variáveis e parâmetros. Os parâmetros mantêm seu valor inalterado durante todo o processo estudado. Assim, um parâmetro possui o mesmo valor para todos os intervalos de tempo, o que não significa que ele não possa variar espacialmente. Por outro lado, as variáveis podem mudar ao longo do tempo que o modelo estiver sendo executado.

Araújo (2005) menciona que a importância dos modelos está, entre outros aspectos, na simulação e previsão dos fenômenos físicos, sobretudo os de frequência rara, a curto, médio e longo prazo. Através dos modelos se podem obter relações de causa-efeito, sem haver realizado interação com os sistemas reais. Algumas vantagens são apresentadas pelos modelos em seu uso, dentre elas: proporcionar respostas quantitativas dos fenômenos físicos, interpolar, simular e prever. Os modelos podem ainda ajudar na definição de metodologias, categorizarem a influência das variáveis que participam do modelo e sugerir prioridades na investigação do problema.

Os processos ambientais no mundo real são geralmente bastante complexos e são tipicamente tridimensionais e dependentes do tempo. Tal complexidade pode incluir comportamentos não lineares e componentes estocásticos sobre múltiplas escalas de tempo e espaço. Pode-se haver um entendimento qualitativo de um processo particular, mas o entendimento quantitativo pode ser limitado. A possibilidade de expressar os processos físicos como um conjunto de equações matemáticas detalhadas pode não existir, ou as equações podem ser muito complexas, exigindo simplificações para seu uso (Steyaert, 1993).

Na solução de problemas relacionados à gestão de recursos hídricos, a escolha do modelo hidrológico depende da avaliação de alguns aspectos como: objetivo do estudo para o qual o modelo vai ser utilizado, características climáticas e físicas da bacia e do rio, e a disponibilidade de dados. Admitindo, então, alguns critérios característicos dos modelos, entre eles, modelo discreto ou contínuo, quando os processos ocorrem em intervalos discretos ou contínuos no tempo; modelo concentrado ou distribuído, o primeiro apresenta parâmetros e variáveis que variam somente em função do tempo e o segundo quando há variação também no espaço; modelo conceitual e empírico, quando a função do modelo leva em consideração os processos físicos ele é considerado conceitual, já os

empíricos são aqueles do tipo “caixa preta”, que ajustam os valores calculados aos valores observados sem relacionar os fenômenos físicos.

A bacia hidrográfica é o objeto de estudo da maioria dos modelos hidrológicos, reunindo as superfícies que captam e despejam água sobre um ou mais canais de escoamento que se desembocam para uma única saída. A bacia pode constituir a unidade espacial para modelos agregados que consideram as propriedades médias para toda a bacia, ou então, pode ser subdividida segundo diversas abordagens a fim de considerar suas características espacialmente distribuídas. A simulação hidrológica é limitada pela heterogeneidade física da bacia e dos processos envolvidos, o que muito tem contribuído para o desenvolvimento de um grande número de modelos (Oliveira, 2003).

As componentes do ciclo hidrológico, precipitação, evaporação, infiltração, escoamentos, dependem de um grande número de variáveis que nem sempre podem ser medidas. Quanto menor for a disponibilidade de informações, maiores serão as incertezas dos prognósticos, tanto que uma das limitações na utilização de modelos hidrológicos é a disponibilidade de dados. No aspecto de quantidade, muitas séries de dados hidrológicos apresentam falhas, quanto à qualidade, muitos dados são mal medidos ou mal observados.

2.2.1 Modelo chuva-vazão

Um processo de grande interesse para estudos é o que tem lugar entre a precipitação e o escoamento dos cursos d'águas, que se convencionou denominar processo chuva-vazão. Um processo dinâmico que se repete em cada evento de precipitação. O interesse de estudo desse processo está na possibilidade de explicar a relação existente entre uma precipitação e o escoamento numa determinada seção transversal do curso d'água principal da bacia hidrográfica.

As seguintes características do processo chuva-vazão dificultam a sua representação através de modelos matemáticos:

- Não-linearidade: a relação entre a precipitação e a vazão não pode ser descrita por uma função linear. Essa não linearidade decorre da concomitância dos diversos subprocessos envolvidos, bem como da não linearidade inerente à maioria destes subprocessos;
- Distribuição espacial: além de várias características físicas da bacia (relevo, tipo de solo, cobertura do solo, etc.) ser espacialmente distribuídas, a

precipitação também ocorre de forma diferenciada sobre a bacia. A forma de distribuição das chuvas pode ser, em alguns casos, mais importante para explicar a relação chuva-vazão do que o próprio modelo matemático utilizado (Valença et al, 1999);

- Variação temporal: características, tais como: cobertura e uso do solo, bem como a magnitude e a intensidade das chuvas podem variar com o tempo.

A representação do processo chuva-vazão através de modelos matemáticos, denominados modelos de simulação chuva-vazão ou simplesmente modelos chuva-vazão, visa quantificar o volume escoado, vazão, como consequência de uma determinada precipitação. Através dessa representação é possível simular condições que não poderiam ser reproduzidas na natureza, previsão. Em geral, esses modelos têm relevante aplicação na engenharia e no gerenciamento dos recursos hídricos. Entre os problemas práticos que demandam esses estudos, destacam-se:

- Avaliação da vazão de cheia máxima para cálculo de sistemas de drenagem;
- Avaliação de ondas de cheia para subsidiar sistemas de controle e prevenção de cheias;
- Previsão de vazões para subsidiar programas de operação de reservatórios;
- Avaliação de vazão mínima de estiagem para subsidiar sistemas de gerenciamento de recursos hídricos;
- Reconstrução de séries históricas de vazões.

A modelagem do processo chuva-vazão tem sido objeto de pesquisa por muito tempo, tendo sido desenvolvidos, até hoje, inúmeros modelos. Dos primeiros modelos baseados em simples equações empíricas até os complexos modelos atuais, esses modelos diferem em muitos aspectos; entre estes, a maior ou menor habilidade para reproduzir as vazões observadas (medidas) e a sua facilidade de aplicação.

2.3 Redes neurais artificiais

Redes neurais artificiais (RNA) é um conceito da computação que visa trabalhar no processamento de dados de maneira semelhante ao cérebro humano. O cérebro é tido como um processador altamente complexo e que realiza processamentos de maneira paralela.

Para isso, ele organiza sua estrutura, ou seja, os neurônios, de forma que eles realizem o processamento necessário. Isso é feito numa velocidade extremamente alta e não existe qualquer computador no mundo capaz de realizar o que o cérebro humano faz.

O cérebro humano é considerado o mais fascinante processador baseado em carbono existente, sendo composto por aproximadamente 10 bilhões de neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas pequenas células. Os neurônios estão conectados uns aos outros através de sinapses, e juntos 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.

O sistema nervoso é formado por um conjunto extremamente complexo de neurônios. Nos neurônios a comunicação é realizada através de impulsos, quando um impulso é recebido, o neurônio o processa, e passado um limite de ação, dispara um segundo impulso que produz uma substância neurotransmissora a qual flui do corpo celular para o axônio (que por sua vez pode ou não estar conectado a um dendrito de outra célula). O neurônio que transmite o pulso pode controlar a frequência de pulsos aumentando ou diminuindo a polaridade na membrana pós sináptica. Eles possuem um papel essencial na determinação do funcionamento, comportamento e do raciocínio do ser humano.

Ao contrário das redes neurais artificiais, redes neurais naturais não transmitem sinais negativos, sua ativação é medida pela frequência com que emite pulsos, frequência esta de pulsos contínuos e positivos. As redes naturais não são uniformes como as redes artificiais, e apresentam uniformidade apenas em alguns pontos do organismo. Seus pulsos não são síncronos ou assíncronos, devido ao fato de não serem contínuos, o que a difere de redes artificiais.

Os principais componentes dos neurônios são:

- Os dendritos, que tem por função, receber os estímulos transmitidos pelos outros neurônios;
- O corpo do neurônio, também chamado de soma, que é responsável por coletar e combinar informações vindas de outros neurônios;
- E finalmente o axônio, que é constituído de uma fibra tubular que pode alcançar até alguns metros, e é responsável por transmitir os estímulos para outras células.

A Figura 2 apresenta o esquema dos constituintes da célula neural biológica.




Figura 2. Esquema dos constituintes da célula neural.

As redes neurais artificiais (RNAs) consistem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. As RNAs são mais que isso, são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto que o cérebro de um mamífero pode ter muitos bilhões de neurônios.

2.3.1 Histórico

As primeiras informações mencionadas sobre a neurocomputação datam de 1943, em artigos do neurofisiologista McCulloch e o matemático Walter Pitts, em que sugeriam a construção de uma máquina baseada ou inspirada no cérebro humano, cujo trabalho fazia uma analogia entre células vivas e o processo eletrônico, simulando o comportamento do neurônio natural, onde o neurônio possuía apenas uma saída. A Figura 3 apresenta esse neurônio. Muitos outros artigos e livros surgiram desde então, porém, por um longo período de tempo, pouco resultado foi obtido.




Figura 3. Neurônio artificial projetado por McCulloch

Até que em 1949, o psicólogo Donald Hebb, escreveu um livro intitulado "The Organization of Behavior" (A Organização do Comportamento) que perseguia a idéia de que o condicionamento psicológico clássico está presente em qualquer parte dos animais pelo fato de que esta é uma propriedade de neurônios individuais. Suas idéias não eram completamente novas. Hebb demonstrou que a capacidade da aprendizagem em redes neurais vem da alteração da eficiência sináptica, isto é, a conexão somente é reforçada se tanto as células pré-sinápticas quanto as pós-sinápticas estiverem excitadas. Ele foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios. Esse primeiro e corajoso passo serviu de inspiração para que muitos outros pesquisadores perseguissem a mesma idéia. E embora muito tenha sido estudado e publicado nos anos que seguiram (1940-1950), estes serviram mais como base para desenvolvimento posterior que para o próprio desenvolvimento.

Também proveniente deste período de tempo foi a construção do primeiro neuro computador, denominado "Snark", por Mavin Minsky, em 1951. O "Snark" operava com sucesso a partir de um ponto de partida técnico, ajustando seus pesos automaticamente, entretanto, ele nunca executou qualquer função de processamento de informação interessante, mas serviu de inspiração para as idéias de estruturas que o sucederam.

Em 1956 no "Darthmouth College" nasceram os dois paradigmas da Inteligência Artificial, a simbólica e o conexionista. A Inteligência Artificial Simbólica tenta simular o comportamento inteligente humano desconsiderando os mecanismos responsáveis por tal. Já a Inteligência Artificial Conexionista acredita que construindo um sistema que simule a estrutura do cérebro, este sistema apresentará inteligência, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros.

O primeiro neuro computador a obter sucesso, "Mark I Perceptron", surgiu em 1957 e 1958, criado por Frank Rosenblatt, Charles Wightman e outros. Rosemblatt

mostrou em seu livro "Principles of Neurodynamics" o modelo dos "perceptrons". Nele, os neurônios eram organizados em camada de entrada e saída, onde os pesos das conexões eram adaptados a fim de se atingir a eficiência sináptica, Figura 4. Devido à profundidade de seus estudos, suas contribuições técnicas e de sua maneira moderna de pensar, muitos o vêem como o fundador da neuro computação na forma em que a temos hoje. Seu interesse inicial para a criação do Perceptron era o reconhecimento de padrões.




Figura 4. Rede de perceptrons proposta por Roseblatt

Após Rosenblatt, Bernard Widrow com a ajuda de alguns estudantes, desenvolveu um novo tipo de elemento de processamento de redes neurais chamado de "Adaline" (Rede Linear Adaptada) que utiliza saídas analógicas em uma arquitetura de três camadas.. Esse elemento é equipado com uma poderosa lei de aprendizado, que diferente do "perceptron" ainda permanece em uso. A Figura 5 apresenta a rede "Adaline". Widrow também fundou a primeira companhia de hardware de neuro computadores e componentes.

Infelizmente, os anos seguintes foram marcados por um entusiasmo exagerado de muitos pesquisadores, que passaram a publicar mais e mais artigos e livros que faziam uma previsão pouco confiável para a época, sobre máquinas tão poderosas quanto o cérebro humano que surgiriam em um curto espaço de tempo. Isto tirou quase toda a credibilidade dos estudos desta área e causou grandes aborrecimentos aos técnicos de outras áreas.




Figura 5. Redes “ADALINE”

Um período de pesquisa silenciosa seguiu-se durante 1967 a 1982, quando poucas pesquisas foram publicadas devido aos fatos ocorridos anteriormente. Entretanto, aqueles que pesquisavam nesta época, e todos os que se seguiram no decorrer de treze anos conseguiram novamente estabelecer um campo concreto para o renascimento da área. Cooper, Cowan, Fukushima, von der Malsburg e muitos outros foram alguns dos muitos pesquisadores dos anos 60 e 70, cujos estudos não devem ser menosprezados.

Nos anos 80, muitos dos pesquisadores foram bastante corajosos e passaram a publicar diversas propostas para a exploração de desenvolvimento de redes neurais bem como suas aplicações. Porém talvez o fato mais importante deste período tenha ocorrido quando Ira Skurnick, um administrador de programas da “DARPA” (Defense Advanced Research Projects Agency) decidiu ouvir os argumentos da neuro computação e seus projetistas, e divergindo dos caminhos tradicionais dos conhecimentos convencionais, fundou em 1983 pesquisas em neuro computação. Este ato não só abriu as portas para a neuro computação, como também deu à “DARPA” o status de uma das líderes mundiais em se tratando de “moda” tecnológica.

Nesse período o renomado físico de reputação mundial, John Hopfield, também emergiu. Hopfield se interessou pela neurocomputação, e escreveu artigos que percorreram o mundo todo persuadindo centenas de cientistas, matemáticos, e tecnólogos altamente qualificados a se unirem esta nova área emergente. Seus trabalhos relataram a utilização de redes simétricas para otimização, através de um algoritmo de aprendizagem que estabilizava uma rede binária simétrica com realimentação.

Apesar de um terço dos pesquisadores da área terem aderido à mesma pela influência de Hopfield, foi em 1986 que este campo de pesquisa "explodiu" com a publicação do livro "Parallel Distributed Processing" (Processamento Distribuído Paralelo) editado por David Rumelhart e James McClelland. Esses introduziram o poderoso método "backpropagation", como apresentado na Figura 6.




