

**UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E AMBIENTAL
MESTRADO EM ENGENHARIA CIVIL
ÁREA DE CONCENTRAÇÃO EM RECURSOS HÍDRICOS**

**ESTUDO DA TRANSFORMAÇÃO PRECIPITAÇÃO-DEFLÚVIO PARA A SUB-
BACIA DO ARNEIROZ II**

FRANCISCO ALBERTO DE ASSIS TEIXEIRA

**FORTALEZA – CEARÁ
2009**

FRANCISCO ALBERTO DE ASSIS TEIXEIRA

**ESTUDO DA TRANSFORMAÇÃO PRECITAÇÃO-DEFLÚVIO PARA A SUB-
BACIA DO ARNEIROZ II**

Dissertação apresentada ao Curso de Mestrado em Engenharia Civil/Área de Concentração em Recursos Hídricos da Universidade Federal do Ceará, como requisito parcial para obtenção do grau de Mestre.

Orientador: Professor Silvrano Adonias Dantas Neto

**FORTALEZA - CEARÁ
SETEMBRO - 2009**

Esta Dissertação foi submetida como parte dos requisitos necessários à obtenção do Grau de Mestre em Engenharia Civil/Área de Concentração em Recursos Hídricos, outorgado pela Universidade Federal do Ceará, e encontra-se à disposição dos interessados na Biblioteca de Pós-Graduação do Centro de Tecnologia da referida Universidade.

A citação de qualquer trecho desta Dissertação é permitida, desde que seja feita de conformidade com as normas da ética científica.

Francisco Alberto de Assis Teixeira

Dissertação Aprovada em: ____/____/____

Examinadores:

Professor Silvrano Adonias Dantas Neto, Dr.
(Orientador da Dissertação)

Professor Francisco de Assis de Souza Filho, Dr
Universidade Federal do Ceará

José Sérgio dos Santos, Dr
Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Dr.

ABSTRACT

The modeling of environmental phenomena, as rain-flow transformation, involves a series of parameters, becoming quite difficult his prediction. On Ceara State this is a hard task because of a small number of data flow is available. No Estado do Ceará, esta tarefa se torna ainda mais complicada, devido à carência de dados pluviométricos, e, sobretudo por se tratar de uma região caracterizada pelos baixos índices pluviométricos e pelo regime pluviométrico intermitente preponderante. Os modelos do tipo transformação de chuva em vazão SMAP e HYMOD em intervalo diário, os quais apresentam como entradas, além da altura média de precipitação, a evaporação, têm sido aplicados a bacias hidrográficas do Ceará apresentando bons índices de correlação na fase de validação. A calibração destes modelos envolve o ajuste dos seus parâmetros percorrendo-se um espaço de busca a fim de se minimizar uma função objetivo, tratando-se de um processo estocástico. Desta forma, objetivando-se apresentar um modelo não-paramétrico e determinístico para a transformação chuva-deflúvio, são utilizadas as Redes Neurais Artificiais, as quais têm apresentado desempenho satisfatório na modelagem de problemas de difícil predição, inclusive no âmbito dos recursos hídricos. Para o estudo de caso foi escolhida a bacia hidrográfica da Barragem Arneiroz II, a qual dispõe de um posto pluviométrico com uma série pseudo-histórica relativamente extensa. Assim, foram calibrados os modelos HYMOD, SMAP, modelos tradicionalmente utilizados pela FUNCEME, e uma rede neural do tipo perceptron multicamadas, treinada pelo algoritmo de retro propagação através do programa *Q-net*. Para a calibração dos modelos SMAP e HYMOD foi utilizado um algoritmo evolucionário denominado *Particle Swarm Optimization* (PSO). Os resultados obtidos com o modelo de RNA foram comparados aos resultados obtidos pelos modelos SMAP e HYMOD através do parâmetro de desempenho proposto por Nash & Sutcliffe (1970). Os resultados obtidos mostraram que o modelo HYMOD foi aquele para o qual parâmetro de Nash obtido foi maior que os valores dos modelos SMAP e RNA. A modelagem chuva-deflúvio com as RNA não apresentaram resultados satisfatórios se comparados aos outros dois modelos hidrológicos empregados. Isto pode ser justificado pelo fato de que o modelo considerou apenas os dados de pluviometria, não tendo sido abastecido com outras variáveis importantes na definição do fenômeno chuva-vazão.

Palavras-chave: redes neurais artificiais, modelagem hidrológica, calibração.

RESUMO

A modelagem do comportamento de fenômenos complexos, como a transformação de chuva em vazão, envolve o ajuste de uma série de parâmetros, conferindo relativa dificuldade para sua predição. No Estado do Ceará, esta tarefa se torna ainda mais complicada, devido à carência de dados fluviométricos, e, sobretudo por se tratar de uma região caracterizada pelos baixos índices pluviométricos e pelo regime fluviométrico intermitente preponderante. Os modelos do tipo transformação de chuva em vazão SMAP e HYMOD em intervalo diário, os quais apresentam como entradas, além da altura média de precipitação, a evaporação, têm sido aplicados a bacias hidrográficas do Ceará apresentando bons índices de correlação na fase de validação. A calibração destes modelos envolve o ajuste dos seus parâmetros percorrendo-se um espaço de busca a fim de se minimizar uma função objetivo, tratando-se de um processo estocástico. Desta forma, objetivando-se apresentar um modelo não-paramétrico e determinístico para a transformação chuva-deflúvio, são utilizadas as Redes Neurais Artificiais, as quais têm apresentado desempenho satisfatório na modelagem de problemas de difícil predição, inclusive no âmbito dos recursos hídricos. Para o estudo de caso foi escolhida a bacia hidrográfica da Barragem Arneiroz II, a qual dispõe de um posto fluviométrico com uma série pseudo-histórica relativamente extensa. Assim, foram calibrados os modelos HYMOD, SMAP, modelos tradicionalmente utilizados pela FUNCEME, e uma rede neural do tipo perceptron multicamadas, treinada pelo algoritmo de retro propagação através do programa *Q-net*. Para a calibração dos modelos SMAP e HYMOD foi utilizado um algoritmo evolucionário denominado *Particle Swarm Optimization* (PSO). Os resultados obtidos com o modelo de RNA foram comparados aos resultados obtidos pelos modelos SMAP e HYMOD através do parâmetro de desempenho proposto por Nash & Sutcliffe (1970). Os resultados obtidos mostraram que o modelo HYMOD foi aquele para o qual o parâmetro de Nash obtido foi maior que os valores dos modelos SMAP e RNA. A modelagem chuva-deflúvio com as RNA não apresentaram resultados satisfatórios se comparados aos outros dois modelos hidrológicos empregados. Isto pode ser justificado pelo fato de que o modelo considerou apenas os dados de pluviometria, não tendo sido abastecido com outras variáveis importantes na definição do fenômeno chuva-vazão.

Palavras-chave: redes neurais artificiais, modelagem hidrológica, calibração.

LISTA DE FIGURAS

Figura 2.1 - Ilustração do Modelo SMAP (Lopes <i>et al</i> , 1981).	16
Figura 2.2 – Representação da bacia hidrográfica no modelo HYMOD (Bos & Vreng <i>apud Barros</i> , 2007).....	25
Figura 2.3 – Representação do Modelo HYMOD.	25
Figura 2.4 – Neurônio Biológico.	25
Figura 2.5 – Representação esquemática da integração espacial temporal dos estímulos por um neurônio (Kóvacs, 2002).	25
Figura 2.6 – Exemplo de Arquitetura de Rede.	25
Figura 2.7 – Representação esquemática do processo de aprendizagem por correção do erro (Haykin, 2001).	25
Figura 2.8 – Representação da superfície de erros ($E(w)$), pertencendo ω_1 e ω_2 ao \mathbb{R}^2 ...	25
Figura 2.9 – Estímulo dado pelos sinais de entrada e cálculo de todos os neurônios das camadas ocultas até a de saída	30
Figura 2.10 – Passo para trás, ilustrando produção do sinal de erro, o qual é retro propagado para a correção dos pesos sinápticos	31
Figura 2.11 – Neurônio pertencente à camada de saída.....	32
Figura 2.12 – Neurônio pertencente à camada de intermediária.....	33
Figura 3.1 – Fotografia aérea do Arneiroz II (SRH, 2005)	39
Figura 3.2 – Mapa de localização da bacia hidrográfica do arneiroz II	40
Figura 4.1 – Fotografia aérea do Arneiroz II (SRH, 2005)	47
Figura 4.2 – Gráfico da função Sigmóide	49
Figura 4.3 – Valores de coeficiente de Nash para as fases de treinamento e validação ..	52
Figura 4.4 – Arquitetura de rede escolhida para modelagem com as RNA	52
Figura 4.5 – Correlação entre as vazões observadas e as vazões calculadas pelo modelo com as RNA, na fase de treinamento	53
Figura 4.6 – Hidrograma observado e hidrograma determinado pelo modelo com as RNA	54
Figura 4.7 – Arquitetura de rede escolhida para modelagem com as RNA	25
Figura 4.8 – Hidrograma observado e hidrograma determinado pelo modelo com as RNA	25
Figura 4.9 – Decrescimento do erro quadrático em função do número de épocas, N	25
Figura 4.10 – Correlação entre as vazões observadas e as vazões calculadas pelo modelo com as RNA, após o treinamento da rede com validação cruzada	25

LISTA DE TABELAS

Tabela 3.1 - Reservatórios da bacia hidrográfica da barragem Arneiroz II.	38
Tabela 3.2 - Informações dos postos pluviométricos.....	44
Tabela 4.1 - Valores dos coeficientes de Nash para treinamento e validação do modelo com as RNA.	51
Tabela 4.2 - Valores dos coeficientes de Nash para calibração e validação do modelo SMAP.	59
Tabela 4.3 - Parâmetros calibrados para o modelo SMAP.....	61
Tabela 4.4 - Parâmetros calibrados para o modelo HYMOD.....	65
Tabela 4.5 - Valores dos coeficientes de Nash para calibração e validação do modelo HYMOD.	67

SUMÁRIO

1. INTRODUÇÃO	10
1.1. Justificativa	10
1.2. Objetivos	11
1.2.1. Objetivos Gerais	11
1.2.2. Objetivos Específicos	12
1.3. Metodologia Empregada	12
1.4. Organização dos Capítulos	13
2. REVISÃO BIBLIOGRÁFICA	14
2.1. Modelos Hidrológicos	14
2.2. O Modelo SMAP	15
2.3. O Modelo HYMOD	19
2.4. Redes Neurais Artificiais	21
2.4.1. Generalidades	21
2.4.2. As Redes Neurais Artificiais: Perceptron	25
2.4.3. Aprendizagem das Redes Neurais Artificiais	26
2.4.4. Etapas de um Processo de Modelagem com as RNA	35
2.5. Parâmetro de Desempenho de Nash	36
3. DESCRIÇÃO DA BACIA HIDROGRÁFICA E DOS DADOS HIDROLÓGICOS UTILIZADOS	38
3.1. Área de Estudo	38
3.2. Descrição dos Dados Utilizados	43
3.3. Análise dos Dados Pluviométricos	44
3.4. Análise dos Dados Fluviométricos	45
4. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS	46
4.1. Introdução	46
4.2. Descrição do Programa Q-net	47
4.3. Tratamento dos Dados de Treinamento e Validação	48
4.4. Resultados Obtidos com as RNA	50
4.5. Resultados Obtidos com o SMAP	58
4.6. Resultados Obtidos com o HYMOD	64

4.7.	Comparação entre os Resultados Obtidos com as RNA, SMAP e HYMOD	70
5.	CONCLUSÕES E SUGESTÕES PARA FUTUROS TRABALHOS	71
5.1.	Conclusões	71
5.2.	Sugestões para Pesquisas Futuras.....	72
	REFERÊNCIAS BIBLIOGRÁFICAS	73
	APÊNDICES	74

1. INTRODUÇÃO

1.1. Justificativa

O gerenciamento dos recursos hídricos, bem como o dimensionamento de obras hidráulicas, depende, além de outros estudos, da representação de fenômenos complexos, caso das transformações de chuva em deflúvio, através de modelos matemáticos. Esta é uma tarefa de difícil execução, sobretudo no Estado do Ceará, o qual carece de um histórico satisfatoriamente extenso de dados fluviométricos e pluviométricos.

Dentre os métodos tradicionais utilizados para a realização dos estudos hidrológicos necessários, sobretudo na fase de projeto, podem ser citados os métodos estatísticos, os quais se baseiam em teorias de probabilidade que se ajustam a uma amostra; os métodos empíricos, os quais estimam a vazão calcados nas características fisiográficas da bacia hidrográfica e os métodos hidrometeorológicos, os quais procuram definir o valor limite da magnitude da enchente a partir da avaliação máxima da precipitação fisicamente possível de ocorrer sobre a bacia, baseado na análise de informações climáticas disponíveis e nos princípios da meteorologia.

Os modelos hidrológicos em geral, quanto à forma de representar e incorporar os dados de entrada, podem ser classificados como concentrados ou distribuídos. Os modelos concentrados são aqueles que representam a bacia hidrográfica considerando-a como uniforme e tratando as séries históricas de precipitações como geradoras de lâminas de escoamento médio sobre a bacia hidrográfica em estudo.

Em detrimento aos modelos hidrológicos concentrados, os modelos hidrológicos distribuídos procuram representar em sua modelagem matemática a diversidade inerente ao espaço da bacia hidrográfica em estudo em função dos diferentes recursos naturais nela encontrados.

O fato de incorporar uma grande variedade de parâmetros em sua modelação confere aos modelos hidrológicos distribuídos certa dificuldade na fase de calibração. Este panorama se mostra, pois, favorável à experimentação de diferentes metodologias para a busca de resultados satisfatórios, seja com métodos para a calibração do modelo estudado, ou com novos modelos não paramétricos que buscam uma solução numérica para a representação do fenômeno, caso das redes neurais artificiais.

Como objeto de estudo destes métodos então descritos foi tomada a bacia hidrográfica da barragem Arneiroz II, a qual realiza o barramento do rio Jaguaribe no município de Arneiroz. Esta bacia dispõe de um posto fluviométrico e de vários postos pluviométricos, necessários para a obtenção de dados consistentes, os quais possibilitarão o fornecimento de bons resultados.

As RNA se apresentam como uma poderosa ferramenta para o estudo de sistemas complexos, não lineares e de padrões dificilmente representáveis por modelagens matemáticas tradicionais. Isto se justifica pelo fato de as RNA munirem-se de uma capacidade única de aprender o espaço na qual estão inseridas, a partir de um processo de treinamento.

Dentre as características inerentes às Redes Neurais, as quais justificam a sua aplicação na tentativa de simular o comportamento do deflúvio do Rio Jaguaribe nas proximidades da barragem Arneiroz II, apontando suas principais vantagens, podem ser citadas (Kasabov, 1998):

- a) Aprendizado - a rede pode começar a partir de um conhecimento zero e pode ser treinada usando-se uma série de dados como exemplos;
- b) Generalização – consiste na capacidade de o modelo produzir os melhores resultados, sendo fornecido um vetor de entrada o qual difere dos exemplos de aprendizagem;
- c) Paralelismo potencial sólido – indica a capacidade de a rede trabalhar, durante o processamento dos dados, vários neurônios simultaneamente;
- d) Robustez – uma rede robusta apresenta a capacidade de fornecer bons resultados mesmo com alguns neurônios desativados.

Trabalhos em outros campos, não somente da engenharia, atestam a eficiência das RNA quando utilizadas como sistemas de apoio à decisão. Dentre estes, menciona-se o trabalho de Faria Andrade et al., o qual utiliza os conceitos de RNA para classificar imagens de satélite de alta resolução através de variáveis espectrais.

O presente trabalho foi, pois, impulsionado pela capacidade de a ferramenta então proposta possivelmente suprir as necessidades dos hidrólogos em apoiarem suas decisões em resultados confiáveis.

1.2. Objetivos

1.2.1. Objetivos Gerais

O principal objetivo do presente trabalho consiste da aplicação de conceitos pertinentes às Redes Neurais Artificiais em conjunto com os conceitos hidrológicos os quais regem as características de uma bacia hidrográfica quanto ao seu escoamento.

1.2.2. Objetivos Específicos

Os principais objetivos do projeto podem ser assim enumerados:

- a) Realizar levantamento bibliográfico sobre modelos chuva-vazão tradicionais, bem como sobre redes neurais artificiais;
- b) Levantar informações das séries históricas de precipitações e dados de vazões para a bacia em estudo;
- c) Utilizar o programa Q-net para o treinamento e validação da rede;
- d) Propor uma metodologia de previsão de vazões satisfatória e de fácil implementação;
- e) Comparar os resultados obtidos pelas RNA com os modelos tradicionais SMAP e HYMOD.

1.3. Metodologia Empregada

O desenvolvimento deste trabalho se deu com o objetivo de se aplicar um modelo utilizando RNA, na busca de uma modelagem capaz de representar o fenômeno chuva-vazão. Para tanto, os seguintes procedimentos se apresentaram imprescindíveis para esta realização:

- a) Levantamento bibliográfico – reunião de informações sobre as bases teóricas relacionadas às redes neurais artificiais, bem como sobre os conceitos hidrológicos os quais influenciam diretamente na modelagem do comportamento do deflúvio;
- b) Seleção e coleta de dados – consiste na aquisição de dados pluviométricos e fluviométricos, principalmente daqueles publicados nos sítios eletrônicos da Agência Nacional das Águas (ANA) e da Fundação Cearense de Meteorologia (FUNCEME);
- c) Modelagem chuva-vazão utilizando as RNA – consiste na aplicação das teorias envolvendo as RNA em conjunto com outras metodologias consagradas para o estudo do escoamento na bacia hidrográfica do Açude Arneiroz II;

- d) Modelagem chuva-vazão utilizando o SMAP e o HYMOD – consiste na aplicação de ambos os modelos para a modelagem do fenômeno chuva-vazão, para que se determine o qual apresentou melhores resultados para a região de estudo;
- e) Definição do modelo que melhor se aplica à representação do deflúvio em função da pluviometria observada na região de estudo.

1.4. Organização dos Capítulos

No presente trabalho, a organização dos capítulos se encontra da seguinte forma:

- a) Capítulo 1 – neste capítulo foram relatadas as importâncias de se estudarem os mais diversos modelos chuva-deflúvio, sobretudo de se testarem novas metodologias baseadas em modelos não paramétricos, caso das redes neurais artificiais;
- b) Capítulo 2 – neste capítulo são apresentadas as abordagens teóricas levantadas em documentos sobre os modelos hidrológicos convencionais, sobretudo acerca das redes neurais artificiais;
- c) Capítulo 3 – neste capítulo são comentadas as características inerentes à região estudada neste trabalho.
- d) Capítulo 4 – neste capítulo são apresentados os resultados relativos à aplicação dos modelos estudados no presente trabalho, bem como explicações sobre as causas que levaram aos mesmos;
- e) Capítulo 5 – são apresentadas as conclusões e sugestões para pesquisas futuras.

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo serão abordados os conceitos relacionados aos modelos hidrológicos de transformação chuva-deflúvio tradicionalmente utilizados nas regiões do semi-árido nordestino, bem como aqueles concernentes às redes neurais artificiais, sua analogia biológica e, sobretudo, as relações matemáticas inerentes à ativação dos neurônios artificiais e aos processos de aprendizagem.

2.1. Modelos Hidrológicos

Os modelos hidrológicos do tipo chuva-vazão, segundo Tucci (2005), visam à representação do ciclo hidrológico entre a precipitação e a vazão. Tais modelos buscam, portanto, a descrição espacial das precipitações, as perdas por interceptação, evaporação, o fluxo através do solo pela infiltração, percolação e água subterrânea, escoamento superficial, subsuperficial e no rio.

Modelos com estas características foram desenvolvidos com vistas à necessidade de serem obtidas séries mais longas de vazões, uma vez que as séries de precipitações apresentam, em geral, maior quantidade de dados disponíveis. Além disto, os modelos chuva-vazão objetivam estimar as vazões com base em novos panoramas previstos para a bacia hidrográfica em estudo.

Com relação à forma de considerar as variáveis inerentes ao espaço da bacia hidrográfica, os modelos podem ser classificados como distribuídos ou concentrados. Os modelos concentrados, em sua maioria, apresentam uma formulação simples de ser resolvida – ou calibrada – além de considerar a chuva distribuída uniformemente na bacia hidrográfica.

Segundo Tucci (1986), os modelos hidrológicos distribuídos são aqueles cujas variáveis e parâmetros dependem não somente do tempo, mas também do espaço. Em suma, estes modelos buscam ao máximo integrar em seu equacionamento as variações espaciais de suas variáveis de entrada, principalmente as precipitações.

O advento das técnicas de Sistemas de Informações Geográficas (SIG) vem se tornando ferramenta indispensável à aplicação e estudo dos modelos distribuídos, sobretudo por possibilitarem o mapeamento das variáveis de entrada em conjunto com os procedimentos necessários à sua distribuição espacial.

Tucci (2005) descreve um modelo hidrológico distribuído de transformação chuva-vazão denominado TOPMODEL, o qual simula os fluxos hidrológicos (fluxo de infiltração, fluxo de saturação, fluxo sub-superficial, evapotranspiração) na bacia hidrográfica. Este modelo explicita as interações entre águas subterrâneas e águas superficiais, prevendo o movimento da água, o qual determina onde a zona saturada se desenvolve de forma a produzir fluxo de saturação.

A calibração de modelos hidrológicos se trata da determinação dos parâmetros do modelo então estudado mediante a otimização de uma função objetivo, a qual é calculada comparando-se os resultados calculados com aqueles obtidos através dos registros observados.

Estas técnicas têm sido aprimoradas, de forma que atualmente podem ser citados vários modelos que buscam abordagens multi-objetivas para a representação do fenômeno, dentre elas a Multi-Objective Honey-Bee Mating Optimization, proposta por Barros *et al* (2007).

2.2. O Modelo SMAP Diário

O modelo SMAP é um modelo determinístico de simulação hidrológica do tipo transformação chuva-vazão, desenvolvido em 1981 por Lopes J.E.G.; Braga B.P.F. Conejo J.G.L e publicado pela *Water Resources Publications* (1982).

O desenvolvimento do modelo se baseou na experiência com a aplicação do modelo *Stanford Watershed IV* (Valença, 2005) e tem sua estrutura baseada em seis parâmetros os quais possuem uma interpretação física, possibilitando assim uma possível determinação a partir de informações físicas ou ambientais da bacia hidrográfica em estudo (Barros, 2007). São eles:

- a) Capacidade de saturação do solo (SAT), em mm;
- b) Parâmetro de recarga subterrânea (CREC), em %;
- c) Abstração inicial (AI), em mm;
- d) Capacidade de campo (CAPC), em %;
- e) Constante de recessão do escoamento superficial (K2t), em dias;

f) Constante de recessão do escoamento básico (Kkt), em dias.

O modelo SMAP se baseia no balanço de umidade do solo, no qual três reservatórios lineares fictícios representam a superfície, o solo e o aquífero, como apresentado na Figura 2.1 (Barros, 2007).

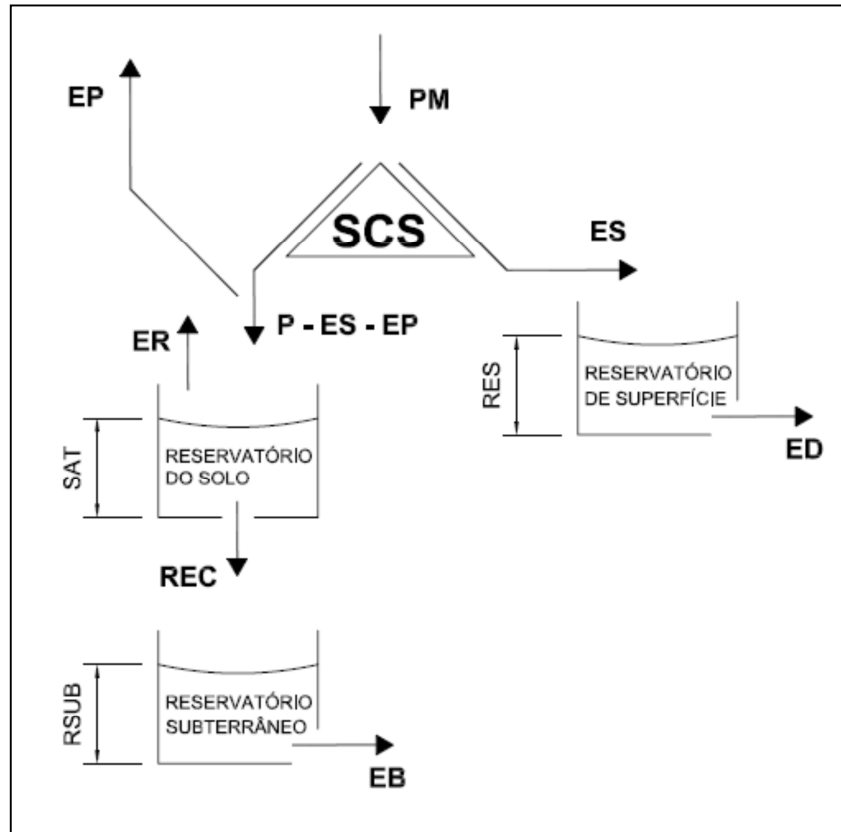


Figura 2.1 - Ilustração do Modelo SMAP (Lopes *et al*, 1981).

O escoamento superficial, calculado com base na precipitação média na bacia hidrográfica, é determinada segundo a Equação (1) do *Soil Conservation Service* (SCS):

$$ES = \frac{(PM - AI)^2}{P - AI + S} \quad (1)$$

Em que:

ES: escoamento Superficial;

PM: precipitação média diária sobre a bacia hidrográfica;

AI: abstração inicial;

S: quantidade máxima de armazenamento no solo.

A abstração potencial, ou capacidade máxima de armazenamento no solo, é determinada pela Equação (2):

$$S = SAT - RSOLO \quad (2)$$

Em que:

SAT: capacidade de saturação do solo (mm);

RSOLO: reservatório do solo (zona aerada).

O próximo passo é a determinação de do escoamento direto (ED), resultado da redução gradativa sofrida pelo nível do reservatório de superfície (RES) a uma taxa constante (K2). A Equação (3) apresenta o cálculo do escoamento direto supracitado.

$$ED = RES. (1 - K2) \quad (3)$$

A taxa de decremento (K2) do nível do reservatório de superfície (RES) é calculado pela Equação (4).

$$K2 = 0,5 \left(\frac{1}{k2t} \right) \quad (4)$$

Em que:

k2t: parâmetro que representa a constante de recessão do escoamento superficial (dias).

Da fração restante da precipitação (P-ES) é retirada a evaporação potencial (EP), e o restante é adicionado ao reservatório do solo que tem seu nível (RSOLO) decrementado devido a perdas por evapotranspiração real (ER), segundo a expressão:

$$ER = EP. TU \quad (5)$$

Em que:

TU: é o teor de umidade inicial do solo;

O teor de umidade do solo é expresso pela Equação (6).

$$TU = \frac{RSOLO}{SAT} \quad (6)$$

Outra saída desse reservatório é dada pela transferência para o reservatório subterrâneo, ou seja, a recarga (REC), que ocorre quando RSOLO é maior que a quantidade retida por capilaridade (CAPC x SAT), segundo a expressão:

$$REC = [RSOLO - (CAPC.SAT)].TU.CREC \quad (7)$$

Em que:

CREC: coeficiente de recarga;

O nível do reservatório subterrâneo (RSUB) recebe um incremento resultante da transferência originada reservatório superficial do solo. Entretanto, este nível sofre o decremento pelo escoamento subterrâneo, ou básico a uma taxa constante (K1). A Equação (8) apresenta a formulação para o cálculo do escoamento de base (EB).

$$EB = RSUB \times (1 - K1) \quad (8)$$

O cálculo da taxa do decremento (K1) sofrido pelo nível do reservatório subterrâneo é realizado mediante utilização da Equação (9).

$$K2 = 0,5 \left(\frac{1}{Kkt} \right) \quad (9)$$

Em que:

Kkt: parâmetro que representa a constante de recessão do escoamento básico (dias).