Figura 6. Estrutura do método "backpropagation".

Em 1987 ocorreu em São Francisco nos EUA a primeira conferência de redes neurais em tempos modernos, a "International Conference on Neural Networks", e também foi formada a "International Neural Networks Society" (INNS). A partir destes acontecimentos decorreu a fundação do INNS journal em 1989. E muitas universidades anunciaram a formação de institutos de pesquisa e programas de educação em neurocomputação.

2.3.2 Neurônio artificial

Assim como o sistema nervoso é composto por bilhões de células nervosas, a rede neural artificial também seria formada por unidades que nada mais são que pequenos módulos que simulam o funcionamento de um neurônio. Estes módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações.

De forma geral, a operação de uma célula da rede se resume em:

- Sinais são apresentados à entrada;

- Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível excede um limite a unidade produz uma saída;

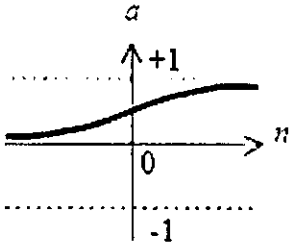
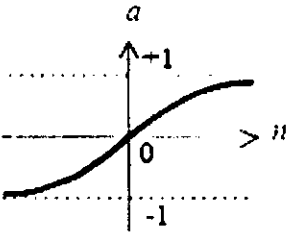
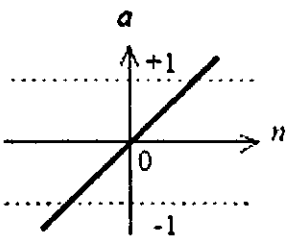
No modelo geral de neurônio, Figura 3, as entradas W_iX_i são combinadas usando uma função F , para produzir um estado de ativação do neurônio (correspondente à frequência de descarga do neurônio biológico). As entradas chegam através dos dendritos e tem um peso atribuído pela sinapse. A função básica de um neurônio é somar as entradas e retornar uma saída, caso esse valor seja maior que o valor de soma.

2.3.3 Função de transferência

A função de transferência define a saída do neurônio em função do nível de atividade na entrada. A utilização da função de transferência permite às RNA identificar relações lineares e não lineares entre as variáveis de entrada e saída. Esta função diferencia a decisão neural baseada no potencial interno do neurônio e determina o valor a ser enviado aos demais neurônios (Santos e Filho, 2003). As funções de transferência mais utilizadas são mostradas na Tabela 1.

A função logística ou sigmóide é a função de transferência mais utilizada em RNAs (Kovács, 1996). São caracterizadas pelo seu formato em S alongado, são funções semi-lineares, contínuas, monotonicamente crescentes e limitadas (Loesch e Sari, 1996). São deriváveis em toda sua extensão, são simétricas e possuem todas as derivadas contínuas, características importantes para demonstração de teoremas matemáticos (Santos, 2001). A Função Tangente Hiperbólica é um exemplo de função logística e está definida no intervalo de $[-1, +1]$. A Função Sigmóide permite a entrada de qualquer valor no intervalo $[-\infty, +\infty]$ e as comprime para o intervalo $[0, +1]$. Devidos às características descritas, essas duas funções são as mais utilizadas em redes neurais. Já a Função Linear não limita a saída e são usadas para armazenar entrada e saída de dados, funcionando como aproximadores lineares.

Tabela 1. Funções de transferências.

Função	Representação gráfica	Equação
Logsig (sigmóide logarítmica)	 <p style="text-align: center;">$a = \text{logsig}(n)$</p>	$\text{logsig}(n) = \frac{1}{(1 + e^{-n})}$
Tansig (sigmóide tangente hiperbólica)	 <p style="text-align: center;">$a = \text{tansig}(n)$</p>	$\text{tansig}(n) = \frac{2}{(1 + e^{-2n}) - 1}$
Purelin (linear)	 <p style="text-align: center;">$a = \text{purelin}(n)$</p>	$\text{purelin}(n) = n$

2.3.4 Característica da rede neural artificial

Do ponto de vista estrutural, a arquitetura de redes neurais pode ser classificada como estática, dinâmica, ou “fuzzy”, e de única ou múltipla camada. Além disso, diferenças computacionais surgem também quando se trata da maneira com que são feitas as conexões existentes entres os neurônios. Estas conexões podem ser estritamente no sentido de ida; de ida e de volta, lateralmente conectadas, topologicamente ordenadas ou híbridas.

De acordo com Rummelhart, a rede neural deve possuir no mínimo duas camadas, a de entrada de dados e a da saída dos resultados. Como a rede apresenta desempenho muito limitado com somente duas camadas, a adição de uma camada intermediária faz-se necessária. Neste tipo de configuração, cada neurônio está ligado com todos os outros das

camadas vizinhas, mas neurônios da mesma camada não se comunicam além da comunicação ser unidirecional, apresentando assim um comportamento estático.

Já a rede neural de Hopfield apresenta comportamento dinâmico e fluxo de dados multidirecional devido à integração total dos neurônios, desaparecendo assim a idéia de camadas bem distintas. Com isso seu funcionamento é mais complexo, havendo certas complicações, seja na fase de aprendizado quanto na fase de testes. Seu uso é direcionado a problemas de minimização e otimização, como por exemplo de percurso de caminhões.

A forma de arranjar “perceptrons” em camadas é denominada “Multilayer Perceptron”, Figura 7. O “multilayer perceptron” foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Os neurônios internos são de suma importância na rede neural, pois sem estes se torna impossível a resolução de problemas linearmente não separáveis. Em outras palavras pode-se dizer que uma rede é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede.




Figura 7. Estrutura de uma RNA em camadas

Usualmente as camadas são classificadas em três grupos:

- Camada de entrada: onde os padrões são apresentados à rede;

- Camadas intermediárias ou Ocultas: onde é feita a maior parte do processamento, através das conexões ponderadas, podem ser consideradas como extratoras de características;
- Camada de saída: onde o resultado final é concluído e apresentado.

A interação entre os neurônios constituintes de uma rede neural pode ocorrer de várias formas, porém duas delas são as mais comuns, são elas, “feedforward” (unidirecional) e “feedback” (recorrentes). Quando os sinais se propagam apenas numa direção, ou seja, todos os neurônios da camada anterior se conectam a todos os neurônios da camada posterior, não havendo realimentação de sinais propagados da camada posterior para a anterior ou para neurônios adjacentes à sua própria camada, a interação é dita “feedforward”. As redes “feedforward” são referenciadas como sistemas de mapeamento não-linear estático instantâneo (Loke, 1995). Já quando existe uma realimentação de sinais já propagados na rede, temos a interação “feedback”. Essas são mais empregadas em sistemas dinâmicos. As redes “feedback” são referenciadas como sistemas não-lineares dinâmicos (Loke, 1995).

2.3.5 Processo de aprendizagem

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. Esse ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. Denomina-se algoritmo de treinamento a um conjunto de regras bem definidas para a solução de um problema de aprendizado.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais.

Existem muitos tipos de algoritmos de treinamento específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo

como os pesos são modificados. O algoritmo de treinamento Levenberg-Marquardt é o método mais rápido para treinar redes neurais feedforward de tamanho moderado. Sua aplicação é descrita em Hagan et al. (1994) e Hagan et al. (1996). Esse algoritmo realiza um treinamento em grupo, ou seja, os pesos só são alimentados quando todas as entradas forem apresentadas ao modelo. O critério de parada do seu treinamento é estabelecido antes do "overfitting" (sobreajuste) dos valores calculados e observados que foram selecionados para validação. Essa parada ocorre quando algumas condições do algoritmo são válidas, como o desempenho dos dados de validação, que pára o processo de treinamento quando esse desempenho for maior que sua queda máxima desde a última vez que diminuiu, dentro do processo iterativo da rede. O algoritmo de Levenberg-Marquadt tem uma implementação muito eficiente no MATLAB, porque a solução da equação em matriz é uma função embutida, assim seus atributos se tornam mais pronunciados até mesmo como entrada no MATLAB.

A rede neural se baseia nos dados para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitar modelos espúrios. Todo o conhecimento de uma rede neural está armazenado nas "sinapses", ou seja, nos pesos atribuídos às conexões entre os neurônios. De 50 a 90% do total de dados devem ser separados para o treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras e não "decore" exemplos. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados.

2.3.6 Vantagens e Desvantagens das RNAs

Como para qualquer modelo matemático que busca a representação dos fenômenos naturais, as RNAs apresentam uma série de vantagens e desvantagens na sua utilização. As principais vantagens na aplicação de redes neurais são:

- 1) **Qualidade superior:** as análises realizadas através das técnicas de redes neurais são superiores às conseguidas através de técnicas estatísticas;
- 2) **Auto-aprendizado:** na tomada de decisão, as RNAs não necessitam de conhecimentos de especialistas, elas se baseiam apenas nos conhecimentos adquiridos através de exemplos históricos a ela apresentados;

3) Implementação mais rápida: o tempo de implementação de uma rede neural, bem como seu custo, é menor do que o necessário para construção de um sistema especialista equivalente;

4) Imunidade à falhas: devido ao fato das unidades de processamento das redes neurais operarem em paralelo, a destruição ou problema num dos seus neurônios não torna a rede inoperante, podendo até mesmo passar despercebido (como ocorre no cérebro humano);

5) 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;

6) Imunidade a ruídos (erros): as redes conseguem separar o ruído existente na informação relevante dos dados reais, podendo ser utilizadas até mesmo como filtros de dados;

7) Adaptabilidade: uma vez construída uma rede eficiente em dada aplicação, ela pode ser utilizada em aplicações de tempo real, sem necessidade de ter sua arquitetura alterada a cada atualização; basta que seja re-treinada com base nos novos dados históricos que forem surgindo;

As principais desvantagens no uso das redes neurais artificiais são:

1) Treinamento demorado: o treinamento de uma rede, dependendo da aplicação, pode demorar horas ou mesmo dias;

2) Resultados desconcertantes: as redes podem chegar a conclusões que contrariam as regras e teorias estabelecidas, bem como, considerar dados irrelevantes como básicos; somente o bom senso do profissional experiente saberá tratar tais casos;

3) Caixa-preta: não se pode conhecer o motivo pela qual levou a rede a uma determinada conclusão; seus critérios decisórios são encriptados, não sabendo quais valores são relevantes à tomada de uma decisão;

4) Volume grande de dados: para uma rede aprender corretamente, necessita-se de um grande volume de dados históricos; a carência de dados relevantes em quantidade suficiente torna a rede inaplicável;

5) Preparação dos dados: os dados de entrada necessitam de tratamento prévio; devem ser normalizados e cuidadosamente selecionados, para que a rede seja corretamente ensinada a agir. Dados de má qualidade produzem resultados falhos.

3. REVISÃO BIBLIOGRÁFICA

O uso dos modelos de RNA para previsão de séries hidrológicas tem crescido vertiginosamente na esperança de uma solução aceitável, mesmo que o usuário não tenha conhecimento mínimo necessário em modelagem com rede neural artificial (Maier e Dandy, 2000). O maior atrativo das RNAs é sua capacidade de representar qualquer função não-linear. Segundo Valença et al. (1999), as Redes Neurais são sistemas constituídos por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas (uma camada de entrada, uma ou várias intermediárias e uma de saída) e são responsáveis pela não-linearidade da rede, através do processamento interno de certas funções matemáticas.

O tipo de rede neural que tem estado em maior evidência na comunidade científica é a rede “perceptron” multicamadas. Como poderosa técnica de regressão, Sarle (1994) afirma que ela é capaz de modelar funções altamente não-lineares, e após ser treinada, generalizar com grande precisão. Trata-se de uma rede com uma ou mais camadas intermediárias em que todos os neurônios de uma camada se ligam a todos da camada seguinte.

A relação entre chuva e vazão é altamente não-linear. Haykan (1994) cita que RNAs com três camadas são capazes de aproximar qualquer função com características não lineares. Essa mesma conclusão também é apresentada por Galvão et al. (1999) e Fernandes et al. (1996). Isso justifica a tentativa de modelar a relação mensal entre chuva e vazão por RNA.

Robinson (1991) efetuou em seu estudo uma comparação entre regressão múltipla e redes neurais, apesar desta última ter mostrado melhores resultados do que a primeira, ele chama atenção para alguns pontos importantes para se obter bons resultados: o primeiro diz respeito à necessidade de uma quantidade satisfatória de dados (quantidade essa que

depende de cada caso específico), para que a rede seja capaz de identificar a relação existente no problema. O segundo, refere-se ao tamanho mais adequado para a rede, que deverá conter mais ou menos neurônios e camadas de acordo com a complexidade do problema. A terceira e última observação feita é relacionada à utilização de valores padronizados para os parâmetros de aprendizagem da rede, que podem não ser os mais apropriados para algumas situações, tornando-se a escolha destes uma questão de experiência e/ou tentativas.

A investigação de aspectos diferentes na modelagem com RNA é essencial para uma melhor precisão da previsão dos processos hidrológicos, como: arquitetura da rede, processo de modelagem, forma de entrada dos dados e métodos de estimativa de eficiência para validação do modelo, Flood et al. (1994).

Muitos estudos já foram realizados anteriormente, quanto à aplicação de RNA na modelagem do processo de transformação da chuva em vazão.

Lorrai et al. (1995) modelaram o processo chuva-vazão na bacia de Araxisi na Sardenha, Itália, utilizando a rede "Multilayer Perceptron" (MLP). Nessa modelagem os autores usaram como variáveis de entrada da rede neural, os valores médios da temperatura e da precipitação sobre a área da bacia e, os valores observados nos seus respectivos pontos (estações meteorológicas), em que com este último a rede neural mostrou melhoria na sua eficiência. De modo geral, os resultados obtidos com a RNA foram melhores quando comparados com aqueles obtidos pelo uso de um modelo conceitual para simular o processo chuva-vazão.

HSU et al. (1995) utilizaram RNA para modelar a relação entre chuva e vazão diária na bacia hidrográfica do rio Leaf próximo a Collins no Mississippi, EUA, em uma bacia hidrográfica de porte médio. Nesse trabalho os autores analisaram um algoritmo de treinamento para as RNAs e confrontaram os resultados obtidos com os resultados do modelo conceitual Sacramento, SAC-SMA, e o modelo estatístico auto-regressivo tipo ARMAX. Eles analisaram os resultados em termos de parâmetros estatísticos, análises gráficas e de função de autocorrelação. Concluíram que as RNAs são capazes de representar a relação chuva-vazão e que o algoritmo de treinamento analisado se mostrou uma ótima ferramenta para treinar as RNAs.

Shamseldin (1997) que também aplicou as RNAs em uma modelagem chuva-vazão, definiu como dado de entrada um índice que tenta interpretar os valores de precipitação, gerando, dessa maneira, um erro logo na entrada dos dados. Ele ressalta que

não há restrição nenhuma para que os dados de entrada sejam as próprias precipitações, mas afirma que é interessante se aproveitar ao máximo a ferramenta que está sendo utilizada (redes neurais), na busca de formas alternativas de entrada de dados, e não somente àquelas já empregados em modelos convencionais.

Zealand et al. (1999) em estudo de previsão de vazões de curto prazo, utilizaram os seguintes dados de entrada: precipitação total semanal, temperatura média semanal e vazão média mensal, para previsão de uma semana. Os dados utilizados foram as precipitações médias de sete semanas anteriores, as sete últimas médias de temperatura, as duas últimas vazões afluentes, a precipitação média da semana seguinte e a temperatura média da semana seguinte, totalizando 18 dados de entrada. Para 2, 3 e 4 semanas foram incluídos, ainda, os valores médios da precipitação e da temperatura da semana, além do valor previsto para a semana anterior, totalizando 21, 24 e 27 dados de entrada, respectivamente. Numa análise de sensibilidade notaram que a quantidade de dados do experimento 1 foi excessiva, reduzindo-se para 3 valores de precipitação, um de temperatura e quatro de vazão, para os quatro períodos pesquisados, totalizando 10 dados de entrada, todos eles de valores medidos. Além dos parâmetros de entrada, mostrou-se importante, no estudo, o bom conhecimento do local e correta escolha das variáveis hidrológicas que podem afetar o resultado final. Os autores concluíram que uma maior quantidade de dados de entrada não produz, necessariamente, melhores resultados e que a inclusão de dados irrelevantes ao processo pode prejudicar o desempenho da rede.

A determinação da topologia da rede a ser utilizada, o número de camadas, o número de unidades em cada camada, normalmente, é realizado de forma empírica. A definição da configuração de redes neurais é ainda considerada uma arte, que requer grande experiência dos projetistas. A escolha do número de neurônios na camada de entrada é um fator que exige experiência e sensibilidade da parte de quem está definindo a topologia da rede. É necessário que se analise com bom-senso as variáveis que possivelmente irão influenciar, ou que são relevantes na determinação dos dados de saída que se deseja obter. É interessante, por isso, realizar vários testes com diferentes configurações de redes já que é impossível saber, somente com uma tentativa, se a rede está extraindo os melhores resultados possíveis.

Sajikumar et al. (1999) também avaliaram a extensão das séries de dados, de modo que aplicaram RNAs temporais na modelagem chuva-vazão mensal nas bacias hidrográficas do rio Lee, no Reino Unido, e na bacia do rio Thuthapuzha, em Kerala, na

Índia. Durante o desenvolvimento avaliaram a influência de se utilizar séries de dados com diferentes tamanhos para o treinamento das RNAs. Nesse trabalho eles ainda confrontaram os resultados obtidos pelas RNAs com três outros modelos empíricos, concluíram que os melhores resultados foram obtidos pelas RNAs.

Elshorbagy et al. (2000) utilizaram RNAs na previsão de vazões na bacia hidrográfica do rio Red River Valley, no Canadá. Esses autores testaram várias estruturas de RNA e compararam os resultados com outros modelos empíricos: um modelo de regressão linear múltipla e um modelo não-linear de regressão múltipla. Eles afirmaram que as RNAs apresentaram os melhores resultados e que esses resultados são dependentes da estrutura dos dados de entrada.

Anmala et al. (2000) utilizaram RNAs feedforward e RNAs recorrentes com entradas de temperatura e chuva mensal para calcular a vazão média mensal em três bacias hidrográficas no Kansas, EUA. Durante o desenvolvimento os autores também analisaram a influência do número de treinamento. Ao final eles concluíram que as RNAs recorrentes apresentaram os melhores resultados entre todos os modelos empíricos e que os bons resultados foram obtidos para um número limite de iterações no treinamento.

Tokar et al. (2000) utilizaram RNAs na modelagem do processo chuva-vazão em três bacias hidrográficas nos EUA, bacia do rio Fraser, do 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 das RNAs 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, degelo de neve e temperatura.

Ramos et al. (2001) apresentam uma metodologia para determinação da arquitetura das RNAs. Nesta metodologia eles citam a reinicialização de pesos, a mudança em certas funções de transferência e a extensão das séries de dados como elementos importantes.

Olívio et al. (2002) aplicaram as técnicas de redes neurais artificiais 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 da retropropagação do erro. Foi apresentado 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, com relação ao

nível de água do rio nessa mesma seção de interesse. Este estudo faz parte de uma seqüência de outros estudos com o mesmo propósito, onde se pretende chegar ao melhor tipo e arquitetura de rede e aos melhores padrões de entrada, para um melhor reconhecimento do problema. O interesse inicial, desse estudo, foi a previsão de níveis fluviométricos para 4, 6, 8 e 10 horas de antecedências, contudo, apenas a previsão para 4 horas de antecedência obteve resultados satisfatórios. 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 et al. (2003) aplicaram RNAs na modelagem chuva-vazão mensal na bacia hidrográfica do rio Acaraú no semi-árido cearense, Brasil. Os autores avaliaram várias RNAs com diferentes entradas, ditas modelos, e número de neurônios na camada intermediária. Além disso, cada uma das RNAs foi treinada com números diferentes de dados. Os resultados foram muito satisfatórios, com coeficiente de correlação em torno de 0,93, na validação. Os autores não confrontaram esses resultados com os resultados de outro modelo.

Muller et al. (2003) verificaram o comportamento de um modelo de RNA na propagação de vazões em rios. O caso de estudo foi o rio Iguaçu, entre Fluvópolis e União da Vitória. Neste estudo, foi criada uma rede “perceptron” multicamadas do tipo 2-8-8-8-1, onde, na primeira camada tinham-se dois neurônios, um responsável pela informação da vazão em Fluvópolis e o outro pelo incremento de vazão; depois, mais três camadas escondidas, cada uma com oito neurônios com funções de ativação do tipo sigmóide logística e, finalmente, na última camada, o neurônio de saída, responsável pela resposta da propagação da vazão para União da Vitória. Os autores concluíram que o método era promissor, pois, apesar de se tratar de uma técnica puramente matemática, onde não se levava em conta a teoria intrínseca do problema, tal método obteve resultados animadores.

Nayak et al. (2003) realizaram um estudo intitulado “A neuro-fuzzy computing technique for hydrological time series”, trabalho este que objetivou a integração das técnicas de RNAs às de lógica difusa para a modelagem do escoamento no rio Baitarani no Estado de Orissa na Índia. A pesquisa obteve bons resultados, segundo os autores, já que a vazão simulada com o modelo desenvolvido acompanhou o comportamento histórico da série e suas características estatísticas. Eles ressaltaram também o aumento da facilidade em modelar o processo e concluíram afirmando haver viabilidade de tal técnica na modelagem de vazões em rios.

Almeida et al. (2004) utilizaram a técnica de redes neurais com o objetivo de conhecer a previsão de secas hidrológicas para um horizonte de cinco dias. A seca hidrológica está relacionada com a redução dos níveis médios de água nos reservatórios de superfície e subterrâneos e com a depleção de água no solo. Este tipo de seca está normalmente defasado da seca meteorológica, dado que é necessário um período maior para que as deficiências na precipitação se manifestem nos diversos componentes do sistema hidrológico. A rede neural possuía na camada de entrada onze neurônios, que representavam as condições antecedentes da bacia hidrográfica dos últimos cinco dias referentes à vazão e à precipitação e mais uma variável de entrada referente ao total previsto de precipitação para os próximos cinco dias. Na camada de saída, estava o neurônio responsável pela correspondente previsão da vazão média para os próximos cinco dias. O algoritmo de treinamento, usado pelos autores, nesse trabalho, foi o do gradiente conjugado escalonado. Os autores concluíram o trabalho afirmando que os resultados foram satisfatórios na previsão de vazão média diária para um horizonte de cinco dias e que tal técnica auxilia na identificação de um possível início de evento de seca hidrológica e que, com um acompanhamento diário é possível se detectar a evolução dos déficits e a indicação do possível término do evento dentro de intervalos de tempo de cinco dias de duração.

Sousa e Sousa (2006) utilizaram uma arquitetura de rede neural artificial denominada "MultiLayer Perceptron" (MLP) para modelar o processo chuva-vazão com o objetivo de prever vazão média mensal na seção transversal do rio Paraíba, a montante de Caraúbas, a partir de totais mensais precipitados e obteve bom resultados na previsão com uma arquitetura que considerava cinco camadas escondidas representadas pelo módulo da precipitação e uma camada de saída representada pelo módulo da vazão. Esta arquitetura não previu muito bem os picos de cheia.

4. MATERIAL E MÉTODOS

4.1 Área de estudo

O estudo será desenvolvido para a bacia hidrográfica do Rio Piancó, Figura 8, localizada no Sudoeste do Estado da Paraíba, próximo as fronteiras do Ceará, ao Norte de Pernambuco, ao Sul do Alto e Médio Piranhas e a Oeste da bacia do Rio Espinharas. O acesso a partir de João Pessoa, capital do Estado da Paraíba, é feito através da BR-230 até a cidade de Patos onde tomasse a BR-361 e percorre cerca de 80 km, totalizando uma distância de 391,9 km da capital.

Em termos climatológicos a bacia hidrográfica esta inserida no denominado “Polígono das Secas”, constituindo um tipo semi-árido quente e seco, segundo a classificação de Koppen. As temperaturas são elevadas durante o dia, amenizando a noite, com variações anuais dentro de um intervalo 23 a 30° C, com ocasionais picos mais elevados, principalmente durante a estação seca. O regime pluviométrico, além de baixo é irregular com médias anuais de 751,1 mm/ano com mínimas e máximas de 180,0 e 1511,8 mm/ano. No geral, caracteriza-se pela presença de apenas 02 estações: a seca que constitui o verão, cujo clímax é de Setembro a Dezembro e a chuvosa denominada pelo sertanejo de inverno, restrito a um período de 3 a 4 meses por ano. A umidade relativa do ar média anual varia de 64 a 72%. Por outro lado, merece registro a variação da insolação diária durante o ano, que alcança uma média de 7,3 a 8,7 horas/dia.

A vegetação é de pequeno porte, típica de caatinga xerofítica, onde se destacam a presença de cactáceas, arbustos e árvores de pequeno a médio porte. Os solos são resultantes da desagregação e decomposição das rochas cristalinas do embasamento, sendo em sua maioria do tipo Podizólico Vermelho-Amarelo de composição arenoargilosa, tendo-se localmente latossolos e porções restritas de solos de aluvião.

A rede de drenagem é do tipo intermitente e seu padrão predominantemente dentrítico. Devido à existência de fraturas geológicas, mostra variações para retangular e angular.

Todo esse complexo abrange completa ou parcialmente os municípios de Água Branca, Aguiar, Boa Ventura, Catingueira, Conceição, Coremas, Cural Velho, Diamante, Emas, Ibiara, Igaracy, Imaculada, Itaporanga, Juru, Manaíra, Nova Olinda, Olho D'Água, Pedra Branca, Piancó, Pombal, Princesa Isabel, Santana dos Garrotes, Santana de Mangueira, São José de Caiana, Serra Grande e Tavares, ocupando uma área aproximada de 9.274,20 km².

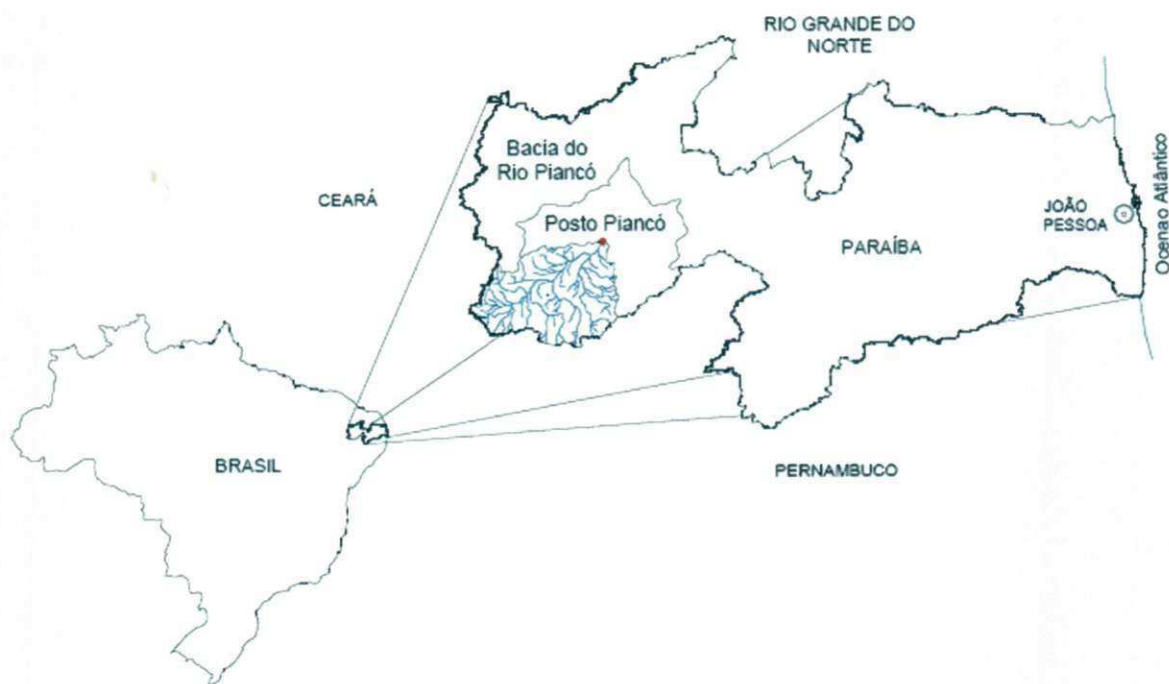


Figura 8. Localização da bacia do Piancó, destacando a área de estudo delimitada pelo posto Piancó.