A saída do modelo, ou seja, a vazão gerada é a soma das vazões direta e básica, como mostra a Equação (10):

$$Q = (EB + ED) \times \text{ÁREA} / 86,4 \quad (10)$$

Em que:

Q : vazão em m³/s

ÁREA: representa a área da bacia em km².

2.3. O Modelo Hymod (*Hydrological Model*)

O modelo Hymod é baseado no trabalho publicado por Moore, R. J. (1985). Este modelo utiliza, *a priori*, as distribuições de probabilidade da variação espacial dos parâmetros, com base em características do processo de geração de vazão em pontos dentro da bacia. O segundo passo consiste em derivar equações algébricas para a integração da vazão (Bos e Vreng, 2006).

Trata-se de um modelo provido de 5 (cinco) parâmetros a serem calibrados, sendo estes:

- a) Capacidade máxima de armazenamento da bacia hidrográfica (C_{max});
- b) Grau de variabilidade espacial da capacidade de umidade do solo (B);
- c) Fator de distribuição do fluxo entre as duas séries de reservatórios (α);
- d) Tempo de residência dos reservatórios lineares rápidos (RQ);
- e) O tempo de residência do reservatório linear lento.

Conceitualmente, a bacia hidrográfica consiste de um conjunto de pontos discretos, os quais não interagem entre si, de forma que cada ponto discreto apresenta determinada capacidade de acúmulo de água, gerando escoamento quando este é excedido. A Figura 2.2 ilustra a idéia da bacia hidrográfica discretizada em pontos que geram escoamento.




Figura 2.2 - Representação da bacia hidrográfica no modelo HYMOD (Bos & Vreng *apud* Barros, 2007).

A função de distribuição das capacidades dos diferentes pontos da bacia é definida pela Equação (11):

$$F(C) = 1 - \left(\frac{C}{C_{max}} \right)^B \quad (11)$$

Em que:

F : representa a probabilidade acumulada da capacidade de água armazenada em um dado ponto;

C_{max} : maior capacidade de armazenamento dentro da bacia;

B : grau de variabilidade na capacidade de armazenamento.

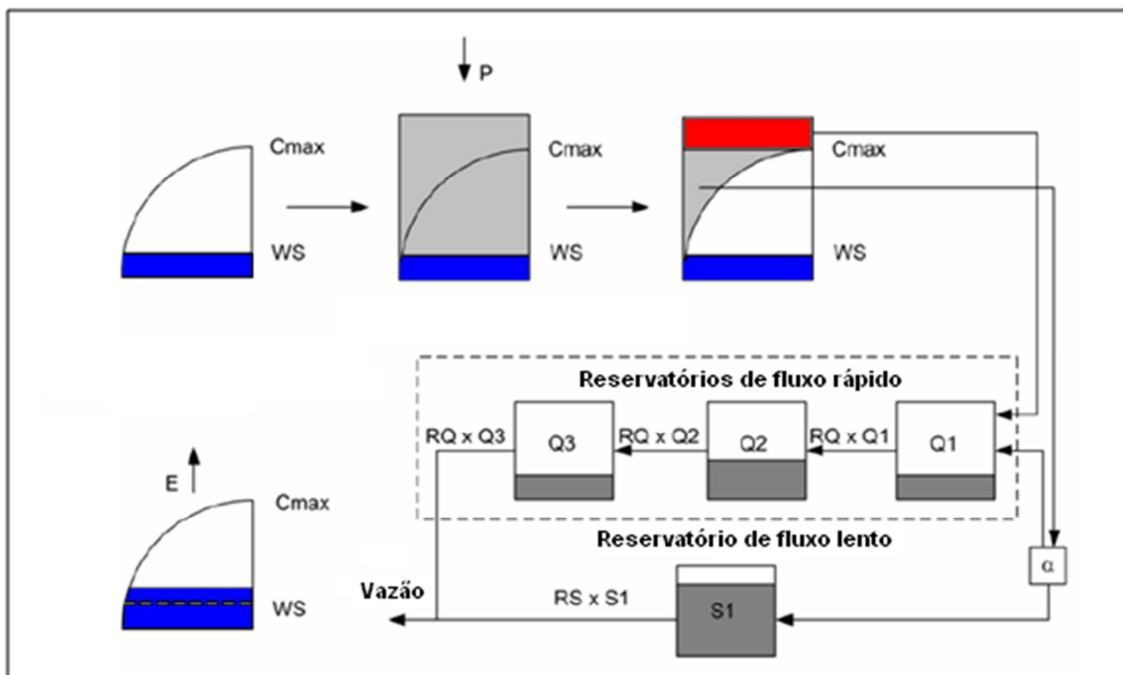


Figura 2.3 - Representação do modelo HYMOD (Bos & Vreng, 2006).

A parcela a qual excede a capacidade máxima de armazenamento da bacia hidrográfica (C_{max}) não se infiltra e segue para os 3 (três) tanques denominados de “tanques de fluxo rápido”. Esta transferência é regida pelo tempo de residência dos reservatórios lineares rápidos. A parcela restante da precipitação, a qual ultrapassa a capacidade dos pontos em que a capacidade é menor que C_{max} , se divide entre os tanques de fluxo rápido e de fluxo lento, determinado por um fator Alfa. A vazão de saída do modelo é o resultado da soma das vazões do terceiro tanque da série de tanques de fluxo rápido e do tanque de fluxo lento (Barros, 2007).

A evaporação é subtraída da água que permanece armazenada na bacia. Assim, caso quantidade de água disponível em armazenamento seja maior que a evaporação potencial, a evaporação real será igual à evaporação potencial, caso contrário, toda a água disponível será evaporada (Bos & Vreng *apud* Barros, 2007).

2.4. Redes Neurais Artificiais

2.4.1. Generalidades

O desenvolvimento das redes neurais artificiais foi motivado pela grande capacidade do cérebro humano aprender e realizar tarefas extremamente complexas após passar por algum processo de aprendizagem. O cérebro humano, principal unidade do sistema nervoso central, é um sistema de processamento de informações altamente

complexo, não-linear e paralelo formado por um conjunto de unidades fundamentais, os neurônios, organizadas de tal forma a realizar certos processamentos muito mais rápidos que qualquer computador digital atualmente conhecido. O neurônio biológico é formado basicamente por três partes distintas, conforme ilustrado na Figura 2.1, o corpo celular (soma), o axônio, e os dendritos.




Figura 2.4 - Neurônio Biológico

O corpo celular é o responsável pelo processamento das informações que chegam ao neurônio na forma de pulsos elétricos e pela produção da resposta a estes estímulos externos, também como um pulso elétrico. Os dendritos são as estruturas do neurônio responsáveis pelo recebimento dos pulsos elétricos e o axônio é o responsável pela emissão do pulso elétrico produzido pelo neurônio às demais células nervosas com as quais este encontra-se conectado.

A transmissão das informações entre os neurônios constituintes do cérebro humano se dá pelas sinapses, que são regiões eletroquimicamente ativas compreendidas entre duas membranas, as pré-sinápticas (axônio) e as pós-sinápticas (dendritos) de neurônios adjacentes.

As sinapses são as principais estruturas do cérebro humano responsáveis pela armazenagem das informações modificadas de acordo com o processo de aprendizagem ao qual o cérebro foi submetido. Qualquer alteração sobre o conhecimento de um determinado fenômeno já aprendido pelo cérebro só será possível pela alteração das sinapses estabelecidas entre os neurônios biológicos.

A Figura 2.5 ilustra o funcionamento do neurônio biológico e o mecanismo responsável pela produção de um novo pulso elétrico que é a resposta do neurônio aos estímulos transmitidos pelas sinapses. O corpo celular em um estado de equilíbrio, ou seja, sem que ocorra qualquer forma de excitação, encontra-se com um potencial elétrico de repouso, conhecido como potencial de repouso da membrana.

Os estímulos que chegam de outras células e são transmitidos via sinapses para os dendritos do neurônio (Entradas A, B, C, D, E, e F) fazem com que haja uma alteração do potencial de repouso da membrana do corpo celular. De acordo com a característica da sinapse em questão (excitatória ou inibitória) este potencial da membrana pode aumentar ou diminuir, tendo influência direta sobre a atividade do corpo celular.

Quando a contribuição de todos os estímulos que chegam ao neurônio, em intervalos de tempo diferentes, atinge um determinado limiar, se dá então a produção do pulso elétrico, que se propaga pelo axônio até as células nervosas seguintes da rede neuronal (Kovács, 2001).

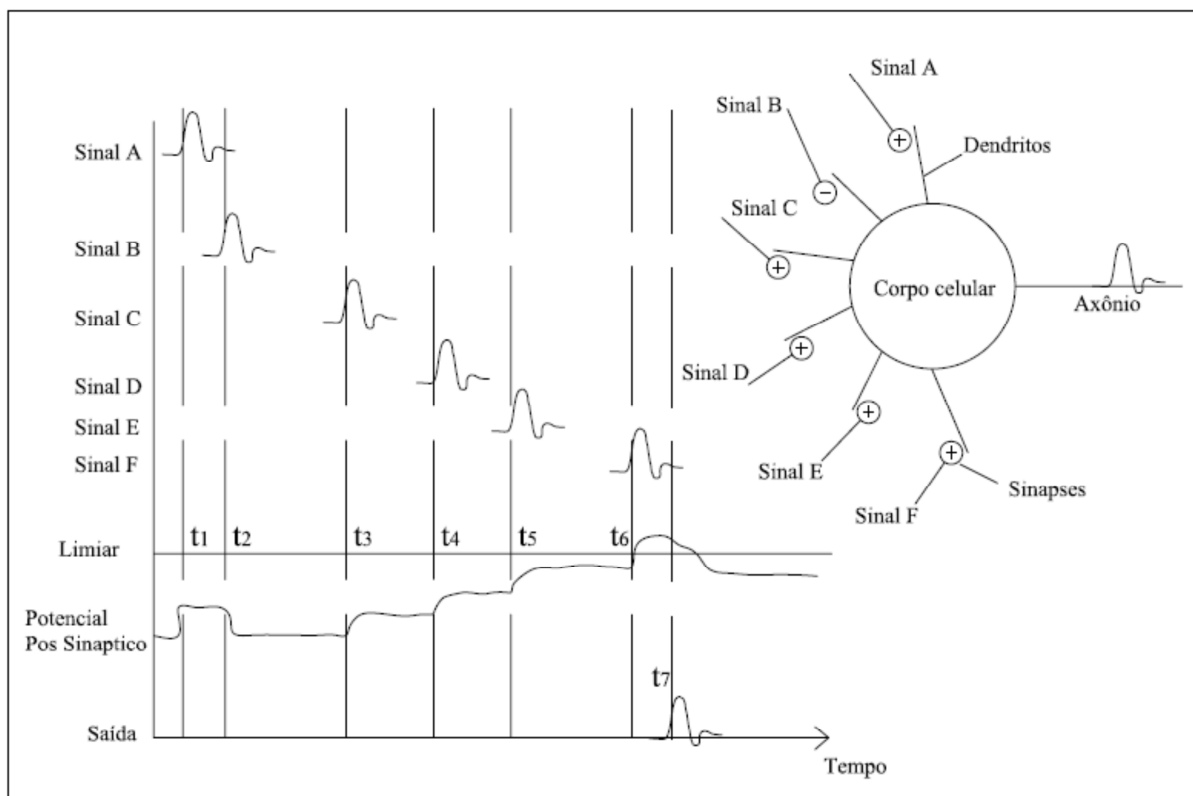


Figura 2.5 - Representação esquemática da integração espacial temporal dos estímulos por um neurônio (Kovács, 2002).

Portanto, com o conhecimento sobre os mecanismos básicos de funcionamento do cérebro humano, como descrito anteriormente, tornaram-se possíveis os primeiros

estudos acerca das redes neurais artificiais, os quais ocorreram no período entre 1943 e 1958 com a publicação dos trabalhos de McCulloch-Pitts, Hebb, e Rosenblatt (Haykin, 2001).

De acordo com Haykin (2001), o trabalho de McCulloch and Pitts in 1943 se apresenta como referência inicial para o desenvolvimento das redes neurais artificiais. Estes desenvolveram elementos computacionais baseados nas propriedades fisiológicas de um neurônio biológico. No entanto, o modelo provia de limitações, de forma a serem aptos a simular somente funções booleanas, cujas entradas fossem números binários definidos em um espaço linearmente separável e os pesos sinápticos eram determinados por processos de tentativa e erro.

A publicação do livro intitulado *“The Organization of Behavior”* escrito por Hebb em 1949 foi o próximo importante avanço para o desenvolvimento das redes neurais artificiais. Neste trabalho, Hebb apresentou o primeiro algoritmo para aprendizagem de um neurônio biológico através de mudanças nos pesos sinápticos, considerando que as conexões do cérebro são continuamente modificadas enquanto o indivíduo realiza diferentes tarefas e que novos grupos de neurônios são criados em função destas modificações (Haykin, 2001).

O próximo passo importante no desenvolvimento dos conhecimentos acerca do aprendizado de um neurônio artificial foi dado por Rosenblatt em 1958, com a proposta de uma rede neural conhecida como perceptron. Este modelo é a forma mais simples de rede neural utilizada como classificador linear, sendo constituído por um único neurônio não-linear com ajustáveis pesos sinápticos e limiar. A vantagem do perceptron em relação ao modelo de McCulloch e Pitts foi o fato de estabelecer uma regra de aprendizado, cuja convergência foi demonstrada por Rosenblatt, conhecida como regra de aprendizagem do perceptron.

O trabalho de Widrow e Hoff deve ser mencionado como um importante avanço para as redes neurais artificiais. Estes atores desenvolveram um modelo linear chamado ADALINE (*Adaptive Linear Element*), o qual foi generalizado para múltiplas camadas e conhecido como MADALINE (*Multiple ADALINE*). A principal contribuição deste modelo foi estabelecer os princípios para o treinamento eficiente de redes ADALINE, o algoritmo LMS (*Least Mean Square*), também conhecido como regra delta, a qual foi generalizada para o treinamento de perceptron multicamadas e conhecido como Regra Delta Generalizada ou Algoritmo de Retro Propagação.