Três fatores justificam a escolha dessa bacia para aplicar o modelo ora proposto:

- 1) a bacia do Rio Piancó apresenta características hidrometeorológicas típicas do norte-nordeste;
- 2) possui uma boa densidade espacial de postos pluviométricos, que fornecem séries históricas de longa duração;

3) ela pode ser considerada de porte médio, representando bem as bacias contribuintes de reservatórios do Nordeste do Brasil, que possuem áreas de 200 km² a 15.000 km².

4.2 Dados

4.2.1 Vazão

Vazão é o volume de água que passa por uma determinada seção de um conduto por uma unidade de tempo. Usualmente é dado em litros por segundo (l/s), em metros cúbicos por segundo (m³/s) ou em metros cúbicos por hora (m³/h).

Para este estudo as séries de vazões se referem à estação fluviométrica de Piancó. Essas séries são constituídas de valores médios mensais e foram adquiridas junto a Agência Nacional de Águas (ANA), com observações de janeiro de 1963 a setembro de 2006. Desse período serão considerados para análise dez anos de dados, que compreende janeiro de 1964 a dezembro de 2003. Esses dados estão apresentados no Apêndice A. A avaliação quanto à qualidade dos dados foi feita por inspeção visual. Os dados dos meses de setembro e novembro de 2002 apresentaram falhas e foram preenchidos com a média climatológica.

As vazões de uma bacia dependem de fatores climáticos e geomorfológicos. A intensidade, a duração, a distribuição espaço-temporal da precipitação sobre uma bacia, bem como a evapotranspiração, estão entre os principais fatores climáticos. Por outro lado, um hidrograma sintetiza a forma pela qual uma bacia hidrográfica atua como um reservatório, distribuindo a precipitação efetiva ao longo do tempo, Figura 9. O hidrograma possui vazões e tempos característicos, os quais são atributos típicos, resultantes das propriedades geomorfológicas da bacia em questão. Essas podem ser sintetizadas pela extensão da bacia, forma, distribuição de relevo, declividade, comprimento do rio principal, densidade de drenagem, cobertura vegetal, tipo e uso do solo, entre outras. Nesse contexto será verificado qualitativamente a resposta da bacia hidrográfica em função dos eventos pluviométricos.

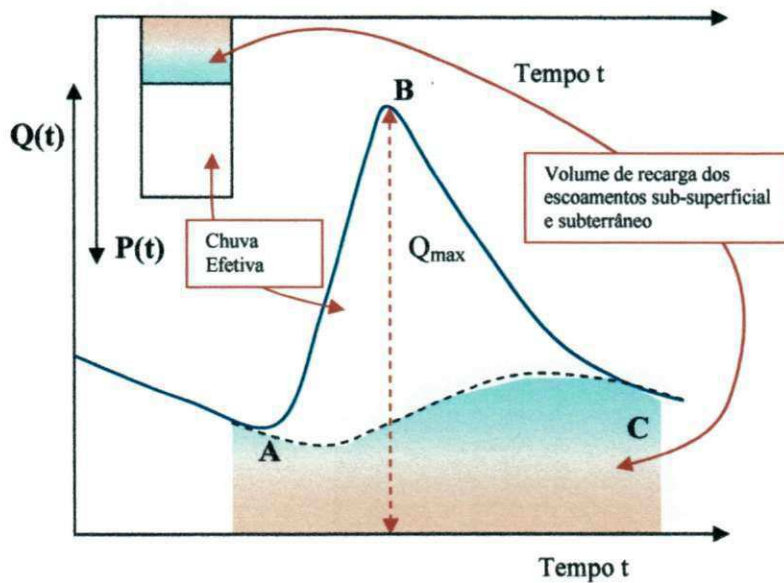


Figura 9. Hidrograma característico de uma bacia hidrográfica. Fonte: <http://www.fag.edu.br/>

4.2.2 Precipitação

Para o estudo em questão serão considerados valores médios mensais de precipitação adquiridos junto a Agência Executiva de Gestão das Águas do Estado da Paraíba (AESAs), para o período de 42 anos, de sete estações pluviométricas, representativas da bacia do Piancó. Na análise desses dados quanto à consistência e tamanho das séries, observou-se um grande número de falhas, descartando-se alguns anos de observação.

O período que compreende os meses de janeiro de 1994 a dezembro de 2003, totalizando 120 meses de observação, apresentou consistência e semelhança nos dados em cinco postos pluviométricos, considerando esse período para nosso estudo. Os dados são mostrados na Tabela A1 no Apêndice A As estações pluviométricas e fluviométrica considerada são apresentadas na Figura B1 no Apêndice B. Para uma melhor visualização da localização das estações, foi feito um zoom da região, como pode ser observado na Figura 10 destacando as estações com setas, são elas: Piancó, Santana dos Garrotes, Nova Olinda, Itaporanga e Boa Ventura.

A altura média de precipitação em uma área específica é necessária em muitos tipos de problemas hidrológicos, portanto para sua determinação existem vários métodos como: o método aritmético, o método das isoietas e o método de Thiessen. Desse modo o primeiro método citado será considerado para o cálculo da média da

precipitação, dos cinco postos pluviométricos estudados, referente a bacia hidrográfica do Rio Piancó.

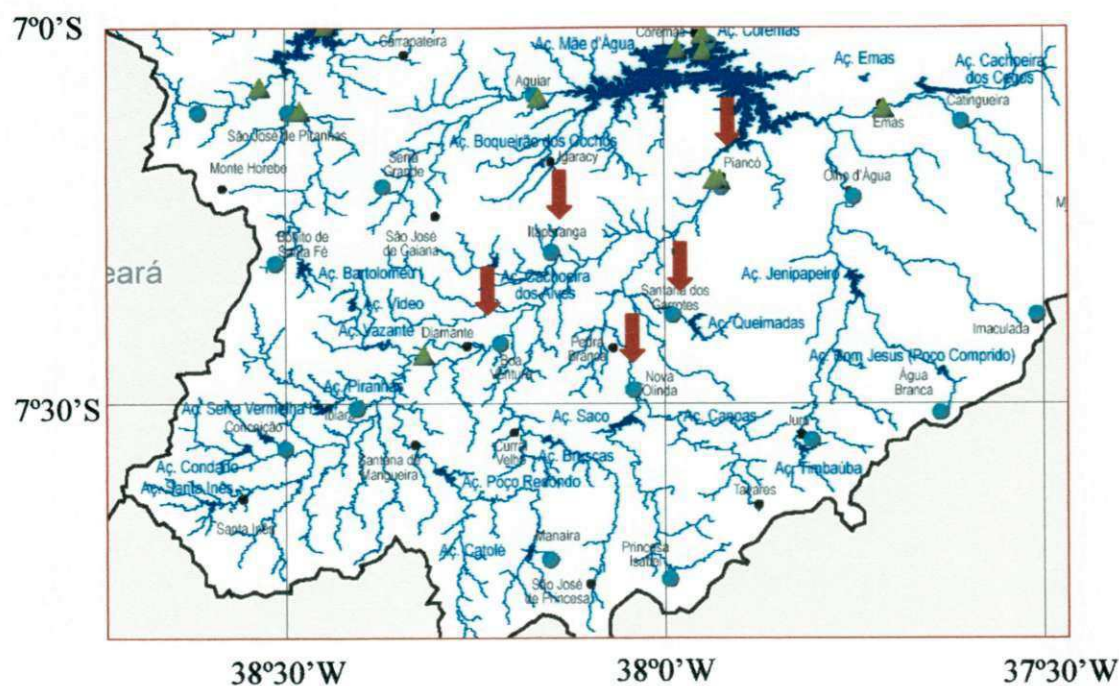


Figura 10. Zoom do mapa do estado da Paraíba com as estações pluviométricas e fluviométrica para a região estudada.

4.3 RNA proposta

Uma rede multicamada com uma única camada escondida de neurônios sigmoidais, que recebem entradas diretamente, e então transmitem suas saídas para uma camada de neurônios lineares, tem provado ser capaz de aproximar qualquer função contínua com satisfatória exatidão, sendo considerada como aproximador universal de funções (Hines, 1997; Demuth et al., 1998; Valença et al., 1999).

As RNAs utilizadas neste trabalho serão do tipo “Multi-Layer Perceptron” (MLP) com três camadas. A camada de entrada de cada rede não faz processamento, ou seja, não se atribui a ela funções de ativação. Ela simplesmente envia os dados de entrada, modificados por um peso, para cada um dos neurônios da próxima camada. A segunda camada, única escondida em cada rede neural, é composta de neurônios com função de ativação sigmoide; e a camada de saída é formada por neurônios com função linear.

A forma funcional de uma RNA é determinada pela sua arquitetura, ou seja, RNA com arquiteturas diferentes significam ajustes de funções distintas. Portanto neste estudo pretende-se utilizar diversas arquiteturas a fim de escolher aquela que melhor prediga as vazões médias mensais da bacia em estudo. A metodologia adotada na investigação da arquitetura da RNA foi a de variar o número de neurônios na camada de entrada, o número de neurônios e a função de transferência na camada intermediária.

A relação entre um conjunto de entrada e saída foi representada por três modelos distintos que apresentam variação nos dados de entrada. O primeiro modelo apresenta como variáveis de entrada as precipitações médias mensais dos seguintes postos pluviométricos: Piancó, Santana dos Garrotes, Itaporanga, Boa Ventura e Nova Olinda. O segundo modelo apresenta as mesmas entradas do primeiro modelo com exceção do posto de Piancó. E o terceiro modelo apresenta como dados de entrada a média da precipitação nos cinco postos estudados. Para todos os modelos a variável de saída é sempre a vazão média mensal na estação fluviométrica de Piancó.

Para cada modelo foi criada uma RNA com 5, 10 e 15 neurônios na camada intermediária, com variação entre as funções de transferência sigmóide tangente hiperbólica (Tan-sig) e sigmóide logarítmica (Log-sig) nesta mesma camada, totalizando 18 RNA distintas.

A opção em variar a arquitetura não apenas em termos da camada intermediária, mas também em relação à camada de entrada possibilita, além de novas formas funcionais, a avaliação da sensibilidade da RNA em função das variáveis de entrada. A proposta de criar modelos e variar o número de neurônios na camada intermediária segue os mesmos moldes do trabalho de Lima et al. (2003).

O treinamento em todas as RNA foi realizado utilizando a técnica de otimização de Levenberg-Marquardt. A motivação pela utilização deste método no treinamento das RNAs se justifica por ser uma ótima técnica para aproximação de relações não-lineares, por ser rápida e por ser uma técnica que já produziu bons resultados segundo Lima et al. (2003) e Sperb et al. (1999) no treinamento de RNAs com propósitos semelhantes ao aqui estudados.

Segundo Hagan e Menhaj (1994), essa técnica de otimização é muito mais eficiente que outras, quando se treina redes que têm até poucas centenas de parâmetros (pesos e ruídos), provocando uma convergência mais rápida e resultados com maior precisão. Demuth et al. (1998) comparou o desempenho de vários algoritmos de treinamento em um determinado problema e mostrou que o algoritmo de Levenberg-

Marquardt é amplamente superior aos demais, pois atinge a convergência em menor tempo, com um menor número de iterações e com menor número de operações com ponto flutuante.

Além da forma funcional da RNA, considerou-se durante o processo de treinamento a influência da inicialização dos pesos, em que todas as RNAs foram inicializadas seis vezes. Outra característica importante é a extensão das séries de dados que esta relacionada com a quantidade de dados utilizados para o treinamento e validação das RNAs. Anmala et al. (2000) acreditam que quanto maior for a quantidade de dados, melhor será a generalização do problema. Em um problema chuva-vazão mensal, Lima et al. (2003) utilizaram 456 dados para sua solução, enquanto Elshorbagy et al. (2000) utilizaram apenas 50 para treinamento e validação para uma previsão de vazão anual. Para este estudo foram utilizados 120 dados. Esses dados foram separados em 72 valores para treinamento, 24 valores para validação e 24 valores para teste, correspondentes a 60%, 20% e 20% respectivamente.

Antes do início do treinamento todos os dados de entrada serão normalizados. No final de cada treinamento, com os pesos e vieses ajustados, a RNA será simulada para gerar resultados. Serão obtidos 120 resultados que correspondem a dois tipos de arquiteturas com dados de entrada não normalizados e dezoito tipos de arquiteturas com dados de entrada normalizados. Todas as respostas serão armazenadas em planilha Excel, convertendo os valores normalizados para valores não-normalizados. Logo em seguida todas as RNAs serão reinicializadas e a rede novamente treinada.

Cada resposta será resultado de uma combinação diferente entre o número de entradas da RNA, o número de neurônios na camada intermediária, a função de transferência da camada intermediária e a inicialização dos pesos.

O processo de criação, treinamento e simulação da RNA será desenvolvido no software MATLAB. Como um sistema iterativo e linguagem de programação para computação técnica e científica em geral, o MATLAB permite a construção de “bibliotecas” de funções, denominada de “toolboxes”, que o torna apto a resolver classes particulares de problemas, Hanselman et al. (1999). A “toolbox” de Redes Neurais do MATLAB possui uma ampla versatilidade e flexibilidade, pois o seu uso possibilita a aplicação dos mais variados tipos de redes neurais, além de permitir a modificação de redes já existentes, como alterações no número de camadas ou mesmo de algoritmos de treinamento com uma particular facilidade de inserção.

4.4 Índices de desempenho

Para avaliar o desempenho de todas as RNAs serão utilizadas três estatísticas: Coeficiente de determinação, Coeficiente de eficiência e Erro Padrão da Estimativa.

i) Coeficiente de determinação (R^2)

O quadrado do coeficiente de correlação de Pearson é chamado de coeficiente de determinação ou simplesmente R^2 . É uma medida da proporção da variabilidade em uma variável que é explicada pela variabilidade da outra. É pouco comum que se tenha uma correlação perfeita ($R^2 = 1$) na prática, porque existem muitos fatores que determinam as relações entre variáveis na vida real. A Equação 1 expressa o coeficiente de correlação de Pearson.

$$R = \frac{N \sum (Q_o Q_c) - \sum Q_o \sum Q_c}{\sqrt{[N \sum Q_o^2 - (\sum Q_o)^2] [N \sum Q_c^2 - (\sum Q_c)^2]}} \quad (1)$$

em que Q_o é a vazão observada, Q_c é a vazão calculada e N é o número de observações.

ii) Coeficiente de eficiência (E)

Definido por Nash et al. (1970), este coeficiente tem sido utilizado por diversos pesquisadores na avaliação de modelos hidrológicos e na quantificação dos constituintes da água para estimativa de sua qualidade, Moriasi (2007).