2.4.2. As Redes Neurais Artificiais: Perceptron

As redes neurais artificiais podem ser entendidas como uma técnica computacional de modelagem não-paramétrica. Apesar de processos estatísticos usuais, as redes neurais não envolvem um conjunto de coeficientes ou parâmetros. Assim, do ponto de vista matemático, as redes neurais artificiais se apresentam como um conjunto de nós organizados em sucessivas camadas, de forma similar ao cérebro humano.

A Figura 2.6 apresenta uma rede neural multicamadas alimentada adiante, também conhecida como perceptron multicamada, constituída de três tipos de camadas: a camada de entrada, cuja função é receber as informações (x_1, x_2, \dots, x_n); uma camada oculta, responsável pelo aumento da capacidade das redes neurais artificiais em simular o comportamento de fenômenos complexos através de dados disponíveis usados no processo de treinamento; e a camada de saída, cuja função é fornecer as respostas (y_1, y_2, \dots, y_k) às correspondentes entradas introduzidas no modelo. A configuração mostrada na Figura 2.3 é também conhecida como arquitetura de rede.

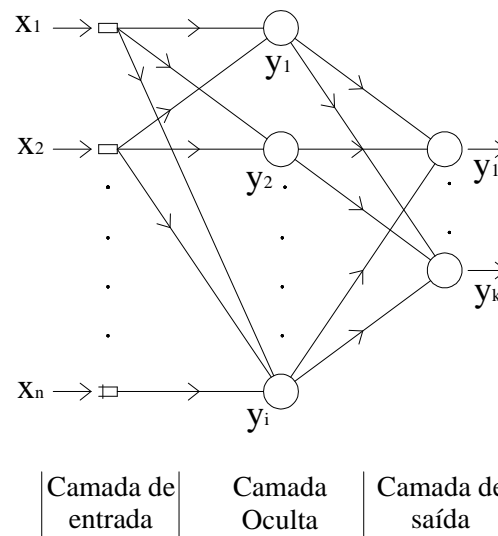


Figura 2.6 – Exemplo de arquitetura de rede.

Em uma rede neural alimentada adiante a informação é repassada em um único sentido, da camada de entrada para a camada de saída através das camadas ocultas. O valor de cada nó é computado em função de todas as respostas produzidas nos neurônios da camada anterior e dos pesos sinápticos correspondentes. A Equação (12) representa a resposta produzida em um neurônio artificial:

$$y_i = \varphi(v_i) = \varphi\left(\sum_{l=0}^n \omega_{i,l} \cdot x_l\right), \text{ or } y_i = \varphi\left(\sum_{l=1}^n \omega_{i,l} \cdot x_l + b_i\right) \quad (12)$$

Em que:

y_i : resposta do neurônio i ;

x_i : valor do nó da camada de entrada;

b_i : limiar, ou bias;

$\omega_{i,l}$: pesos sinápticos;

$\varphi(\cdot)$: função de ativação do neurônio.

Há vários tipos de funções utilizadas para a ativação dos neurônios, sendo a função sigmóide e a tangente hiperbólica as mais usadas (Haykin, 2001). Os valores dos nós de saída podem ser computados da mesma forma apresentada pela Equação (12), considerando como entradas os valores calculados nos nós das camadas ocultas.

2.4.3. Aprendizagem das Redes Neurais Artificiais

Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados por meio de um estímulo contínuo do ambiente no qual a rede está operando, ou seja, este processo corresponde ao ajuste dos pesos sinápticos. Desta forma, faz-se necessário entrada no modelo com um conjunto de dados confiáveis. Este conjunto de

dados de entrada, ou conjunto de dados de

$$\Psi = \left\{ x_{1,l}, x_{2,l}, \dots, x_{n,l}, y_{1,l}, y_{2,l}, \dots, y_{d,l} \right\}_{l=1}^L \quad \text{treinamento, é definido na}$$

Equação (13):

(13)

Em que:

Ψ : conjunto de dados de treinamento para a modelagem de um neurônio artificial;

L : número de entradas e saídas conhecidas no conjunto de entradas;

$x_{1,l}, x_{2,l}, \dots, x_{n,l}$: l -exemplos da camadas de entrada apresentados ao neurônio artificial;
 $y_{1,l}, y_{2,l}, \dots, y_{d,l}$: valores alvos para os l -exemplos apresentados na camada de entrada.

O tipo específico de aprendizagem é definido pela maneira como ocorrem os ajustes realizados nos parâmetros livres da rede, ou seja, nos pesos sinápticos e bias (Haykin *apud* Santos, 2001). Esta é a etapa mais importante na modelagem, a qual dispõe de duas fases: o treinamento, que visa à apresentação de exemplos à rede a fim de que esta aprenda o ambiente na qual se encontre; e a validação, que consiste na verificação da capacidade de generalização do modelo.

Em 1960, Widrow e Hoff desenvolveram um método para o ajuste dos pesos sinápticos e bias de um neurônio linear. Este é um processo baseado na aprendizagem por correção do erro, a qual parte do princípio de que o ajuste dos pesos sinápticos é função dos sinais de erro calculados como a diferença entre a saída desejada para o neurônio quando estimulado por um dado padrão de entrada e a saída calculada pelo neurônio como resposta aos estímulos dados (dados de entrada). A Figura 2.4 ilustra esquematicamente o processo de aprendizagem por correção do erro.




Figura 2.7 - Representação esquemática do processo de aprendizagem por correção do erro (Haykin, 2001).

O processo de aprendizagem por correção de erro é iniciado quando um sinal de erro $e_k(n)$ aciona um mecanismo de controle, processando, assim, uma seqüência de ajustes corretivos aos pesos sinápticos do neurônio, aproximando gradativamente o sinal de saída $y_k(n)$ da saída desejada $d_k(n)$. Este objetivo é alcançado minimizando-se uma função de custo ou índice de desempenho, $E(n)$, definido em termos do sinal de erro $e_k(n)$ como:

$$E(n) = \frac{1}{2} \cdot e_k^2(n) \quad (14)$$

Em que:

$E(n)$: função de custo;

$e_k(n)$: sinal de erro, determinado pela Equação (15);

$$e_k(n) = d_k(n) - y_k(n) \quad (15)$$

Em que:

$d_k(n)$: saída desejada;

$y_k(n)$: sinal de saída;

n : n-ésimo padrão existente no conjunto de treinamento.

Sendo a resposta do neurônio neste caso calculada como:

$$y_k(n) = \omega^T(n) \cdot x(n) \quad (16)$$

Em que:

$\omega(n)$: vetor de pesos sinápticos;

$x(n)$: vetor de dados de entrada;

Uma vez que, de acordo com a Equação (14), a função de custo é dependente dos pesos sinápticos do modelo neuronal, o modelo de Widrow propõe que o ajuste destes parâmetros seja feito a partir da minimização da função de custo. Neste caso, parte-se de uma configuração inicial arbitrária para os pesos sinápticos, e através de ajustes sucessivos aplicados aos mesmos converge-se em direção ao ponto de mínimo local da função de custo que pode ser representada de acordo com a Figura 2.8.




Figura 2.8 - Representação da superfície de erros ($E(w)$), pertencendo w_1 e w_2 ao \mathbb{R}^2 .

Neste caso, o ajuste dos pesos sinápticos é feito de forma iterativa empregando-se a seguinte expressão:

$$\omega(n+1) = \omega(n) - \eta \nabla [E(n)] \quad (17)$$

Em que:

$\omega(n+1)$: vetor de pesos sinápticos na iteração (n+1);

$\omega(n)$: vetor de pesos sinápticos na iteração (n);

\mathbf{V} : vetor gradiente;

η : taxa de aprendizagem.

O gradiente da função de custo pode ser calculado como:

$$\vec{\nabla} E(n) = \frac{\partial E(n)}{\partial e_k(n)} \cdot \frac{\partial e_k(n)}{\partial y_k(n)} \cdot \frac{\partial y_k(n)}{\partial \omega(n)} = -e_k(n) \cdot \mathbf{x}(n) \quad (18)$$

Neste caso o ajuste dos pesos sinápticos é realizado pela seguinte expressão:

$$\omega(n+1) = \omega(n) + \eta e_k(n) \cdot \mathbf{x}(n) \quad (19)$$

A Equação acima mostra que o ajuste dos pesos sinápticos é função dos sinais de erro produzidos e do vetor de entrada. Convém salientar ainda que a convergência do processo de aprendizagem, ou seja, de ajuste dos pesos sinápticos tem grande influência da taxa de aprendizagem adotada.

Segundo Santos (2003), as redes neurais alimentadas adiante (perceptrons) treinadas pelo algoritmo da retropropagação do erro (*backpropagation*) operam como uma variação da regra delta, denominada de regra delta generalizada. Este algoritmo visa à minimização do erro obtido pela rede por um processo semelhante ao descrito anteriormente, aplicando, então, uma função de ativação ao adaptador linear, de forma a ampliar o poder de otimização do processo de aprendizagem descrito por Widrow e Hoff.

O Algoritmo de Retro-propagação do Erro apresenta, paulatinamente, dois passos: um adiante (Figura 2.9), quando a rede é alimentada com os dados de entrada e as respostas dos neurônios da camada de saída são calculadas, com os respectivos sinais de erro; e um passo para trás (Figura 2.10), quando os sinais de erro produzidos, são retro-propagados desde a camada de saída até a camada de entrada alterando-se todos os pesos sinápticos entre camadas de neurônios.




Figura 2.9 - Estímulo dado pelos sinais de entrada e cálculo de todos os neurônios das camadas ocultas até as de saída.




Figura 2.10 - Passo para trás, ilustrando produção do sinal de erro, o qual é retro propagado para correção dos pesos sinápticos.

Para o perceptron multicamadas, o erro quadrático instantâneo é calculado a partir do somatório dos erros quadráticos de todos os neurônios da camada de saída, conforme Equação (20) (Haykin, 2001):

$$E(n) = \frac{1}{2} \cdot \sum_{j \in C} e_j^2(n) \quad (20)$$

No estabelecimento do processo de ajuste dos pesos sinápticos das redes neurais multicamadas duas situações devem ser consideradas: quando o neurônio pertence à camada de saída; e quando o neurônio pertence a uma camada oculta.

Na primeira situação, ou seja, quando o neurônio pertence à camada de saída (Figura 2.11), a regra de ajuste dos pesos sinápticos é semelhante àquela apresentada na Equação (19), uma vez que os sinais de erro de todos os neurônios da camada de saída são conhecidos. Portanto, pode-se estabelecer a função de custo correspondente.




Figura 2.11 - Neurônio pertencente à camada de saída.

Nota-se que o neurônio j recebe como sinal de entrada o resultado y_i relativo ao neurônio i da camada anterior. A Equação (12), portanto, deve ser representada na forma da Equação (21):

$$v_j(n) = \sum_{i=0}^m \omega_{ji}(n) y_i(n) \quad (21)$$

Na Equação (21) o termo m representa o número de entradas aplicadas ao neurônio j . Ao campo local induzido $v_j(n)$, produzido no neurônio j , aplica-se então a função de ativação relativa ao neurônio j . Logo, o sinal de saída do neurônio j pode ser expresso pela Equação (22):

$$y_j(n) = \varphi(v_j(n)) \quad (22)$$

De forma análoga ao algoritmo descrito por *Widrow*, o algoritmo de retro propagação aplica uma correção $\Delta\omega_{ji}$ ao vetor de pesos sinápticos, a qual é proporcional à derivada parcial da função erro, expressa pela Equação (23), em relação aos pesos sinápticos ω_{ji} . Desta forma, aplicando-se a regra da cadeia:

$$\frac{\partial E(n)}{\partial \omega_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial \omega_{ji}(n)} \quad (23)$$

A qual resulta na Equação (24):

$$\frac{\partial E(n)}{\partial \omega_{ji}(n)} = -e_j(n)\varphi'(v_j(n))y_i(n) \quad (24)$$

A correção de pesos sinápticos é, finalmente, obtida pela aplicação da regra delta, resultando na Equação (25):

$$\Delta\omega_{ji} = -\eta e_j(n)\varphi'(v_j(n))y_i(n) \quad (25)$$

Simplifique a expressão acima, introduzindo o gradiente local.

em que,

$y_i(n)$: sinal de saída do neurônio i , que se liga ao neurônio j pela sinapse ω_{ji} ;

A dificuldade em se realizar o ajuste dos pesos sinápticos dos neurônios pertencentes às camadas ocultas se apresenta no cálculo do sinal de erro do neurônio, o qual se realiza recursivamente em função dos sinais de erro de todos os neurônios aos quais os neurônios das camadas ocultas estão diretamente conectados.

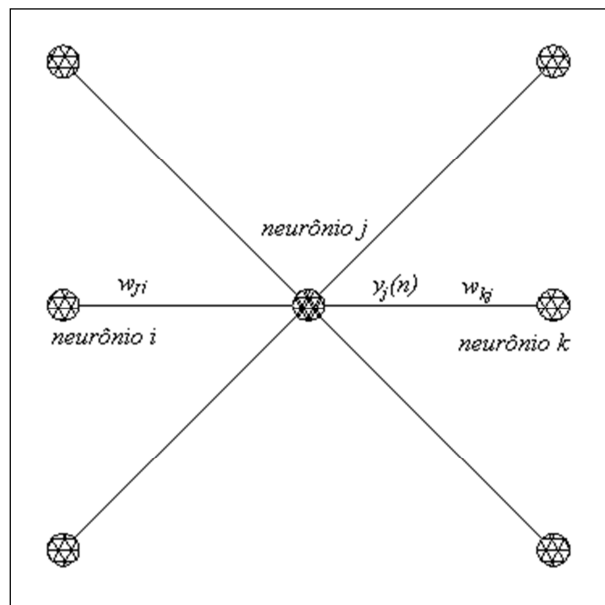


Figura 2.12 - Neurônio pertencente à camada intermediária.

Considerando-se, pois, na Figura 2.12 o caso do neurônio j , o qual se encontra diretamente ligado aos neurônios i e k , o gradiente local pode ser definido segundo a Equação (26).

$$\delta_j(n) = -\frac{\partial E(n)}{y_j(n)} \cdot \frac{\partial y_j(n)}{\partial v_j(n)} \quad (26)$$

A Equação (26) resulta na Equação (27):

$$\delta_j(n) = -\frac{\partial E(n)}{y_j(n)} \cdot \varphi_j'(v_j(n)) \quad (27)$$

O objetivo principal a partir do próximo passo é obter um meio de se determinar a derivada da função erro ($E(n)$) em relação ao sinal de saída do neurônio j ($y_j(n)$). Desta forma, considerando-se a Figura 2.12, sendo k um neurônio pertencente à camada de saída a Equação (20) se apresenta na forma da Equação (28).

$$E(n) = \frac{1}{2} \cdot \sum_{k \in C}^L e_k^2(n) \quad (28)$$

Diferenciando a Equação (28), tem-se como resultado a Equação (29).

$$\frac{\partial E(n)}{y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (29)$$

Pela regra da cadeia, calculando-se a derivada parcial do segundo termo da Equação (29), tem-se a Equação (30).

$$\frac{\partial E(n)}{y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \cdot \frac{\partial v_k(n)}{\partial y_j(n)} \quad (30)$$

Assim,

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi_k'(v_k(n)) \quad (31)$$

A Equação (12) pode ser então utilizada, no neurônio k , para se obter o campo local induzido, resultando na Equação (32).

$$v_k(n) = \sum_{j=0}^m \omega_{kj}(n) y_j(n) \quad (32)$$

Assim,

$$\frac{\partial v_k(n)}{y_j(n)} = \omega_{kj}(n) \quad (33)$$

Definido o gradiente local nos casos em que o neurônio se encontra na camada de saída ou nas camadas ocultas, os pesos sinápticos das novas iterações são corrigidos conforme apresentado na Equação (34).

$$\omega(n+1) = \omega(n) - \eta \cdot \delta_j(n) \cdot y_i(n) \quad (34)$$

2.4.4. Etapas de um processo de modelagem com as RNA

Segundo Galvão e Valença (1999), as etapas de uma modelagem mediante a utilização das RNA são similares aos modelos estatísticos e baseados em um processo iterativo, compreendendo as seguintes etapas: coleta dos dados, tratamento dos dados, treinamento da rede, validação da rede.

A coleta dos dados consiste da seleção dos dados de entrada, as quais correspondem aos valores os quais regem o fenômeno, consistindo na sua principal causa; e seleção dos dados de saída desejados, os quais descrevem o problema a ser modelado através das RNA. Esta etapa consiste da análise preliminar e identificação do modelo a ser estudado.

O tratamento dos dados é a etapa do processo de modelagem na qual os dados de entrada são adequados ao domínio da função de ativação escolhidas dos neurônios e os dados de saídas desejadas são ajustados à imagem desta função de ativação. Desta forma, este processo se constitui de uma simples interpolação dos dados de entrada e saída a fim de que estes se amoldem aos conjuntos domínio e imagem da função de ativação.

O treinamento da rede consiste da apresentação dos dados do problema à rede para que esta possa aprender o ambiente ao qual esta se encontra inserida. Esta etapa é realizada em concomitância com a escolha da melhor arquitetura de rede e função de

ativação dos neurônios, pois o seu monitoramento determina a escolha das melhores redes, a fim de se obterem os melhores resultados.

A definição da topologia da rede se trata de uma tarefa de difícil execução, pois depende de inúmeros fatores, dentre os quais estão aqueles intrínsecos ao fenômeno então modelado. Dentre estes fatores estão: a quantidade de exemplos para o treinamento, a complexidade do problema analisado, a relação entre a quantidade dos neurônios de entrada e saída (Galvão e Valença, 1999).

A validação é a etapa em que a configuração de rede então treinada é inserida em um espaço desconhecido, através da apresentação do conjunto de dados de validação. Trata-se da verificação da rede por meio da apresentação de dados de uma amostra representativa do fenômeno estudado. A qualidade da rede treinada é então atestada através de um índice indicativo, seja este o erro médio quadrático ou o índice de correlação.

Conclui-se, pois, que a modelagem mediante a utilização das RNA se trata de um procedimento realizado por tentativas e erros, constituindo-se de um processo empírico de escolha de melhores topologias de redes por meio de comparação concomitante e paulatina entre os resultados calculados pelo modelo e aqueles observados. Pode-se, portanto, aferir que não existe, até então, regra que determine quais as melhores arquiteturas de rede em função do problema a ser modelado.

2.4.5. Validação Cruzada

A validação cruzada é um método que faz hipótese mínima sobre as características estatísticas dos dados de forma que o desempenho da rede treinada seja avaliada para um conjunto de dados extraído do conjunto de exemplos de treinamento. A aplicação desta técnica consiste em calcular simultaneamente o erro médio quadrático para o conjunto de treinamento, após ser retirado o conjunto de validação, e para o conjunto de validação, de maneira que o treinamento seja parado quando o erro para o conjunto de validação começar a crescer indefinidamente (Viera *et al*, 1999).

Segundo Haykin (2001), quando o número de exemplos rotulados, N , for demasiado limitado, pode-se utilizar de uma variante da validação cruzada denominada método deixe um de fora. Neste caso $N - 1$ exemplos são utilizados para o treinamento do modelo e o modelo é validado testando-o sobre o exemplo deixado de fora. O

experimento é repetido para um total de N vezes, cada vez deixando de fora um exemplo um exemplo diferente para a validação.

2.5. Parâmetros de Desempenho

Parâmetros de desempenho, não somente no âmbito das modelagens hidrológicas, são índices os quais denotam a consistência do modelo então calibrado de forma a comparar os resultados calculados pelo modelo com os dados-alvos então fornecidos a este.

Os parâmetros de desempenho frequentemente apresentados na literatura se baseiam no somatório dos erros quadráticos, sugerido em análises com regressões lineares. Dentre estes parâmetros, a função proposta por Nash & Sutcliffe (1970) atingiu maior destaque. Esta função é o somatório dos erros quadráticos padronizada pela variância da série observada (Barros, 2007). Seu valor numérico representa a fração da variância da série observada explicada pelo modelo em termos de magnitude relativa da variância dos resíduos dos fluxos (Yapo et al. *apud* Barros, 1996). O valor 1,0 representa a solução ótima. A Equação (35) apresenta a formulação proposta por Nash & Sutcliffe (1970).

$$R = \frac{\sum_{i=1}^N (Q_i^{obs} - Q_i^{calc})^2}{\sum_{i=1}^N (Q_i^{obs} - \bar{Q}_i^{obs})^2} \quad (35)$$

Em que,

R : coeficiente de Nash;

Q_i^{obs} : vazões observadas;

Q_i^{calc} : vazões calculadas pelo modelo;

\bar{Q}_i^{obs} : média das vazões observadas.

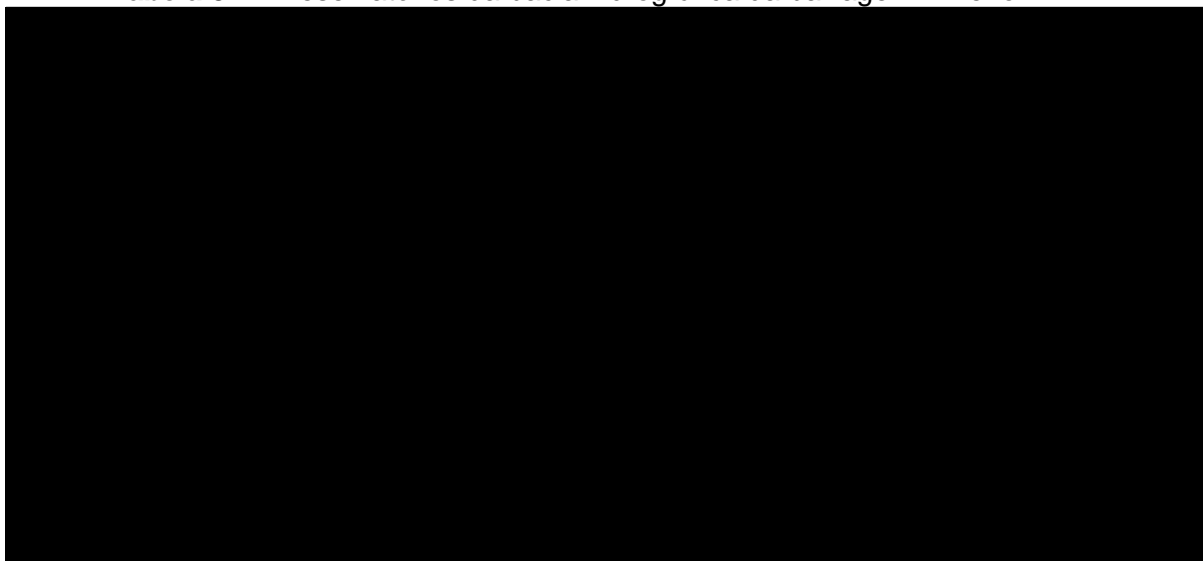
3. DESCRIÇÃO DA BACIA HIDROGRÁFICA E DOS DADOS HIDROLÓGICOS UTILIZADOS

3.1. Área de Estudo

A bacia hidrográfica cujo exutório corresponde ao posto fluviométrico Arneiroz, apresenta área superior a 5.300 km², englobando parte dos municípios de Arneiroz e Parambu, e compreendendo ainda a toda a extensão do território de Tauá, sendo seu limitante topográfico a fronteira deste município com as cidades de Mombaça, Independência e Quiterianópolis.

Quanto à hidrografia da região, o principal curso d'água natural responsável pela drenagem da bacia corresponde ao Alto Curso do Rio Jaguaribe. Este percorre uma extensão superior a 30,0 km desde suas cabeceiras até encontrar o ponto de exutório equivalente à estação fluviométrica de Arneiroz.

Tabela 3.1 - Reservatórios da bacia hidrográfica da barragem Arneiroz II.



A região hidrográfica do Alto Jaguaribe localiza-se a montante do açude Orós e drena uma área de 24.636 km². O Rio Jaguaribe, nessa região, possui uma extensão de 325 km e tem declividades que variam de 0,03% a 2,5%, sendo a declividade média de 0,06%. Apresenta como principais afluentes os rios: Bastiões, Trussu e Cariús (SRH, 2006).

Em termos de acumulação de águas superficiais, segundo dados da Secretaria de Recursos Hídricos (2006) a região do Jaguaribe apresenta uma capacidade monitorada

em 15 (quinze) reservatórios, da ordem de 2.544,98hm³ que regulariza uma vazão de cerca de 19,83m³/s. Apesar deste expressivo volume de acumulação de águas superficiais, a região é considerada deficitária pela quantidade de trechos de rios perenizados, dos quais os grandes reservatórios se situam no terço inferior da bacia.

Este exutório recebe as vazões regularizadas de outros sete reservatórios situados a montante: Trici, Favelas, Forquilha, Várzea do Boi, Espírito Santo, Parambu, Monte Són. A Tabela 3.1 apresenta informações sobre localização, capacidade de armazenamento e ano de construção dos reservatórios da bacia hidrográfica da barragem Arneiroz II.



Figura 3.1 - Fotografia aérea do Arneiroz II (SRH, 2005).

Inserir Mapa de Localização A4

Figura 3.2 - Mapa de Localização da Bacia Hidrográfica do Arneiroz II.

A bacia hidrográfica da barragem Arneiroz II conta com uma área superior à 5.400,0 km². Seu rio mais longo percorre cerca de 150,0 km desde região próxima à fronteira dos municípios de Pedra Branca e Independência, na cota topográfica aproximada 640,0 m, até a barragem, onde a cota mínima de sua foz estima-se nos 340,0 m. Com base nestes dados, afere-se que o tempo de concentração desta bacia excede as 34,0 h.

A bacia hidrográfica do Rio Jaguaribe, inclusive na região de Arneiroz, apresenta baixa expectativa quanto à presença de águas subterrâneas, haja vista estarem situadas – praticamente toda sua área – no embasamento cristalino, conforme se observa no mapa de unidades litológicas apresentado no mapa da Figura 3.3, cuja fonte são os dados fornecidos pela CPRM – Serviços Geológicos do Brasil.

O município de Arneiroz apresenta uma área de 941,9km² e está situado na microrregião do sertão dos Inhamuns tendo como limites ao norte, sul, leste e oeste, respectivamente, os municípios de Tauá, Aiuaba, Saboeiro e Parambu. O índice pluviométrico médio anual para a região é de 506,3mm, segundo dados da Secretaria de Recursos Hídricos (SRH, 2006).

Inserir Mapa Geológico.

3.2. Descrição dos Dados Hidrológicos Utilizados

Os dados de chuvas obtidos para o presente estudo pluviométrico da bacia hidrográfica da Barragem Arneiroz II, encontram-se disponíveis na no endereço eletrônico <http://www.ana.gov.br/portalsnirh/>. O mapa da Figura 3.2 apresenta os postos pluviométricos os quais forneceram os dados para a modelagem realizada neste trabalho, assim como a Tabela 3.2 lista suas coordenadas e código do respectivo posto pluviométrico.

A Agência Nacional de Águas (ANA) mantém um banco de dados constantemente atualizado, no qual se encontram catalogados os postos pluviométricos instalados em todo o território nacional, estejam eles em operação ou mesmo desativados. Fornece ainda, dentre outras informações, quais as entidades responsáveis pela manutenção e operação dos postos.

Além disso, a ANA dispõe as séries históricas observadas ao longo do tempo quando o monitoramento dos postos pluviométricos é de sua responsabilidade ou quando as entidades responsáveis pelo monitoramento repassam à ANA as séries observadas.

As séries utilizadas no presente trabalho compreendem sete anos entre 1965 e 1971. Apresentam sete postos pluviométricos e um posto fluviométrico. Estes correspondem aos anos os quais dispunham de dados diários sem falhas, tendo sido a maior sequência então encontrada para a maior quantidade de postos.

Tabela 3.2 - Informações dos postos pluviométricos.

Código	Posto Pluviométrico	Coordenadas	
		N	E
437006	Posto Jaguaruana	40 ^o 42'	6 ^o 13'
739038	Posto Jardim	40 ^o 16'	6 ^o 1'
739054	Posto Jati	40 ^o 8'	6 ^o 1'
639002	Posto Jucás	40 ^o 29'	6 ^o 9'
739007	Posto Missão Velha	40 ^o 17'	6 ^o 13'
640015	Posto Parambu	40 ^o 30'	6 ^o 25'
640002	Posto Tauá	39 ^o 54'	6 ^o 12'

3.3. Análise dos Dados Pluviométricos

O instrumento utilizado para medir as precipitações nos postos pluviométricos da área de estudo é do tipo Ville de Paris, padrão das entidades de monitoramento. Este pluviômetro destina-se à captação e acumulação de chuva para posterior medição com provetas graduadas e é o modelo de uso mais tradicional e generalizado do Brasil.