Valores do coeficiente de eficiência maiores ou iguais a zero indicam melhor performance do modelo. A Equação 2 expressa esse coeficiente.

$$E = 1 - \frac{\sum (Q_o - Q_c)^2}{\sum (Q_o - \bar{Q}_o)^2} \quad (2)$$

em que Q_o é a vazão observada, Q_c é a vazão calculada e \bar{Q}_o é a média da vazão observada.

iii) Erro Padrão da Estimativa (EPE)

O erro padrão da estimativa mede o desvio médio entre os valores observados e calculados de vazão. Ele informa de modo aproximado o quanto grande são os erros de estimativa em relação aos dados da amostra. EPE é medido na unidade de vazão. O que se busca é conseguir o menor valor possível do erro padrão da estimativa. O EPE é expresso pela Equação 3.

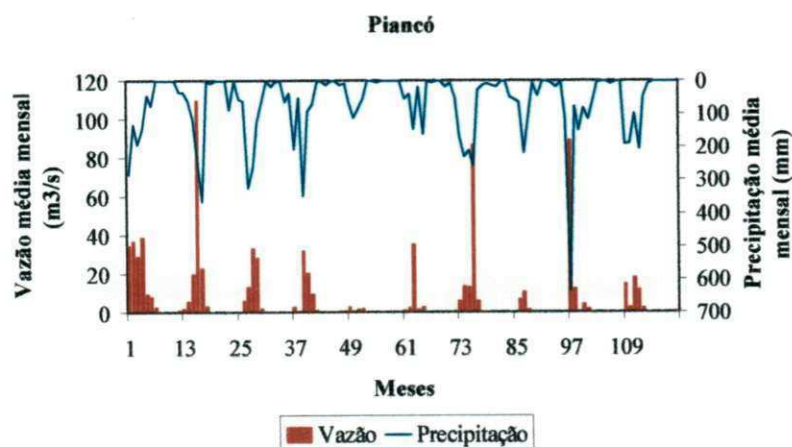
$$EPE = \sqrt{\frac{\sum (Q_o - Q_c)^2}{n-1}} \quad (3)$$

Essas estatísticas serão calculadas para todos os valores gerados pelas RNAs, dividindo esses dados em treinamento, validação e teste. Os resultados serão armazenados numa planilha Excel.


5. RESULTADOS E DISCUSSÃO

A resposta da avaliação qualitativa da bacia hidrográfica do Piancó em função dos eventos pluviométricos pode ser verificada nos hidrogramas e hietogramas representados pela Figura 12 de (a) a (f). Em todos os hidrogramas a vazão é referente à estação fluviométrica de Piancó, já os hietogramas são referentes às estações pluviométricas de: Piancó (a), Santana dos Garrotes (b), Boa Ventura (c), Itaporanga (d), Nova Olinda (e) e a média dessas estações (f).


Observa-se nessas figuras uma sazonalidade nos eventos de precipitação e de vazão, verificando que existe uma correspondência entre o aumento dos volumes precipitados ao aumento dos volumes escoados. No mês representado pelo número 49, que corresponde a Janeiro de 1998, conforme a Tabela A1, no Apêndice A, observa-se em todas as figuras, valores menores de precipitação e de vazão se comparado com os demais períodos observados, o que caracteriza um período de anomalia negativa de precipitação, já que a vazão depende da precipitação. A Tabela 2 mostra que a precipitação em 1998 foi abaixo da média apresentando considerável desvio padrão negativo.



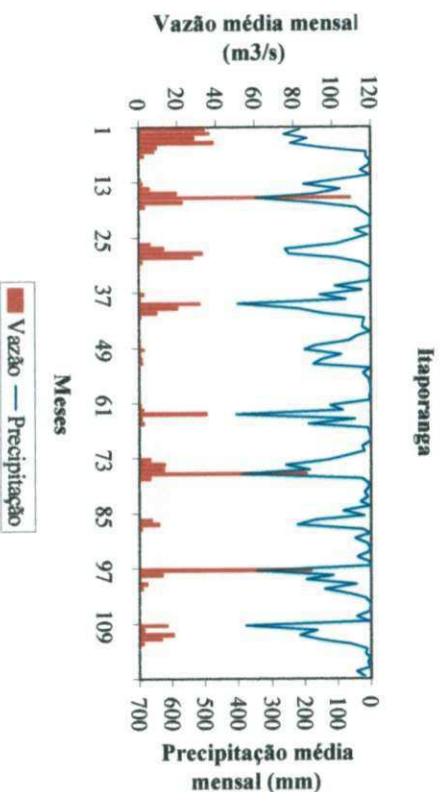
(a)



(b)



(c)



(d)

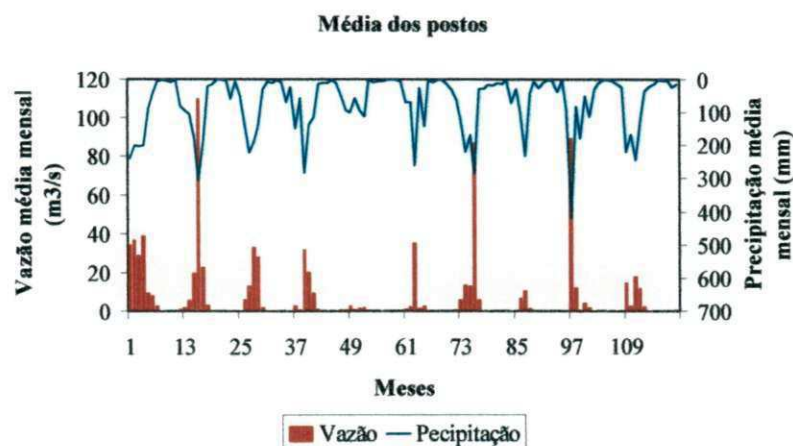
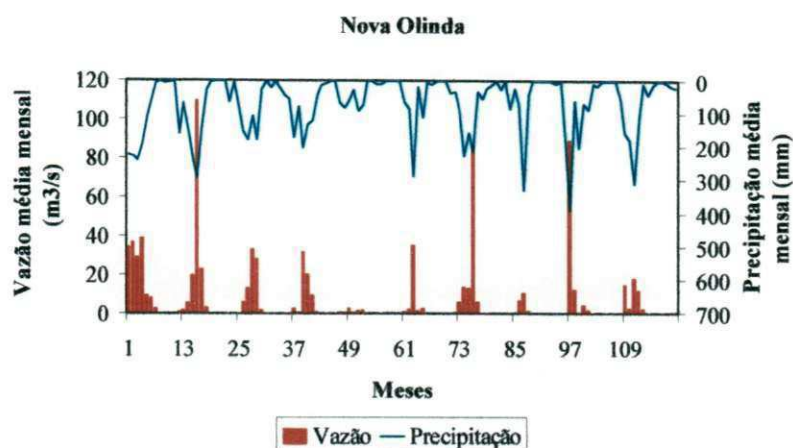


Figura 11. Hidrograma e Hietograma em: (a) Piancó, (b) Santana dos Garrotes, (c) Boa Ventura, (d) Itaporanga, (e) Nova Olinda, e (f) Média dos postos, para o período estudado.

Tabela 2. Precipitação em 1998 nas estações estudadas neste trabalho.

Estação	Total anual (mm)	Climatologia anual (mm)	Desvio Padrão (mm)
Piancó	314,6	903,3	-588,7
Santana dos Garrotes	332,7	706,6	-373,9
Boa Ventura	354,1	910	-555,9
Itaporanga	644,1	878	-233,9
Nova Olinda	266,2	932,3	-666,1
Média dos Postos	383,34	866,04	-483,7

Foram totalizados 120 resultados correspondentes a 20 diferentes arquiteturas de RNAs. Para melhor compreender os resultados, esses foram divididos em treinamento, validação e teste. Na nomenclatura das arquiteturas de RNAs adotou-se convenções que seguem a seguinte regra. Todas as RNAs são identificadas por sete caracteres. O primeiro caractere identifica a rede pela letra 'R'. O segundo caractere refere-se à normalização dos dados de entrada, e são identificados pelas letras 'S', sem normalização, e 'C', com normalização. O terceiro caractere refere-se ao modelo utilizado, este é representado por uma numeração que varia de um a três. Ele identifica o número de entradas e quais são as entradas. Os caracteres quatro e cinco referem-se ao número de neurônios da camada intermediária. Por exemplo, o número 05 significa que a RNA possui cinco neurônios na camada intermediária. O sexto caractere refere-se à função de transferência utilizada, sendo representado pelas letras 'T', quando a função é sigmóide tangente hiperbólica, e 'L', quando a função é sigmóide logarítmica. Por fim, o último caractere refere-se à inicialização, e é representado por uma numeração que varia de um a seis. A inicialização um, por exemplo, significa a primeira inicialização para uma RNA em particular. Duas RNAs com um primeiro conjunto de pesos, inicialização um, não apresentam os mesmos valores até porque as RNAs são diferentes, número de pesos diferentes.

Dos 120 resultados obtidos apenas os 24 melhores resultados foram selecionados para análise. O critério de seleção das melhores arquiteturas foi o de avaliar o desempenho de generalização da RNA através de análises estatísticas entre os dados calculados e observados para o período de teste. Para uma primeira avaliação considerou-se o coeficiente de determinação com valores maiores ou iguais a 90 por cento. Esses resultados são apresentados na Tabela 3.

A melhor arquitetura apresentada na Tabela 3 foi a RC305T3 com valor de 0,97 para o coeficiente de determinação. Essa arquitetura apresenta as seguintes características: os dados de entrada são representados pelo modelo três, com valores normalizados, a camada intermediária possui cinco neurônios, a função de transferência utilizada é a Tan-sig e o resultado é obtido na terceira inicialização da arquitetura. Como se considerou apenas o coeficiente de determinação, não se pode afirmar se essa arquitetura é a melhor para simular os dados de vazões médias observadas. Desse modo, foram realizadas outras avaliações adicionais. Foram considerados os valores de E e EPE a fim de se obter a confirmação de qual arquitetura seria a melhor para modelar vazões médias observadas.

Tabela 3. Melhores arquiteturas, considerando o coeficiente de determinação com valores maiores ou iguais a 90 por cento, para o período de teste.

	Treinamento			Validação			Teste		
	R2	E	EPE	R2	E	EPE	R2	E	EPE
RC305T3	0,82	0,80	7,41	0,88	0,82	7,48	0,97	0,02	18,26
RC310L4	0,88	0,78	7,63	0,87	0,85	6,94	0,96	-0,51	22,63
RC310L5	0,94	0,94	4,11	0,51	0,49	12,67	0,96	-1,27	27,71
RC310T6	0,91	0,91	4,99	0,78	0,75	8,89	0,96	-0,21	20,24
RC305L4	0,87	0,87	5,96	0,73	0,73	9,30	0,96	-3,43	38,73
RC305T6	0,88	0,87	5,84	0,84	0,80	7,99	0,95	-1,03	26,21
RC315L3	0,71	0,68	9,26	0,98	0,95	3,91	0,95	0,92	5,30
RC305T2	0,90	0,90	5,18	0,82	0,76	8,65	0,95	0,30	15,37
RC305L6	0,88	0,84	6,56	0,82	0,82	7,62	0,95	-0,15	19,73
RC310L2	0,67	0,66	9,56	0,97	0,94	4,23	0,95	0,94	4,62
RC315T4	0,77	0,76	7,97	0,89	0,88	6,11	0,95	0,58	11,93
RC305L2	0,76	0,75	8,14	0,80	0,78	8,25	0,95	-0,50	22,57
RC305L5	0,84	0,84	6,66	0,75	0,67	10,17	0,94	0,14	17,09
RC305L3	0,92	0,90	5,08	0,75	0,73	9,26	0,94	-0,26	20,65
RC315L6	0,75	0,63	10,01	0,98	0,96	3,45	0,94	0,71	9,88
RC305L1	0,87	0,87	5,98	0,87	0,86	6,60	0,94	0,78	8,55
RC315L5	0,79	0,65	9,74	0,96	0,91	5,31	0,94	0,50	13,00
RC310L1	0,87	0,71	8,82	0,80	0,78	8,31	0,93	-0,96	25,80
RC315L4	0,52	0,18	14,87	0,98	0,96	3,47	0,93	0,89	6,07
RC315T2	0,86	0,84	6,54	0,90	0,89	5,98	0,93	0,86	6,80
RC315L1	0,63	0,56	10,86	0,98	0,96	3,48	0,92	0,91	5,59
RC305T5	0,90	0,90	5,28	0,76	0,74	9,06	0,91	0,41	14,14
RC315T6	0,78	0,73	8,61	0,94	0,91	5,19	0,90	0,88	6,30
RC310T2	0,78	0,70	9,06	0,98	0,95	4,15	0,90	0,73	9,65

Analisando as 24 arquiteturas selecionadas na Tabela 3 observa-se que todas utilizam o modelo três com dados de entrada normalizados. Considerando o número de neurônios na camada intermediária, grande parte das arquiteturas apresenta cinco neurônios nessa camada, conforme mostrado na Tabela 4.

Tabela 4. Quantidade de arquiteturas, considerando os neurônios na camada intermediária.

Arquitetura	Neurônios
10	5
6	10
8	15

No estudo aqui desenvolvido a função de transferência Log-sig é a que está presente na maior parte das arquiteturas, quinze arquiteturas, enquanto a função Tan-sig aparece em nove arquiteturas. Analisando as inicializações de cada arquitetura, observa-se que a arquitetura, RC305L apresenta maior frequência. A Tabela 5 mostra esse resultado.

Tabela 5. Quantidade de inicializações por arquitetura.