Com base nos registros de chuvas diárias fornecidas pela ANA é possível obter as estatísticas médias para as séries históricas dos postos pluviométricos. Tais estatísticas são compostas pelas precipitações médias, máximas e mínimas mensais e anuais registradas em cada estação pluviométrica, bem como pelo desvio-padrão e pelo coeficiente de variação obtidos da amostra. Dessa forma, a Tabela (A.1) do Apêndice A apresenta os valores estatísticos mensais e anuais para cada posto analisado, informando ainda, o número de dias médio de chuvas ocorridas.

Na região então estudada podem ser observados dois regimes pluviométricos distintos, a partir dos dados analisados. O primeiro, registrado nas estações pluviométricas Tauá e Parambu, caracteriza-se por um regime mais chuvoso, com totais médias anuais as quais superam os 1000 mm de pluviometria, sendo, portanto, acima da média do Estado do Ceará. O segundo, representado pelos demais postos, caracteriza-se por regime similar ao comumente observado no restante do Estado, com totais médias anuais as quais variam de 500 a 800 mm.

3.4. Análise dos Dados Fluviométricos

Os dados fluviométricos então utilizados para as modelagens utilizando as RNA e os modelos SMAP e HYMOD pertencem à estação fluviométrica de Arneiroz (36020000). Esta estação apresenta a maior série de dados de vazões observadas no Estado do Ceará, embora provida de falhas e de dados preenchidos estatisticamente, os quais impedem de serem utilizadas sequências extensas de dados, ao longo de vários anos.

Para a seleção dos dados fluviométricos foram então considerados os anos cujos dados medidos eram consistentes e integravam as sequências mais longas de anos encontrada, realizando-se as interseções entre as sequências de dados fluviométricos e as sequências de dados pluviométricos, não sendo trabalhados, pois, os anos os quais apresentavam falhas em pelo menos um dia de observação. Este procedimento reduziu substancialmente o conjunto de treinamento para entradas nos modelos então estudados.

Desta forma, foram selecionados os dados diários entre os anos de 1965 e 1971, cujos estudos estatísticos similares aos realizados no estudo pluviométrico encontram-se apresentados na Tabela (A.2) do Apêndice A. As Figuras (B.1) a (B.7) do Apêndice B apresentam as hidrógrafas relativas aos anos de 1965 a 1971 com base nos dados observados na estação de Arneiroz.

Com base na análise dos dados relativos à série observada, pode-se observar que o comportamento temporal das vazões mensais compreende dois períodos distintos, sendo um com maiores escoamentos, o qual se inicia em janeiro e se estende até maio. A partir de maio, as vazões escoadas superficialmente diminuem significativamente, caracterizando um segundo período, de estiagem, entre os meses de junho e dezembro. Este fato é explicado pelo período chuvoso da região, o qual apresenta comportamento semelhante.

Salienta-se que os regimes fluviométricos, caracterizados no presente estudo, relativos aos registros do posto Arneiroz, correspondem aos anos de 1965 a 1971. Assim, o único reservatório situado à montante da foz do Arneiroz a essa época o qual apresentava capacidade significativa no controle das vazões a montante seria o reservatório Várzea do Boi, com capacidade de acumulação superior a 50.000.000 m³.

4. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

4.1. Introdução

Neste capítulo serão apresentadas as análises realizadas utilizando-se dos modelos com as RNA, SMAP e HYMOD. Ressalte-se, pois, que os resultados foram obtidos através da técnica denominada validação cruzada (*crossvalidation*). Este procedimento é recomendável nos casos em que se dispõe de séries históricas curtas, situação esta observada nas séries históricas pluviométrica e fluviométrica utilizadas neste trabalho.

O processo de busca, além de permitir a variação da quantidade de neurônios e do número de camadas, possibilita a escolha da taxa de aprendizagem (η). Isto torna a modelagem bastante dependente do conhecimento do supervisor do processo de treinamento acerca de modelagens utilizando as RNA. Assim, foram inicialmente testadas as convergências de algumas taxas de aprendizagem, escolhendo-se em cada simulação aquela que apresentou a maior convergência.

Para a calibração do modelo SMAP, foram realizadas 22 simulações combinando a série destinada à calibração de forma que esta apresentasse 1, 2, 3 e 4 anos de dados observados de precipitações e vazões e respectivamente 6, 5, 4 e 3 anos de dados observados para a validação. Os dados de calibração combinaram ainda os anos dentro da série da forma apresentada na Figura 4.1.

Observa-se que não foi apresentada ao modelo, na fase de validação, uma série inferior a 3 (três) anos de dados observados. Este procedimento é justificado pelo fato de se ter utilizado uma série relativamente curta para esta modelagem. Assim, buscou-se a apresentação de uma série de dados capaz de representar ao máximo a sazonalidade do fenômeno precipitação-vazão.

Este procedimento foi realizado a fim de se buscar apresentar ao modelo, na fase de calibração os anos mais representativos, comparando-se, em cada uma das simulações os valores de Nash calculados para as fases de calibração e validação. Desta forma são determinados os parâmetros os quais fornecem o melhor ajuste do modelo SMAP à série apresentada.

Simulação	Ano						
	1965	1966	1967	1968	1969	1970	1971
1	■						
2		■					
3			■				
4				■			
5					■		
6						■	
7							■
8	■	■					
9		■	■				
10			■	■			
11				■	■		
12					■	■	
13						■	■
14	■	■	■				
15		■	■	■			
16			■	■	■		
17				■	■	■	
18					■	■	■
19	■	■	■	■			
20		■	■	■	■		
21			■			■	
22				■	■	■	■

■ Séries utilizadas para calibração

□ Séries utilizadas para validação

Figura 4.1 - Anos correspondentes às séries de dados pluviométricos e fluviométricos utilizados nas fases de calibração e validação dos modelos SMAP e HYMOD.

Por se tratar de um processo de busca de melhores resultados em um espaço muito amplo e desconhecido, foi gerada uma gama de resultados a qual tornaria a apresentação dos resultados obtidos demasiado longa. Desta forma, serão apresentados os melhores resultados obtidos em cada etapa do processo.

4.2. Descrição do Programa Q-Net

Para a obtenção dos modelos que representassem o fenômeno estudado foi utilizado o Q-Net, um perceptron multicamadas o qual realiza o treinamento da rede através da retro propagação do erro (algoritmo *backpropagation*), oferecendo ao usuário a possibilidade de definição da arquitetura de rede através de até oito camadas intermediárias e permitindo a escolha de quatro diferentes funções de ativação, dentre as quais estão as citadas neste trabalho.

O modo auto-treinamento do programa permite o treinamento de redes multicamadas de forma contínua e aberta. Esta é uma característica que possibilita a preservação ou um novo treino de um grande número de modelos. O referido modo dispõe de um histórico o qual guarda as redes selecionadas seqüencialmente treinadas para posterior processamento ou análise. Além disto, é informada a parcela de contribuição de cada neurônio de entrada, permitindo a decisão entre a utilização ou não dos neurônios com menor percentual de contribuição.

É necessário o fornecimento de dois parâmetros utilizados pelo algoritmo de aprendizagem para a adequação dos pesos sinápticos. São eles a taxa de aprendizagem (η) e o fator α (momentum). Ambos os parâmetros controlam a variação dos valores dos pesos sinápticos durante o treinamento da rede através do algoritmo de retropropagação.

4.3. Tratamento dos Dados de Treinamento e Validação

Os dados de entrada dos modelos apresentados no presente trabalho recebem tratamentos diferentes, de acordo com o modelo a ser utilizado. Esta é uma etapa importante, sobretudo no modelo o qual utiliza as RNA, uma vez que se necessita que o conjunto de dados de entrada esteja contido no conjunto imagem da função de ativação escolhida para os neurônios. A função de ativação então utilizada se trata da função sigmóide apresentada pela Equação (36).

$$f(x) = \frac{1}{1 + e^{-x}} \tag{36}$$

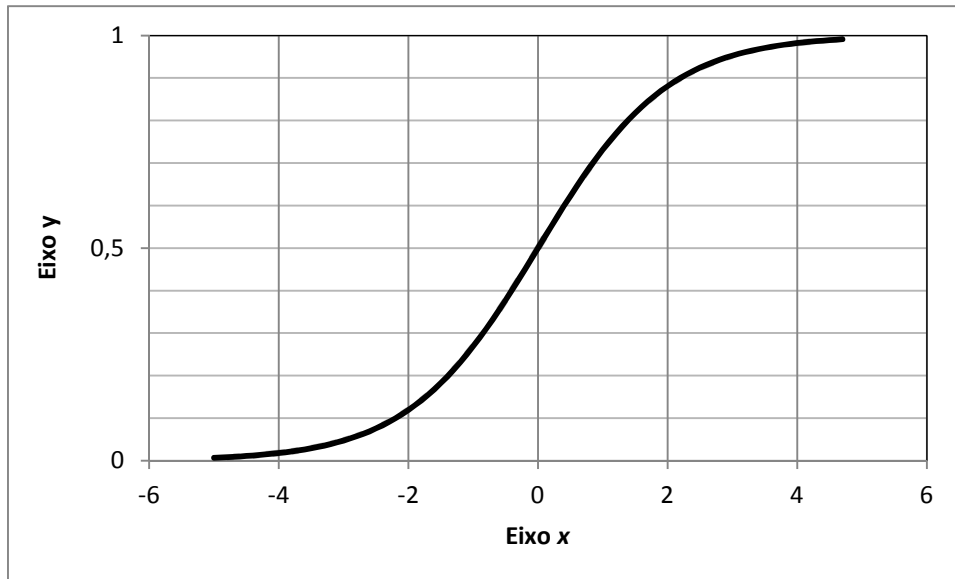


Figura 4.2 - Gráfico da função sigmóide.

A função sigmóide, com gráfico representado na Figura 4.2, é definida como uma função contínua e diferenciável, cujo conjunto imagem é o intervalo aberto]0; 1[. Desta forma, torna-se necessário que, no mínimo, o conjunto de validação seja normalizado a fim de que pertença ao referido intervalo aberto. É usual, para esta determinação, que se normalizem os dados de forma que estes pertençam ao intervalo fechado [0,1; 0,9] através da Equação (37).

$$y = (a - b) \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (37)$$

Em que:

y : valor normalizado;

x_i : dado original;

x_{max} : valor máximo do conjunto de dados originais;

x_{min} : valor mínimo do conjunto de dados originais;

a : limite máximo do conjunto de dados normalizados desejado;

b : limite mínimo do conjunto de dados normalizados desejado;

Salienta-se a importância de serem normalizados, também, os dados de entrada no intervalo compreendido entre 0 e 1, embora o domínio da função de ativação do tipo sigmóide seja o conjunto dos números reais. Isto se deve ao fato de o

gradiente da função logística para valores extremos serem próximos de zero, não sendo interessante para a representação do modelo.

4.4. Resultados Obtidos com as RNA

Os resultados apresentados neste item correspondem àqueles obtidos com a aplicação das RNA do tipo perceptron multicamadas através do programa *Q-Net*. As simulações realizadas, utilizando-se da arquitetura de rede a qual forneceu os maiores valores de Nash, correspondem àquelas mostradas na Figura 4.1.

Para a avaliação do desempenho do modelo foi utilizado o coeficiente de Nash & Sutcliffe (1970) apresentado no Capítulo 2. Contudo, o algoritmo utilizado para a realização do treinamento das RNA não inclui em sua formulação a maximização de uma função de correlação e sim a minimização da função do erro médio, a qual determina, conforme o algoritmo de retro propagação, a correção dos pesos sinápticos.

Desta forma, a busca de uma melhor representação do fenômeno então estudado através das RNA foi realizada de duas formas distintas. A primeira objetivou simular a representação da variação espacial dos dados de entrada (dados pluviométricos) considerando o valor da precipitação (em mm) medido em cada uma das 7 (sete) estações pluviométricas as quais forneceram os dados de entrada. Na segunda, assim comparando o tratamento dado aos valores de precipitação nos modelos concentrados SMAP e HYMOD, foram calculadas as precipitações médias através dos polígonos de Thiessen para que estas fossem fornecidas como entradas.

Em testes preliminares, as topologias que apresentavam mais de uma camada intermediária apresentavam desempenhos mais fracos. Para as simulações apresentadas na Figura 4.1, foi então utilizada a arquitetura de rede a qual apresenta 7 neurônios camada de entrada, 6 neurônios na camada intermediária única e 1 neurônio na camada de saída. A Tabela 4.1 apresenta as simulações e seus respectivos valores de Nash nas fases de treinamento e validação.

Tabela 4.1 - Valores dos coeficientes de Nash para treinamento e validação do modelo com as RNA.



Com os dados fornecidos pela Tabela 4.1 foi traçada a dispersão mostrada na Figura 4.3, a qual evidencia a correlação entre os coeficientes de Nash calculados nas fases de treinamento e validação do modelo utilizando as RNA.

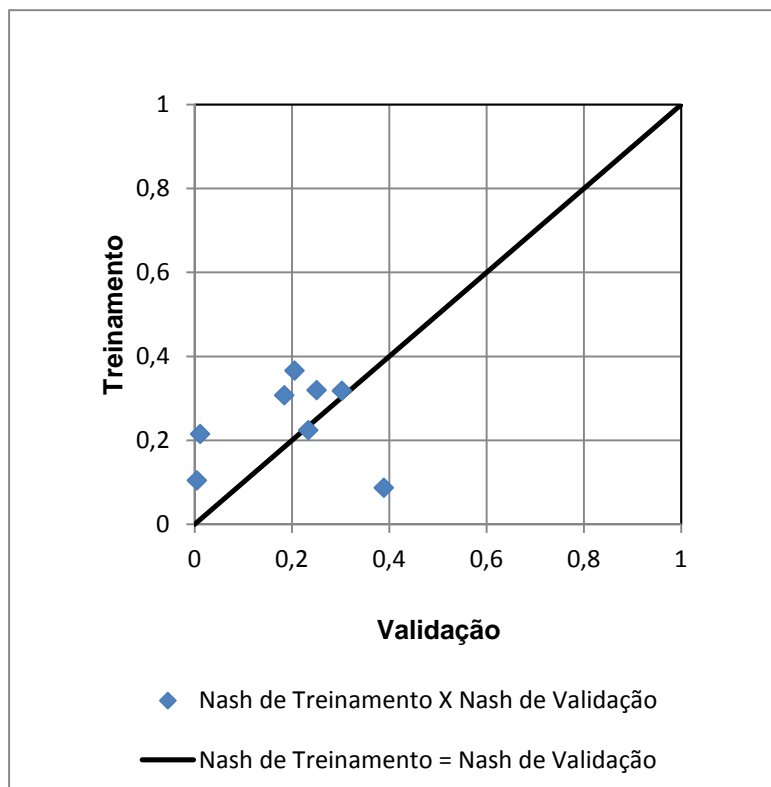


Figura 4.3 - Valores de coeficientes de Nash para as fases de treinamento e validação.