Arquitetura	Inicialização
RC305T	4
RC305L	6
RC310T	2
RC310L	4
RC315T	3
RC315L	5

Com base nas análises realizadas para a primeira avaliação, que considera apenas o coeficiente de determinação para o desempenho da arquitetura, observa-se que existem incoerências nos resultados. A melhor arquitetura apresenta cinco neurônios na camada intermediária e a função de transferência utilizada é a função Tan-sig, nas demais análises observou-se que existe maior quantidade de arquiteturas com cinco neurônios, e com a função de transferência Log-sig. Nas inicializações, por apresentar maior frequência, a melhor arquitetura é a RC305L. A análise da frequência das características de uma arquitetura ou da arquitetura mostra a possibilidade desta representar melhor o que se deseja.

Sendo assim para se obter um padrão coerente nos resultados, fez-se necessário uma segunda avaliação, considerando o erro padrão de estimativa (EPE) com valores menores que sete unidades. Esse critério foi utilizado para observar os menores valores do

erro, pois quanto menor seu valor melhor o resultado. Esses resultados são exibidos na Tabela 6.

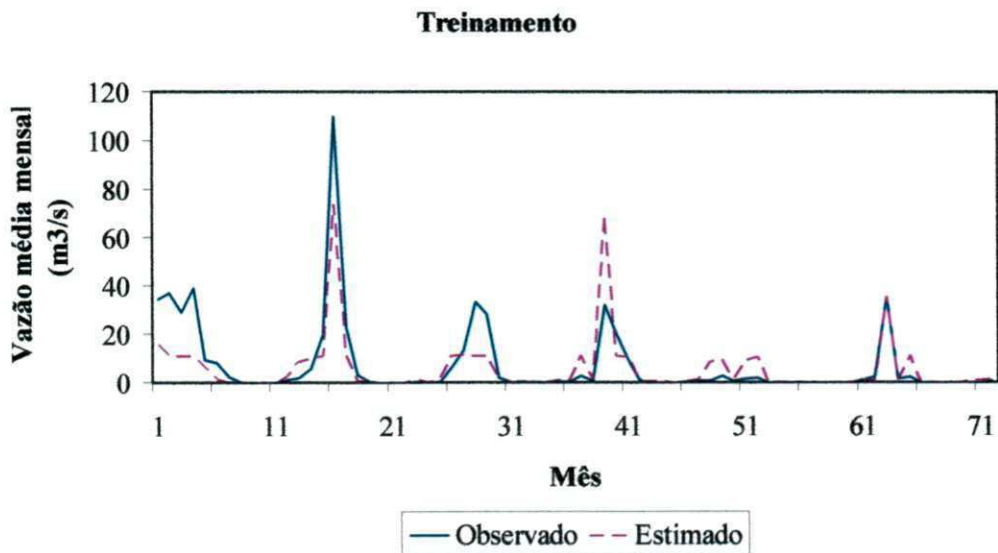
Tabela 6. Melhores arquiteturas, considerando o erro padrão de estimativa com valores menores que sete unidades, para o período de teste.

	Treinamento			Validação			Teste		
	R2	E	EPE	R2	E	EPE	R2	E	EPE
RC310L2	0,67	0,66	9,56	0,97	0,94	4,23	0,95	0,94	4,62
RC315L3	0,71	0,68	9,26	0,98	0,95	3,91	0,95	0,92	5,30
RC315L1	0,63	0,56	10,86	0,98	0,96	3,48	0,92	0,91	5,59
RC315L4	0,52	0,18	14,87	0,98	0,96	3,47	0,93	0,89	6,07
RC315T6	0,78	0,73	8,61	0,94	0,91	5,19	0,90	0,88	6,30
RC315T2	0,86	0,84	6,54	0,90	0,89	5,98	0,93	0,86	6,80


A Tabela 6 mostra que a arquitetura com melhor resultado em todos os parâmetros estatísticos foi o RC310L2, com coeficiente de determinação de 0,95, coeficiente de eficiência de 0,94, e erro padrão de estimativa de 4,62, considerando o período de teste. Essa arquitetura possui as seguintes características: para os dados de entrada utilizou-se a arquitetura três com valores normalizados, a camada intermediária possui dez neurônios, a função de transferência utilizada é a Log-sig. Esse resultado foi obtido em uma segunda inicialização.

A Figura 13 apresenta os resultados obtidos para a arquitetura RC310L2, divididos em treinamento, validação e teste. Na Figura 13 (a), processo de treinamento, observa-se que os valores estimados de vazão seguem o comportamento dos valores observados, mas não representa com precisão os picos, ora superestima ora subestima esses valores. O coeficiente de determinação, o coeficiente de eficiência e o erro padrão da estimativa são apresentados na Tabela 6, não sendo muito bons, mas considera-se que a rede está aprendendo. Na Figura 13 (b), processo de validação, os valores estimados de vazão apresentam desempenho satisfatório, representando com precisão os valores observados, principalmente os valores de pico, meses correspondentes aos números quatro e quinze. A tabela 6 apresenta o desempenho desse processo, e observa-se que os parâmetros estatísticos analisados, diferentes do processo de treinamento, foram melhores. O processo de teste é apresentado na Figura 13 (c) e mostra semelhança com o processo de validação,

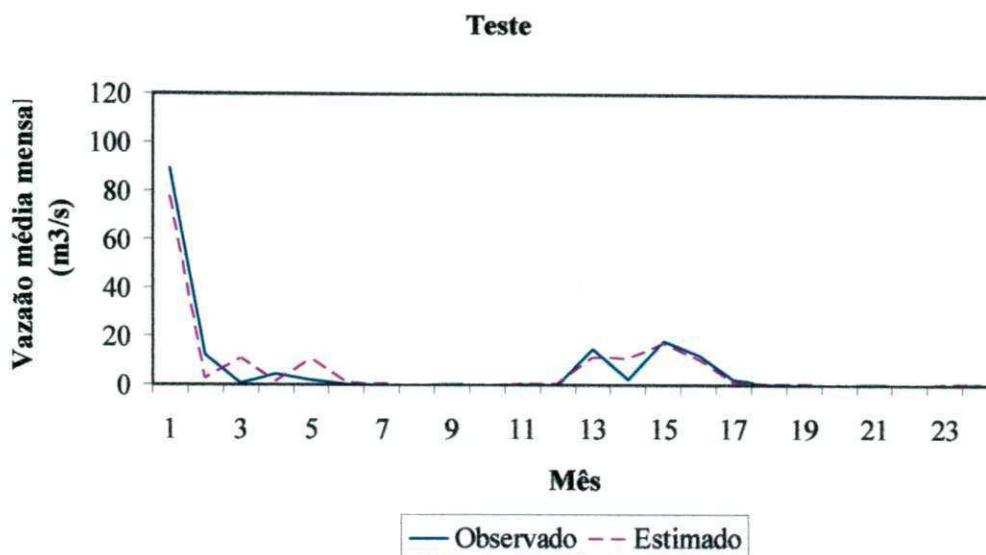
quanto aos parâmetros estatísticos utilizados para avaliar o desempenho. Observa-se que os valores estimados de vazão seguem o comportamento dos valores observados, com algumas imprecisões. Nos meses três, cinco e quatorze a rede superestima o valor da vazão, nos meses treze e quinze a estimativa é satisfatória representando bem o comportamento do pico de vazão dos dados observados.



(a)



(b)



(c)

Figura 12. Resultados obtidos utilizando a arquitetura RC310L2, divididos em três períodos, treinamento (a), validação (b) e teste (c).

Analisando de forma geral essa Tabela 6, observa-se que dentre as seis arquiteturas selecionadas apenas uma apresenta 10 neurônios na camada intermediária, as demais apresentam 15 neurônios nessa camada. Outra característica observada é referida a função de transferência, a função Log-sig se apresenta com maior frequência. Se a análise for realizada por arquitetura observa-se que a RC315L está presente em três inicializações, ou seja, 50% dos resultados. Já a arquitetura RC315T apresentou duas ocorrências, mas apresenta desempenho estatístico menos significativo do que as arquiteturas analisadas anteriormente.

A fim de aumentar a confiabilidade dos resultados obtidos anteriormente, fez-se necessário analisar, em média, qual seria a melhor arquitetura. Assim, foram efetuados os cálculos das médias das inicializações dos parâmetros estatísticos utilizados, em cada arquitetura, obtendo vinte resultados. Esses resultados estão dispostos na Tabela 7.

Tabela 7. Média das inicializações dos parâmetros estatísticos em cada arquitetura.

	Treinamento			Validação			Teste		
	R2	E	EPE	R2	E	EPE	R2	E	EPE
RS105T	0,18	0,17	14,98	0,14	0,12	16,69	0,09	0,02	18,13
RC105T	0,93	0,93	4,25	0,92	0,90	5,42	0,44	0,27	15,34
RC110T	0,94	0,94	3,61	0,88	0,86	6,10	0,37	0,18	16,54
RC115T	0,95	0,94	3,28	0,91	0,89	5,62	0,42	0,34	14,77
RC205T	0,92	0,92	4,46	0,92	0,89	5,68	0,77	0,38	14,39
RC210T	0,89	0,86	5,33	0,90	0,89	5,90	0,67	0,43	13,44
RC215T	0,94	0,90	4,23	0,87	0,85	6,83	0,72	0,56	12,02
RC305T	0,82	0,81	6,90	0,83	0,79	8,05	0,88	0,19	15,56
RC310T	0,72	0,62	9,65	0,89	0,85	6,58	0,79	0,50	12,41
RC315T	0,84	0,82	6,85	0,87	0,83	6,93	0,80	0,71	9,59
RS105L	0,23	0,21	14,55	0,16	0,13	16,57	0,05	-0,05	18,87
RC105L	0,94	0,94	3,74	0,89	0,86	6,23	0,59	0,45	13,37
RC110L	0,97	0,97	2,54	0,92	0,91	5,18	0,53	0,44	13,31
RC115L	0,93	0,93	3,82	0,86	0,85	6,86	0,47	0,42	13,73
RC205L	0,94	0,94	3,96	0,92	0,91	5,22	0,79	-0,10	17,94
RC210L	0,93	0,92	4,02	0,83	0,79	7,65	0,71	0,57	11,81
RC215L	0,90	0,89	5,17	0,81	0,79	8,02	0,72	0,55	12,28
RC305L	0,85	0,85	6,40	0,79	0,76	8,53	0,95	-0,57	21,22
RC310L	0,73	0,57	9,58	0,82	0,78	7,83	0,90	-0,06	16,63
RC315L	0,71	0,59	10,17	0,95	0,93	4,43	0,92	0,77	8,29

Com os valores médios das inicializações dos parâmetros estatísticos, realizou-se uma análise que considerou, para o período de teste, os valores do coeficiente de determinação maiores ou iguais a 90 por cento. O resultado dessa análise, mostrado na Tabela 8, indicou as três melhores arquiteturas. As arquiteturas RC305L e RC310L apresentaram valores negativos de E, indicando que suas eficiências não foram satisfatórias o bastante para simular os dados de vazão, já que o critério utilizado por esse coeficiente para o melhor desempenho são valores maiores que zero. No entanto, a arquitetura RC315L apresenta o melhor desempenho se analisado os três parâmetros estatísticos, R2, E e EPE, com valores de 0,92, 0,77 e 8,29 respectivamente. Lima et al. (2003) obtiveram no

estudo realizado no semi-árido cearense, valores para o coeficiente de determinação de 0,86 na melhor arquitetura.

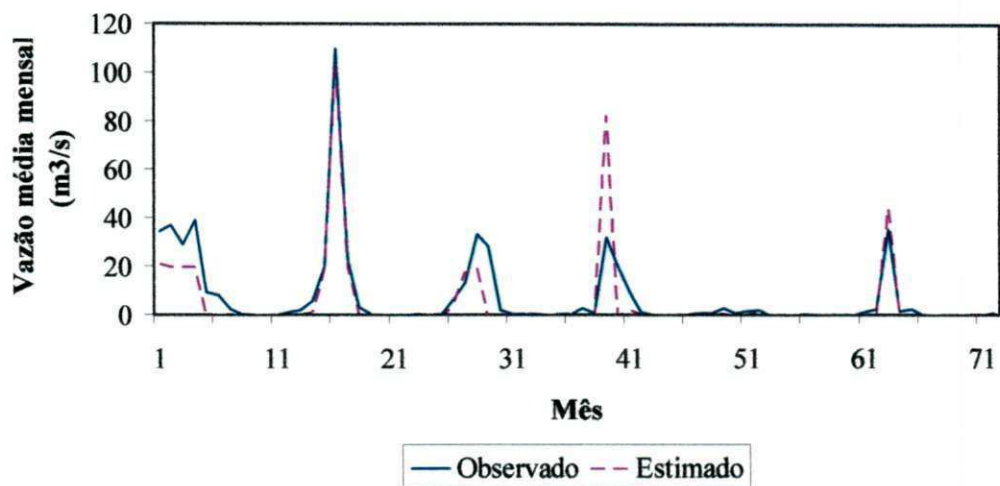
Tabela 8. Melhores arquiteturas pela média das inicializações, considerando o coeficiente de determinação com valores maiores ou iguais a 90 por cento, para o período de teste.

	Treinamento			Validação			Teste		
	R2	E	EPE	R2	E	EPE	R2	E	EPE
RC305L	0,85	0,85	6,40	0,79	0,76	8,53	0,95	-0,57	21,22
RC315L	0,71	0,59	10,17	0,95	0,93	4,43	0,92	0,77	8,29
RC310L	0,73	0,57	9,58	0,82	0,78	7,83	0,90	-0,06	16,63

De forma geral, a arquitetura RC315L apresentou o melhor desempenho estatístico, com valor maior que 0,90 no coeficiente de determinação, maior que zero no coeficiente de eficiência e valor consideravelmente menor no erro padrão da estimativa. Essa arquitetura apresenta as seguintes características: para os dados de entrada utilizou-se o modelo três com valores normalizados, a camada intermediária possui quinze neurônios e a função de transferência utilizada é a Log-sig. Os resultados obtidos utilizando a arquitetura, divididos em treinamento, validação e teste, são apresentados na Figura 14.