A arquitetura de rede 7-6-1, juntamente com a simulação 9, a qual forneceu os melhores resultados, ou seja, a qual apresentou maiores coeficientes de Nash nas fases de treinamento e validação concomitantemente, é representada na Figura 4.4. O treinamento desta arquitetura de rede foi realizado com 100.000 interações, taxa de aprendizagem inicial (η) igual a 0,0025 e *momentum* (\square) igual a 0,8.

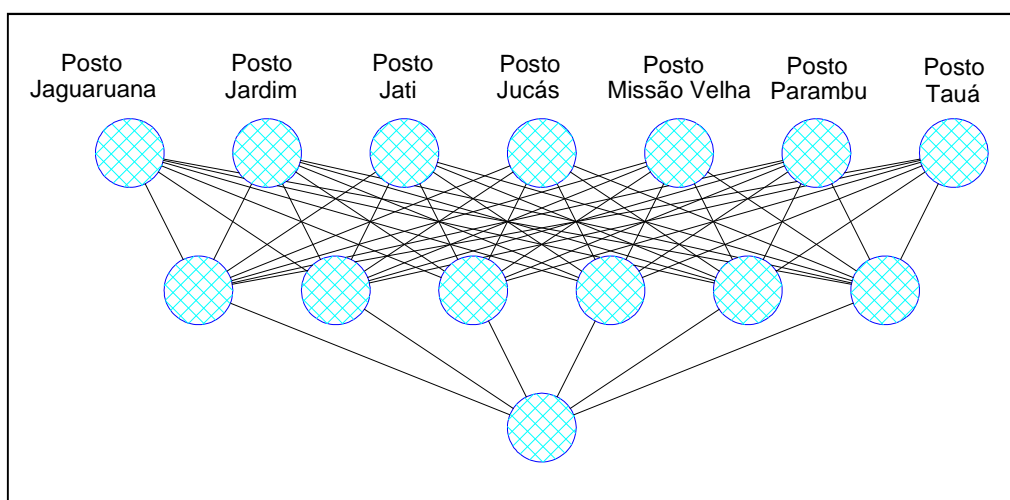


Figura 4.4 - Arquitetura de rede escolhida para modelagem com as RNA.

O gráfico mostrado na Figura 4.5 apresenta os valores de vazões calculadas pelo modelo *versus* vazões observadas. Este gráfico representa o desempenho do modelo na fase de treinamento da rede. A Figura 4.6 traz a comparação entre os hidrogramas calculados e observados na mesma fase.




Figura 4.5 - Correlação entre as vazões observadas e as vazões calculadas pelo modelo com as RNA, na fase de treinamento.




Figura 4.6 - Hidrograma diário observado e hidrograma determinado pelo modelo com as RNA.

Os gráficos mostrados nas Figuras 4.7 e 4.8 apresentam os valores de vazões calculadas pelo modelo utilizando as RNA *versus* vazões observadas. Estes gráficos representam o desempenho do modelo com as RNA na fase de validação.

Com a análise dos gráficos das Figuras 4.7 e 4.8 pode-se observar o baixo valor para o coeficiente de Nash obtido para a fase de validação do modelo o qual utiliza as RNA. Os hidrogramas da Figura 4.8 indicam que o modelo não foi capaz de se adequar à sazonalidade inerente ao fenômeno, haja vista os grandes erros observados principalmente nos maiores picos de vazões.




Figura 4.7 - Correlação entre as vazões observadas e as vazões calculadas pelo modelo com as RNA, na fase de validação.




Figura 4.8 - Hidrograma observado e hidrograma determinado pelo modelo com as RNA.

Devido a este baixo rendimento das RNA, que pode ser explicado pela limitação severa da quantidade de dados, utilizou-se da técnica de validação cruzada para a rede cuja configuração – 7-6-1 – apresentou os melhores resultados. No entanto, apresentando-lhe uma gama maior de dados de chuva e vazão, tendo sido aqui utilizados seis anos de dados (de 1965 a 1970) para o treinamento e apenas um (1971) para a validação.

O erro quadrático foi monitorado, de forma a se estabelecer como critério de parada o seu início de crescimento ou sua estabilização. Assim, para o treinamento utilizando a série de seis anos de dados, observa-se a estabilização do erro médio quando o número de épocas excede $1,0 \times 10^5$ épocas. O gráfico da figura 4.9 apresenta o comportamento do erro, na fase de validação.

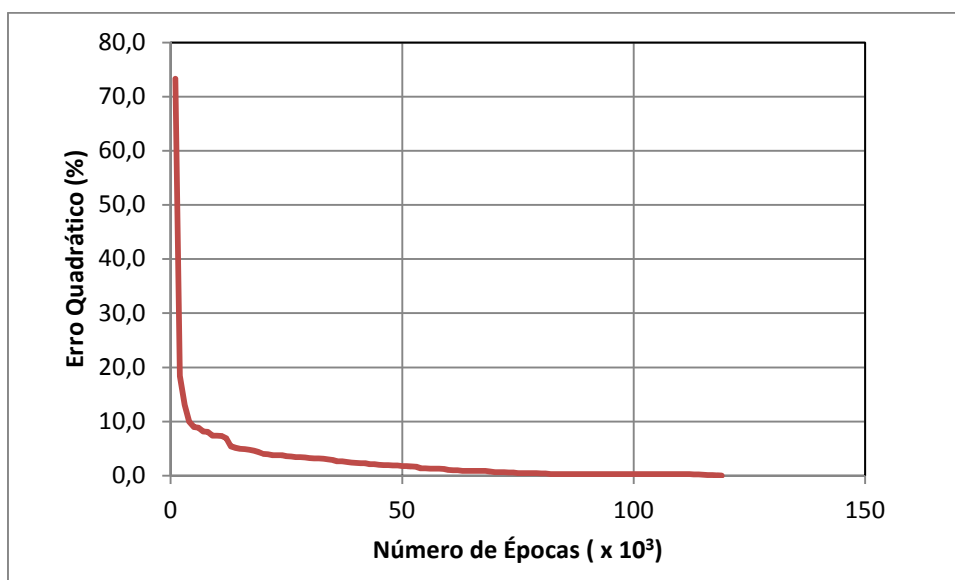


Figura 4.9 – Decréscimo do erro quadrático em função do número de épocas, N .

Os gráficos mostrados nas Figuras 4.10 e 4.11 apresentam os valores de vazões calculadas pelo modelo utilizando as RNA versus vazões observadas. Estes gráficos representam o desempenho do modelo com as RNA nas fases de validação, quando se utilizando da técnica de validação cruzada.




Figura 4.10 - Correlação entre as vazões observadas e as vazões calculadas pelo modelo com as RNA, após o treinamento da rede com validação cruzada.




Figura 4.7 - Hidrograma observado e hidrograma determinado pelo modelo com as RNA.

Observa-se, com os gráficos das figuras 4.10 e 4.11, que a rede então treinada, mesmo utilizando-se da técnica de validação cruzada, apresentou baixa capacidade de generalização. Estes resultados forneceram coeficiente de Nash igual a 0,25, e erro médio igual a 3,0%.

4.5. Resultados Obtidos com o SMAP

A calibração do modelo SMAP foi realizada mediante utilização do algoritmo evolucionário *Particle Swarm Optimization* (PSO), apresentando como função objetivo a maximização do coeficiente de Nash & Sutcliffe. Este procedimento é realizado no trabalho de Barros (2007).

O objetivo de se obter uma modelagem através do SMAP é a comparação entre os resultados obtidos com as RNA e aqueles obtidos através de uma modelagem tradicional ou com qualidade atestada em outras publicações, caso da calibração do modelo SMAP através do PSO apresentada por Barros (2007) e por Nascimento (2007).

A Tabela 4.2 apresenta os resultados calibrados dos parâmetros inerentes ao modelo SMAP, calibrados nas 22 simulações realizadas para os modelos estudados. O gráfico da Figura 4.9 apresenta a relação entre os coeficientes de Nash obtidos na fase de calibração (eixo y) e validação (eixo x). A dispersão mostrada na Figura 4.9 denota que as melhores soluções são aquelas representadas pelos pontos mais próximos da reta ($Nash_{calibração} = Nash_{validação}$) e mais próximos da unidade.

Tabela 4.2 - Valores dos coeficientes de Nash para calibração e validação do modelo SMAP.

Simulações	Parâmetros Calibrados do SMAP		
	SAT	k2t	Ai
1	363,00	7,49	5,88
2	190,80	1,42	10,00
3	658,00	2,96	0,00
4	357,80	5,06	0,00
5	445,60	3,95	1,46
6	1301,30	1,53	10,00
7	5,25	5,25	0,10
8	409,20	4,41	1,88
9	534,10	2,61	0,00
10	647,90	3,08	0,00
11	380,90	4,21	0,00
12	413,20	4,20	3,71
13	669,70	5,92	3,50
14	521,40	3,12	0,00
15	523,20	2,79	0,00
16	638,30	3,10	0,00
17	369,40	4,36	1,07
18	410,90	4,31	4,15
19	512,50	3,27	0,00
20	514,70	2,97	0,00
21	638,70	3,14	0,00
22	370,10	4,49	1,75

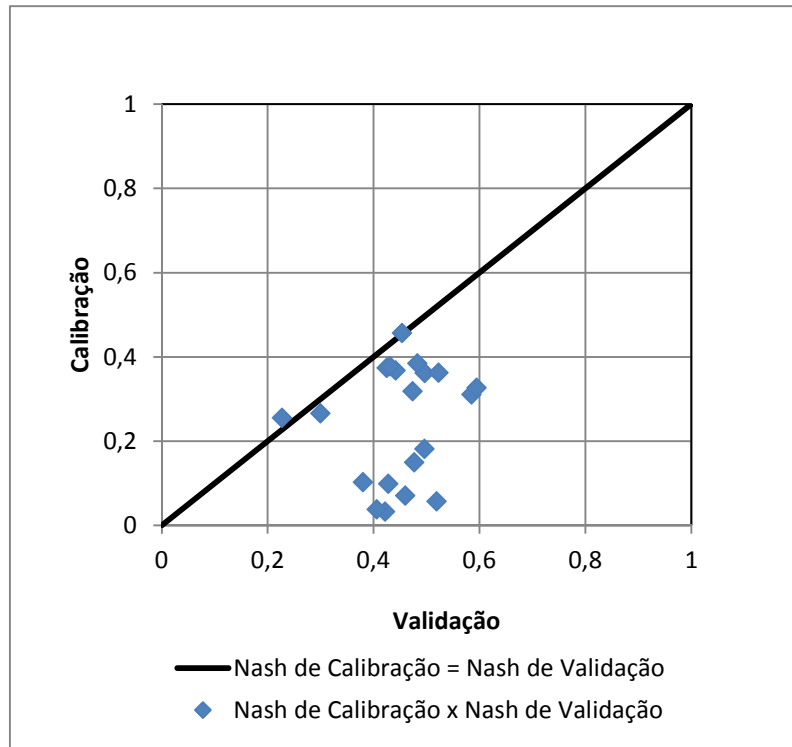
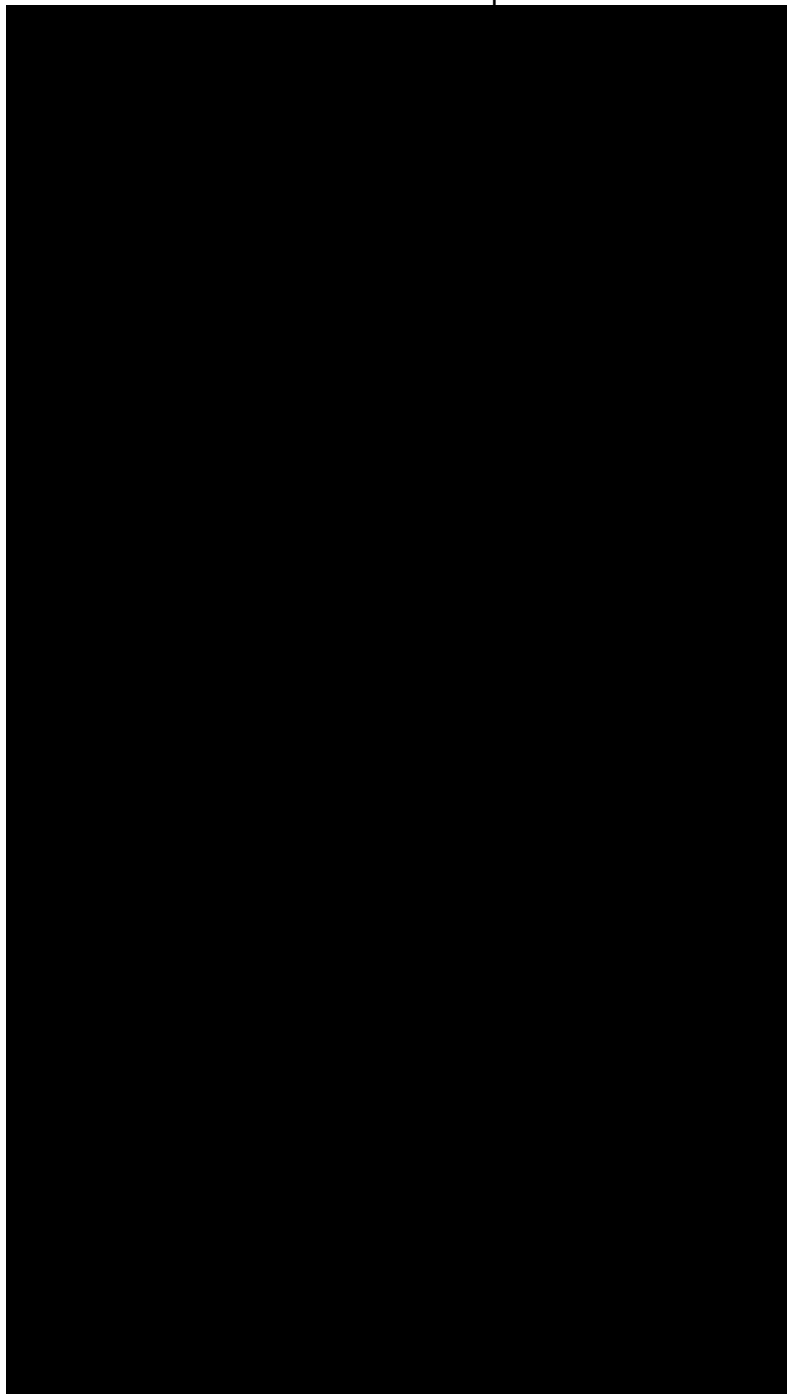


Figura 4.9 - Valores de coeficientes de Nash para as fases de calibração e validação.