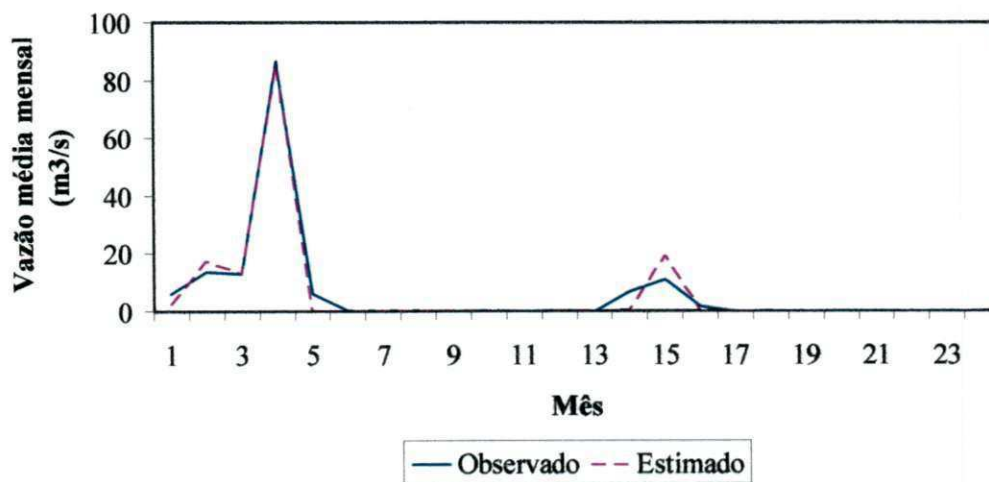
A Figura 14 (a) mostra os resultados obtidos na fase de treinamento, observa-se que os valores estimados de vazão seguem o comportamento dos valores observados, representando com certa precisão alguns picos, mas ora superestima ora subestima outros. O coeficiente de determinação, o coeficiente de eficiência e o erro padrão da estimativa são apresentados na Tabela 8, com valores satisfatórios, considerando que a rede esta sendo treinada. Na Figura 14 (b) os resultados se referem à fase de validação, os valores estimados de vazão apresentam o mesmo comportamento dos dados observados, superestimando o valor de vazão de pico no mês representado pelo número quinze. A Tabela 8 apresenta os parâmetros estatísticos analisados nesse processo, e observa-se melhores resultados que no processo de treinamento. O processo de teste é apresentado na Figura 14 (c) e mostra semelhança com o processo de validação, quanto aos parâmetros estatísticos utilizados para avaliar o desempenho. Observa-se que os valores estimados de vazão seguem o comportamento dos valores observados, com algumas imprecisões. No mês três há uma superestimação no valor da vazão, e nos meses treze e quinze a estimativa é satisfatória representando bem o comportamento do pico de vazão dos dados observados.

Treinamento



(a)

Validação



(b)

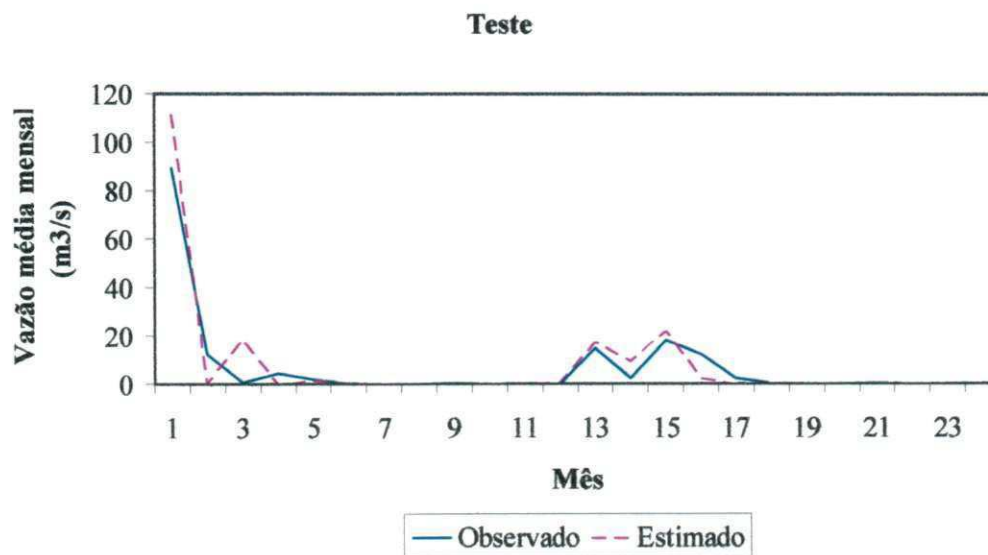


Figura 13. Resultados obtidos utilizando a arquitetura RC315L, divididos em três períodos, treinamento (a), validação (b) e teste (c).

6. CONCLUSÕES E SUGESTÕES

- O aumento dos volumes escoados, medidos na estação fluviométrica de Piancó teve correspondência com o aumento dos volumes precipitados, medidos nas estações pluviométricas de Piancó, Santana dos Garrotes, Nova Olinda, Boa Ventura e Itaporanga;
- Na primeira avaliação, a que considera apenas o coeficiente de determinação no período de teste, a arquitetura RC305T3 obteve o melhor desempenho com valor de 97,0 % para esse coeficiente;
- As 24 melhores arquiteturas utilizaram como entrada os valores normalizados da precipitação média dos cinco postos pluviométricos: Piancó, Santana dos Garrotes, Nova Olinda, Boa Ventura e Itaporanga. Dentre essas, a melhor arquitetura foi a RC305L, considerando a maior frequência de inicializações;
- Pela análise de frequência de repetições, nas 24 melhores arquiteturas observa-se que a arquitetura RC305L e a função de transferência Log-sig foram utilizadas em maior quantidade e a arquitetura RC315L foi utilizada em maior quantidade, com bons índices de desempenho;
- Em uma avaliação mais precisa, que considera todos os índices de desempenho para o período de teste, a arquitetura RC310L2 apresentou os melhores resultados. Nessa arquitetura o coeficiente de determinação foi de 95,0 %, o de eficiência foi igual a 94,0 % e o erro padrão de estimativa igual a 4,62;

- Considerando os valores médios dos parâmetros estatísticos das inicializações em cada arquitetura, a arquitetura RC315L foi a que obteve o melhor desempenho estatístico. Nessa arquitetura o valor do coeficiente de determinação foi superior a 90,0% o coeficiente de eficiência de 0,77 e o erro padrão da estimativa de 8,29.
- A arquitetura RC315L com base em RNA e na função de transferência Log-sig com quinze neurônios na camada intermediária pode ser utilizada para simular e prever as vazões médias mensais da bacia hidrográfica estudada.
- Sugere-se em trabalhos futuros se aplicar a metodologia proposta nesta pesquisa para modelar eventos horários, diários e semanais, juntamente com a investigação de outros algoritmos de treinamento para a RNA, e a utilização de amostras de dados observados maior, com melhor distribuição espacial no âmbito da bacia hidrográfica. Sugere ainda que se comparem os resultados obtidos com os resultados de outros modelos hidrológicos.

REFERÊNCIAS BIBLIOGRÁFICAS

AESA. Agência Executiva de Gestão das Águas do Estado da Paraíba. Disponível em <<http://www.acsa.pb.gov.br>>. Acessado em set. 2007.

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://www.ana.gov.br>>. Acessado em set. 2007.

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.

ARAÚJO, P. C. Aplicação do modelo GR4J à bacia hidrográfica do Rio Paraíba em Caraúbas. Dissertação do Curso de Mestrado em Meteorologia, Universidade Federal de Campina Grande, Campina Grande, 2005.

BARROS, M.T.L.; TSAI, F.T-C.; YANG, S-L.; LOPES, J.E.G.; YEH, W.W-G. Optimization of Large-Scale Hydropower System Operations. *Journal of Water Resources Planning and Management*. V.129, n.3, p.178-188. 2003.

DEMUTH, H.; BEALE, M. *Neural Network Toolbox for use with MATLAB – User's guide*, version 3. The MathWorks, Inc, 1998.

ELSHORBAGY, A.; SIMONOVIC, S. P.; PANU, U. S.; Performance evaluation of artificial neural networks for runoff prediction. *Journal of Hydrologic Engineering*, Reston, v. 5, n. 4, p. 424-427, Oct. 2000.

FAG. Fundação Assis Gurgacz. Disponível em <<http://www.fag.edu.br>>. Acessado em jan. 2008.

FAVORETO, R.S.; ROHN, M.C.; MINE, M.R.M.. A técnica de rede neural artificial aplicada na previsão de vazão. 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.

FERNANDES, L. G. L.; NAVAU, P. O. A.; PORTUGUAL, M. S. Previsão de Séries de tempo: Redes Neurais Artificiais e Modelos Estruturais. *Pesquisa e Planejamento Econômico, PPE*: v. 26, n.2, p. 253-276, Ago. 1996.

FLOOD, I.; KARTAM, N. Neural networks in civil engineering I: principles and understanding, *Journal Computational Civil Engineering*, Nº 8, 1994, p. 131-148.

GALVÃO, C.O.; VALENÇA, M.J.S. *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*. 1ª ed. Porto Alegre, Editora da Universidade/UFRGS/ABRRH, 246p. Coleção ABRH de Recursos Hídricos; vol. 7.1999.

HAGAN, M.T.; DEMUTH, H.B.; BEALE, M.H. *Neural Network Design*, Boston, MA: PWS Publishing, 1996.

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

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.

HANSELMAN, D.; LITTLEFIELD, B. MATLAB 5 Versão do Estudante – Guia do Usuário. São Paulo: MAKRON Books, 1999.

HAYKAN, S. Neural Networks – A comprehensive Foundation. New York: Macmillan College Publishing Company, 1994.

HINES, J. W. MATLAB, Supplement to fuzzy and neural approaches in engineering. Chichester: John Wiley & Sons, 1997.

HSU, K. L.; GUPTA, 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.

KOVÁCS, Z. L. Redes Neurais Artificiais: fundamentos e aplicações. 2 ed., São Paulo, Editora Collegium Cognition, 174p, 1996.

LABADIE, J.W. Optimal Operation of Multireservoir Systems: State-of-the-Art Review. Journal of Water Resources Planning and Management. V.130, n.2, p.93-111. 2004.

LIMA, C. H. R.; FERRERIA FILHO, W. M. Análise de modelos de redes neurais aplicados ao processo chuva-deflúvio no semi-árido. In: Simpósio Brasileiro de Recursos Hídricos, 15, 2003, Curitiba. Relação de trabalhos. Curitiba: ABRH, 2003. 1 CD ROOM.

LOESCH, C.; SARI, S. Redes neurais artificiais: fundamentos e modelos. Blumenau, Editora da FURB, 125p, 1996.

LOKE, E. Introduction to artificial neural networks in urban hydrology, 1995.

LORRAI, M; SECHI, G. M. Neural nets for modelling rainfall-runoff, transformations, Water Resources Manage. Nº 9, 1995, p. 299-313.

MAIDMENT, D. R. GIS and hydrologic modeling. In: GOODCHILD, M. F.; PARKS, B. O.; STEYART, L. T.; ed. Environmental modeling with GIS. New York, Oxford University Press, 1993. Cap. 14, p. 147-167.

MAIER, H. R.; DANDY, G. D. Neural Networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications, *Environmental Modelling Software*, N° 15, 2000, p. 101-124.

MORIASI, D. N.; ARNOLD, J. G.; VAN LIEW, M. W.; BINGNER, R. L.; HARMEL, R. D.; VEITH, T. L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of American Society of Agricultural and Biological Engineers*, v. 50, n. 3, p. 885-900, 2007.

MÜLLER, M.; FILL, H.D. Redes neurais aplicadas na propagação de vazões. In: XV Simpósio Brasileiro de Recursos Hídricos. CD-ROM. Curitiba / PR, 2003.

NAYAK, P.C.; SUDHEER, K.P.; RANGAN, D.M.; RAMASASTRI, K.S. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*. vol. 291, pp. 52– 66, 2003.

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

OLIVEIRA, L. C. K. Papel do monitoramento e da previsão de vazões no gerenciamento de bacias hidrográficas. Dissertação do curso de Mestrado em Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2003.

OLIVO, A.A., SILVA, J.D.S., VIJAYKUMAR, N.L. Previsão de cheias fluviais usando redes neurais artificiais. In: VI Simpósio de Recursos Hídricos do Nordeste. Maceió / AL, 2002.

ONU. Organização das Nações Unidas. Disponível em <<http://www.onu-brasil.org.br>>. Acessado em dez. 2007.

PAIXÃO, F. J. R.; ANDRADE, A. R. S.; AZEVEDO, C. A. V.; SILVA, J. M.; COSTA, T. L.; FEITOSA, R. M. Estimativa da Infiltração da água no solo através de modelos empíricos e funções não lineares. Revista de Biologia e Ciências da Terra. Volume 5. Número 1. 2004

RAMOS, A. M.; GALVÃO, C. O. Estabilidade de redes neurais em modelagem hidrometeorológicas. In: Simpósio Brasileiro de Recursos Hídricos, 14, 2001, Aracaju. Relação de trabalhos. Aracaju: ABRH, 2001. 1 CD ROOM

RAUDKIVI, A. J., Hydrology: an advanced introduction to hydrological processes and Modeling. New York: Pergamon, 1979.

ROBINSON, R. Neural networks offer an alternative to traditional regression. Geobyte. February, p.14-19, 1991.

SANTOS, C.C. Modelagem de bacias urbanas com redes neurais artificiais. São Paulo. Dissertação de Mestrado – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Hidráulica e Sanitária, 105p, 2001.

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

SAJKUMAR, N.; THANDAVESWARA, B. S. A non-linear rainfall-runoff model using an artificial neural network. Journal of Hydrology 216, 1999.

SARLE, W. S. Neural networks and statistical models. Proceedings of the Nineteenth Annual SAS Users Group International Conference. Cary, NC: SAS Institute, 1994.

SHAMSELDIN; A. Y. Application of a neural network technique to rainfall-runoff modeling. Journal of Hydrology 199, 1997.

SOUSA, F. A. S.; SOUSA, W. S. Rede Neural Aplicada ao Processo Chuva-Vazão da Bacia Hidrográfica de Caraúbas- PB. XIV Congresso Brasileiro de Meteorologia. CD Rom. 2006.

SPERB, R. M.; MODRO, N. R.; MARCONDES, P.; FOES, P. A.; BARCIA, R. M.; PACHECO, R. C. S.; TAVARES, G. Prevent: protótipo de um sistema de previsão de enchentes baseado em redes neurais. Simpósio Brasileiro de Recursos Hídricos, 13, 1999, Belo Horizonte. Relação de Trabalhos. Belo Horizonte: Abril, 1999. 1 CD Room.

STEYAERT, L. T. A perspective on the state of environmental simulation modeling. In: GOODCHILD, M.F.; PARKS, B.O.; STEYAERT, L.T.; ed. Environmental modeling with GIS. New York, Oxford University Press, 1993. Cap. 3, p. 16-30.

TOKAR, A. S.; MARKUS, M. Precipitation-runoff modeling using artificial neural networks and conceptual models. Journal of Hydrologic Engineering, Reston: ASCE, v. 5, n. 2, p. 156-161, Apr. 2000.

TUCCI, C.E.M.; COLLISCHONN, W. Previsão de Vazão. In: TUCCI, C.E.M.; BRAGA, B. (Orgs.) Clima e Recursos Hídricos no Brasil. Porto Alegre: ABRH, p.281-348, nov. 2003.

UFRB. Universidade Federal do Recôncavo da Bahia. Disponível em <<http://www.ufrb.edu.br>>. Acessado em jan. 2008.

VALENÇA, M. J. S. e LUDERMIR, T. B. Introdução às redes neurais. In: Galvão, C. O., Valença, M. J. S. (Org.). Sistemas Inteligentes; aplicações a Recursos Hídricos e ciências ambientais. Porto Alegre: Associação Brasileira de Recursos Hídricos, p.19-59, 1999.

VAREJÃO-SILVA, M. A. Meteorologia e Climatologia. Brasília: INMET, Gráfica e Editora Pax, 2001.

VILLELA, S.; MATTOS, A. Hidrologia Aplicada, ed. McGraw-Hill, p. 244, São Paulo – SP, 1975.

ZEALAND, C. M.; BURN, D. H.; SIMONOVIC, S. P. Short term streamflow forecasting using artificial neural networks. *Journal of Hydrology* 214, 1999.

APÊNDICE A – DADOS DE VAZÃO MÉDIA MENSAL E PRECIPITAÇÃO MÉDIA MENSAL

Tabela A1. Dados de vazão média mensal, $Q(m^3/s)$, da estação fluviométrica de Piancó, e dados de precipitação média mensal, $P(mm)$, das estações pluviométricas em: Piancó, Santana dos Garrotes, Boa Ventura, Itaporanga, Nova Olinda. A média da precipitação nesses postos também esta disponível.

Período	Q (m ³ /s)		P (mm)					Média dos postos
	Piancó	Piancó	Santana dos Garrotes	Boa Ventura	Itaporanga	Nova Olinda		
1	Jan/94	34,5	283,0	226,6	252,6	211,4	220,0	238,7
2	Fev/94	37,2	132,0	144,9	233,3	259,4	226,1	199,1
3	Mar/94	29,3	191,0	223,5	169,2	190,5	239,2	202,7
4	Abr/94	39,2	145,0	190,8	230,9	241,1	193,0	200,2
5	Mai/94	9,5	44,0	71,5	74,4	135,3	110,0	87,0
6	Jun/94	8,5	75,0	56,4	28,5	13,1	60,1	46,6
7	Jul/94	2,7	0,0	11,8	0,0	11,0	3,8	5,3
8	Ago/94	0,3	0,0	0,0	0,0	0,0	0,0	0,0
9	Set/94	0,0	0,0	0,0	0,0	4,5	5,5	2,0
10	Out/94	0,0	0,0	0,0	0,0	28,6	2,5	6,2
11	Nov/94	0,1	0,0	0,0	0,0	0,0	0,0	0,0
12	Dez/94	1,2	33,0	0,0	105,4	107,5	158,4	80,9
13	Jan/95	2,1	35,0	25,0	137,7	200,6	64,5	92,6
14	Fev/95	6,0	61,0	82,6	143,4	90,9	144,6	104,5
15	Mar/95	19,8	118,0	217,8	158,3	168,2	233,7	179,2
16	Abr/95	110,0	235,0	347,6	306,9	347,2	292,3	305,8
17	Mai/95	22,8	364,0	140,6	129,9	165,2	137,6	187,5
18	Jun/95	3,2	2,0	2,0	29,0	40,3	27,4	20,1
19	Jul/95	0,6	8,0	1,0	40,3	24,9	3,3	15,5

continua

continuação

		Q (m3/s)		P (mm)				
Período		Piancó	Piancó	Santana	Boa	Itaporanga	Nova	Média
				dos	Ventura		Olinda	
				Garrotes				postos
20	Ago/95	0,2	0,0	0,0	0,0	0,0	0,0	0,0
21	Set/95	0,0	0,0	0,0	0,0	0,0	0,0	0,0
22	Out/95	0,0	0,0	5,5	1,0	0,0	0,0	1,3
23	Nov/95	0,4	87,5	37,0	64,0	45,4	63,4	59,5
24	Dez/95	0,2	0,0	0,0	13,0	7,1	3,6	4,7
25	Jan/96	0,4	56,7	41,5	22,2	58,4	80,0	51,8
26	Fev/96	6,2	60,3	152,8	176,9	104,6	150,5	129,0
27	Mar/96	13,4	322,1	207,5	134,0	258,1	178,5	220,0
28	Abr/96	33,4	262,5	193,4	133,3	244,4	105,7	187,9
29	Mai/96	28,3	126,0	174,2	117,4	104,4	177,6	139,9
30	Jun/96	2,2	62,0	31,6	0,0	29,4	23,1	29,2
31	Jul/96	0,5	0,0	0,0	26,4	0,0	0,0	5,3
32	Ago/96	0,3	17,0	9,0	7,4	0,0	18,6	10,4
33	Set/96	0,3	3,0	0,0	0,0	0,0	0,0	0,6
34	Out/96	0,2	0,0	0,0	6,4	3,5	20,7	6,1
35	Nov/96	0,5	64,4	83,2	38,0	108,0	44,9	67,7
36	Dez/96	0,3	36,5	0,5	0,0	25,0	52,8	23,0
37	Jan/97	2,8	206,5	82,1	128,6	153,9	169,1	148,0
38	Fev/97	0,9	51,0	50,2	22,0	74,0	76,4	54,7
39	Mar/97	31,9	347,1	225,5	234,8	400,2	202,1	281,9
40	Abr/97	20,5	92,5	143,6	101,6	218,1	130,2	137,2
41	Mai/97	9,6	69,4	94,0	147,4	144,7	120,1	115,1
42	Jun/97	1,3	2,0	0,0	0,0	16,9	40,7	11,9
43	Jul/97	0,2	0,0	0,0	12,8	21,9	13,2	9,6
44	Ago/97	0,2	11,0	0,0	3,8	23,4	7,5	9,1
45	Set/97	0,0	0,0	0,0	0,0	0,0	0,0	0,0

continua

continuação

Período	Q (m ³ /s)		P (mm)				Média dos postos	
	Piancó	Piancó	Santana dos Garrotes	Boa Ventura	Itaporanga	Nova Olinda		
46	Out/97	0,5	0,0	0,0	12,0	38,6	0,0	10,1
47	Nov/97	1,0	13,0	73,5	21,4	66,5	66,6	48,2
48	Dez/97	0,9	6,4	107,1	98,7	167,5	79,5	91,8
49	Jan/98	2,8	63,0	80,9	87,7	200,4	61,0	98,6
50	Fev/98	0,7	111,4	18,8	39,2	87,0	26,3	56,5
51	Mar/98	1,6	82,7	74,8	73,9	145,4	90,9	93,5
52	Abr/98	1,9	51,5	136,1	132,1	173,7	70,4	112,8
53	Mai/98	0,1	0,0	0,0	0,0	0,0	0,0	0,0
54	Jun/98	0,0	0,0	9,1	0,0	21,3	0,0	6,1
55	Jul/98	0,0	5,0	0,0	8,2	8,0	9,0	6,0
56	Ago/98	0,4	1,0	0,0	6,8	2,8	8,6	3,8
57	Set/98	0,1	0,0	0,0	0,0	0,0	0,0	0,0
58	Out/98	0,0	0,0	0,0	0,0	0,8	0,0	0,2
59	Nov/98	0,0	0,0	0,0	0,0	2,2	0,0	0,4
60	Dez/98	0,1	0,0	13,0	6,2	2,5	0,0	4,3
61	Jan/99	1,1	54,2	26,3	72,7	122,7	62,6	67,7
62	Fev/99	2,6	38,0	54,2	79,4	82,3	81,9	67,2
63	Mar/99	35,5	146,5	153,5	310,9	406,1	287,7	260,9
64	Abr/99	1,6	17,1	6,0	31,2	47,0	16,2	23,5
65	Mai/99	2,7	160,0	122,0	126,7	186,5	110,5	141,1
66	Jun/99	0,1	0,0	0,0	0,0	6,8	4,7	2,3
67	Jul/99	0,0	5,0	9,4	7,1	2,2	10,5	6,8
68	Ago/99	0,0	0,0	0,0	0,0	0,0	0,0	0,0
69	Set/99	0,0	0,0	0,0	0,0	0,0	0,0	0,0
70	Out/99	0,0	17,0	14,3	3,5	23,2	0,0	11,6
71	Nov/99	0,0	5,0	38,2	47,4	17,3	36,5	28,9

continua

continuação

Período	Q (m ³ /s)		P (mm)				Média dos postos	
	Piancó	Piancó	Santana dos Garrotes	Boa Ventura	Itaporanga	Nova Olinda		
72	Dez/99	0,7	49,9	73,2	74,3	74,3	30,9	60,5
73	Jan/00	6,4	165,1	119,2	95,7	130,0	84,3	118,9
74	Fev/00	13,9	228,1	182,0	205,4	255,2	224,9	219,1
75	Mar/00	13,2	208,9	105,0	188,7	183,5	155,1	168,2
76	Abr/00	86,9	258,4	263,4	291,9	390,4	213,1	283,4
77	Mai/00	6,2	27,0	25,0	27,4	24,5	32,6	27,3
78	Jun/00	0,5	11,0	15,0	50,5	4,0	52,9	26,7
79	Jul/00	0,2	7,0	0,0	34,5	5,8	21,7	13,8
80	Ago/00	0,2	11,0	15,0	31,1	16,2	11,2	16,9
81	Set/00	0,0	16,0	0,0	29,0	8,2	0,0	10,6
82	Out/00	0,2	0,0	0,0	9,0	28,0	24,2	12,2
83	Nov/00	0,0	0,0	0,0	0,0	0,0	0,0	0,0
84	Dez/00	0,4	48,0	92,0	46,1	81,7	83,2	70,2
85	Jan/01	0,0	56,0	0,0	33,6	18,2	22,5	26,1
86	Fev/01	7,0	64,3	106,0	83,6	162,4	72,1	97,7
87	Mar/01	11,0	215,8	185,8	202,1	222,3	328,2	230,8
88	Abr/01	1,7	97,5	20,8	29,4	21,5	42,3	42,3
89	Mai/01	0,1	6,0	2,0	19,0	0,0	0,0	5,4
90	Jun/01	0,0	43,0	16,0	21,6	46,8	0,0	25,5
91	Jul/01	0,0	0,0	0,0	22,4	9,6	0,0	6,4
92	Ago/01	0,0	0,0	0,0	0,0	0,0	0,0	0,0
93	Set/01	0,0	5,0	0,0	0,0	4,4	0,0	1,9
94	Out/01	0,1	18,0	44,0	78,0	38,7	8,2	37,4
95	Nov/01	0,0	0,0	0,0	0,0	2,0	0,0	0,4
96	Dez/01	0,0	109,9	57,5	123,2	0,0	162,4	90,6
97	Jan/02	89,4	634,0	327,0	396,5	345,4	387,9	418,2

continua

continuação

		Q (m3/s)		P (mm)				
Período	Piancó	Piancó	Santana dos Garrotes	Boa Ventura	Itaporanga	Nova Olinda	Média dos postos	
98	Fev/02	12,6	74,4	96,2	62,0	112,5	57,7	80,6
99	Mar/02	0,9	148,3	153,4	192,1	194,7	201,4	178,0
100	Abr/02	4,5	81,3	27,0	26,0	42,2	68,2	48,9
101	Mai/02	2,1	113,2	93,5	131,8	139,5	84,5	112,5
102	Jun/02	0,5	56,8	0,0	16,8	60,2	7,0	28,2
103	Jul/02	0,2	2,0	0,0	11,0	15,4	15,6	8,8
104	Ago/02	0,0	0,0	0,0	0,0	0,0	0,0	0,0
105	Set/02	0,3	0,0	0,0	0,0	0,0	0,0	0,0
106	Out/02	0,0	8,2	0,0	0,0	2,0	0,0	2,0
107	Nov/02	0,3	0,0	0,0	22,7	41,8	0,0	12,9
108	Dez/02	0,0	0,0	0,0	52,1	2,8	54,2	21,8
109	Jan/03	14,8	189,6	156,0	222,4	375,8	155,1	219,8
110	Fev/03	2,7	187,4	154,8	146,0	160,6	177,6	165,3
111	Mar/03	18,4	97,0	241,8	351,6	213,6	308,7	242,5
112	Abr/03	12,3	204,9	69,5	60,9	145,4	114,8	119,1
113	Mai/03	2,3	45,9	35,5	24,4	57,5	7,0	34,1
114	Jun/03	0,3	8,0	17,9	18,0	9,8	40,3	18,8
115	Jul/03	0,0	0,0	14,7	13,6	15,5	11,2	11,0
116	Ago/03	0,1	0,0	0,0	0,0	0,0	0,0	0,0
117	Set/03	0,4	0,0	0,0	4,0	7,8	0,0	2,4
118	Out/03	0,1	0,0	0,0	4,0	0,0	5,0	1,8
119	Nov/03	0,1	0,0	11,9	37,5	40,2	14,6	20,8
120	Dez/03	0,6	0,0	0,0	30,8	16,1	19,6	13,3

APÊNDICE B

Figura B1. Mapa do estado da Paraíba com as estações pluviométricas e fluviométricas. Destacado em vermelho a região estudada. Fonte: AESA.