Analisando-se o gráfico mostrado na Figura 4.9, observa-se que a maioria das simulações apresentou coeficientes de Nash superiores a 40% na fase de validação, embora na maioria das simulações este parâmetro tenha sido inferior a 20%. É possível se afirmar, ainda, que o modelo apresentou na fase de validação desempenhos incompatíveis com aqueles obtidos na fase de calibração, haja vista a disparidade entre parâmetros de Nash calculados para ambas as fases.

A partir da Tabela 4.3, pode-se observar que a simulação 19, a qual se utilizou dos dados relativos aos anos de 1968 a 1970 para a calibração do modelo, apresentou o mais alto coeficiente de Nash para a fase de validação. Desta forma, serão adiante analisados os resultados obtidos para a simulação 19 pelo modelo SMAP.

Tabela 4.3 - Parâmetros calibrados para o modelo SMAP.



Como mostra a Tabela 4.3, o coeficiente de Nash calculado para a fase de calibração da simulação 19 apresentou resultado de 45,40%, enquanto para a validação o Nash calculado foi de 45,70%, superando ligeiramente o desempenho apresentado na calibração. O gráfico mostrado na Figura 4.10 apresenta os valores de vazões calculadas pelo modelo *versus* vazões observadas. Este gráfico representa o desempenho do modelo na fase de calibração. A Figura 4.11 traz a comparação entre os hidrogramas calculados e observados na mesma fase.




Figura 4.10 - Correlação entre as vazões observadas e as vazões calculadas pelo modelo SMAP, na fase de calibração.




Figura 4.11- Hidrograma observado e hidrograma determinado pelo modelo SMAP, na fase de calibração.

Os gráficos mostrados nas Figuras 4.12 e 4.13 apresentam os valores de vazões calculadas pelo modelo SMAP *versus* vazões observadas. Este gráfico representa o desempenho do modelo na fase de validação.

Com a análise dos gráficos das Figuras 4.12 e 4.13 pode-se observar que os valores de vazões calculados flutuam em relação à linha de soluções ótimas ora superestimando as vazões observadas de menor magnitude, ora subestimando os valores de vazões observadas os quais apresentavam maiores medidas.




Figura 4.12 - Correlação entre as vazões observadas e as vazões calculadas pelo modelo SMAP, na fase de validação.




Figura 4.13 - Hidrograma observado e hidrograma determinado pelo modelo SMAP.

4.6. Resultados Obtidos com o HYMOD

Assim como na calibração do modelo SMAP, os parâmetros do modelo HYMOD foram determinados pelo algoritmo PSO, tendo como função objetivo a maximização do coeficiente de Nash.

No processo de calibração do modelo HYMOD, foram realizadas as mesmas 22 simulações, combinando a série destinada à calibração de forma que esta apresentasse 1, 2, 3 e 4 anos de dados observados de precipitações e vazões e respectivamente 6, 5, 4 e 3 anos de dados observados para a validação. Os dados de calibração combinaram ainda os anos dentro da série da forma apresentada na Figura 4.1.

Tabela 4.4 - Parâmetros calibrados para o modelo HYMOD.

Simulação	Parâmetros do Modelo		
	Cmax	Beta	RQ
1	328,70	0,10	0,70
2	1459,40	2,01	0,70
3	3500,00	2,05	0,58
4	3211,70	3,00	0,41
5	2993,80	3,00	0,56
6	2199,40	0,21	0,70
7	3499,90	1,06	0,60
8	557,10	0,28	0,69
9	3500,00	2,14	0,60
10	3500,00	2,21	0,57
11	3243,60	3,00	0,53
12	225,80	0,10	0,63
13	3499,90	0,88	0,62
14	3475,20	2,05	0,61
15	3499,90	2,26	0,59
16	3500,00	2,36	0,57
17	3102,30	2,67	0,53
18	226,50	0,10	0,62
19	3500,00	2,17	0,60
20	3499,90	2,41	0,58
21	3500,00	2,32	0,57
22	454,70	0,28	0,55

Desta forma, utilizando-se da mesma série de dados os quais foram apresentados ao modelo SMAP, os resultados calibrados dos parâmetros inerentes ao modelo HYMOD, calibrados nas 22 simulações apresentadas na Figura 4.1, são mostrados na Tabela 4.5. O gráfico da Figura 4.14 apresenta a relação entre os coeficientes de Nash obtidos nas fases de calibração e validação.

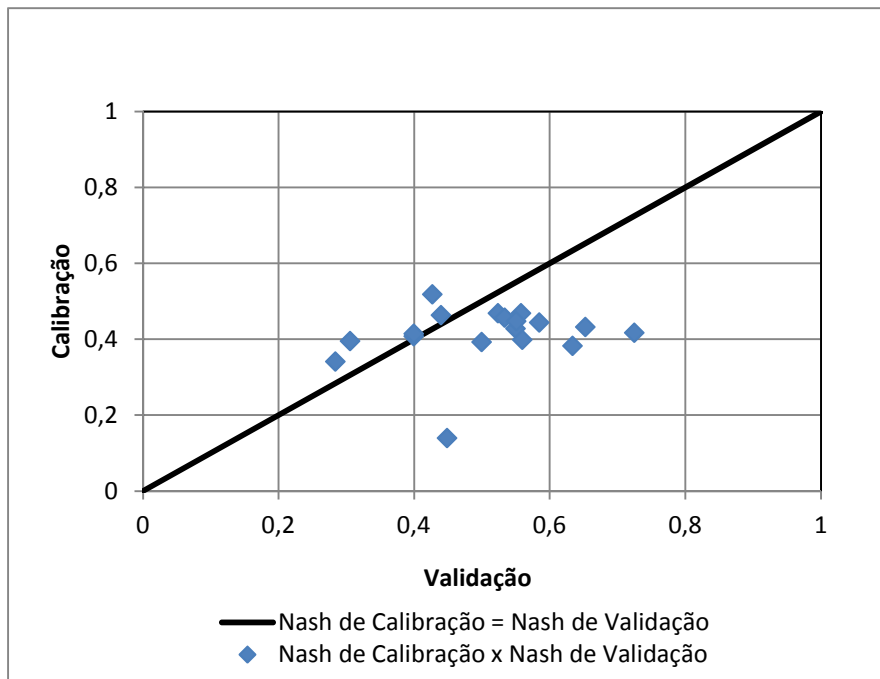


Figura 4.14 - Valores de coeficientes de Nash para as fases de calibração e validação do modelo HYMOD.

Analisando-se a dispersão apresentada na Figura 4.14, observa-se que a maioria das simulações apresentou coeficientes de Nash superiores a 40% tanto na fase de calibração quanto na fase de validação. É possível se afirmar ainda, pela figura, que o modelo apresentou na fase de validação desempenhos compatíveis com aqueles obtidos na fase de calibração, embora com baixas correlações.

A partir da tabela 4.5, pode-se observar que a simulação 17, a qual se utilizou dos dados relativos aos anos de 1968 a 1970 para a calibração do modelo, apresentou o mais alto coeficiente de Nash para a fase de validação. Desta forma, serão adiante analisados os resultados obtidos para a simulação 17 pelo modelo HYMOD.

Tabela 4.5 - Valores dos coeficientes de Nash para calibração e validação do modelo HYMOD.



Como mostra a tabela 4.5, o coeficiente de Nash calculado para a fase de calibração da simulação 17 apresentou resultado de 42,70%, enquanto para a validação o Nash calculado foi de 51,90%, superando o desempenho apresentado na calibração. Os gráficos mostrados nas Figuras 4.15 e 4.16 confrontam os valores de vazões calculadas pelo modelo (Q_c) com os de vazões observadas (Q_d). Estes gráficos representam o desempenho do modelo na fase de calibração.




Figura 4.15 - Correlação entre as vazões observadas e as vazões calculadas pelo modelo HYMOD, na fase de calibração.




Figura 4.16 - Hidrograma observado e hidrograma determinado pelo modelo HYMOD.

O gráfico mostrado na Figura 4.17 apresenta os valores de vazões calculadas pelo modelo HYMOD *versus* vazões observadas. Este gráfico representa o desempenho do modelo na fase de validação.

Com a análise dos gráficos das Figuras 4.17 e 4.18, pode-se observar que os valores de vazões calculados flutuam em relação à linha de soluções ótimas ora superestimando as vazões observadas de menor magnitude, ora subestimando os valores de vazões observadas os quais apresentavam maiores medidas.




Figura 4.17 - Correlação entre as vazões observadas e as vazões calculadas pelo modelo HYMOD, na fase de validação.




Figura 4.18 - Hidrograma observado e hidrograma determinado pelo modelo HYMOD.

4.7. Comparação entre os Resultados Obtidos com RNA, SMAP e HYMOD

Os resultados obtidos com as modelagens as quais utilizaram as RNA, SMAP e HYMOD, para a Bacia Hidrográfica do Arneiroz, apresentaram baixos coeficientes de Nash, sobretudo na fase mais importante do processo, a de validação. Observa-se, pois, que, dos três modelos, o modelo HYMOD diário apresentou os resultados mais consistentes, obtendo maiores coeficientes de Nash e maior coerência entre as correlações calculadas em ambas as fases do processo.

Os modelos, individualmente, apresentaram seu respectivo melhor desempenho em simulações distintas. Observa-se que o modelo utilizando as RNA apresentou os melhores resultados quando este utilizou os dados relativos à simulação 9 – a qual consta de uma série de dois anos para treinamento e de cinco anos para validação. Em contrapartida, os modelos SMAP e HYMOD, apresentaram os maiores parâmetros de desempenho quando se utilizaram dos dados referentes às simulações 19 e 17, às quais foram apresentadas séries de quatro e três anos de dados.

Destaca-se, então, nas modelagens realizadas no presente trabalho, a consistência de ambos os modelos hidrológicos tradicionais, os quais se utilizam de uma gama de dados capaz de melhor aferir sobre o regime de escoamento superficial na bacia hidrográfica estudada.

5. CONCLUSÕES E SUGESTÕES PARA FUTUROS TRABALHOS

5.1. Conclusões

A representação matemática do fenômeno estudado no presente trabalho, para a Bacia Hidrográfica do Arneiroz, revelou-se uma tarefa de exequibilidade complicada e envolta por inúmeras imprecisões, sobretudo aquelas recorrentes da disponibilidade insatisfatória de dados confiáveis.

Os modelos envolvendo as RNA apresentaram resultados demasiado aquém das expectativas iniciais, de maneira tal a fornecer desempenho ínfimo, principalmente quando comparados seus resultados com o dos modelos SMAP e HYMOD. Este panorama, porém, não é suficiente para que se conclua sua ineficiência em relação à transformação precipitação-vazão para o Estado do Ceará, uma vez que podem ser testados outros algoritmos de aprendizagem, outras funções de ativação e outras maneiras de se tratarem os dados de entrada para este modelo.

O modelo SMAP, com resultados também bastante aquém daqueles usualmente fornecidos por este, apresentou desempenho ligeiramente superior ao do modelo utilizando as RNA, demonstrando maior compatibilidade entre os coeficientes de Nash relativos às fases de calibração e validação. Neste ínterim, pode-se afirmar que mesmo a simulação a qual apresentou o melhor parâmetro Nash se revela inadequada como base para uma tomada de decisão envolvendo a previsão de vazões.

O modelo HYMOD, diferindo do panorama apresentado quando da utilização dos modelos utilizando as RNA e do SMAP, apresentou índices de desempenho, no mínimo, coerentes entre as fases de calibração e validação, demonstrando uma variabilidade menor quanto a estes índices nas diferentes simulações às quais foi submetido. Ainda assim, para a Bacia Hidrográfica do Arneiroz, este modelo não forneceu resultados sólidos os quais permitam uma tomada de decisão envolvendo a previsão de vazões.

5.2. Sugestões para pesquisas futuras

A fim de se buscar o aperfeiçoamento dos resultados obtidos no presente estudo ou para que seja possível se conhecer mais sobre os níveis de confiabilidade fornecidos pelos modelos com as RNA, SMAP e HYMOD, são feitas as seguintes sugestões:

- Analisar os resultados obtidos com esta metodologia, confrontando-os com outros obtidos para as demais estações fluviométricas do Estado do Ceará;
- Utilizar para as RNA, outros algoritmos de aprendizagem, novas topologias, novas funções de ativação e outros tratamentos relativos aos dados de entrada;
- De forma análoga, utilizar para a calibração dos modelos SMAP e HYMOD outros algoritmos, especialmente aqueles envolvendo outras funções objetivo;
- Testar, além dos modelos então descritos neste trabalho, modelos hidrológicos distribuídos, em consonância com ferramentas as quais envolvem os Sistemas de Informações Geográficas, as quais facilitam o tratamento dado à diversidade espacial dos parâmetros de entrada inerentes a estes modelos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALEXANDRE, ALAN M. BARROS; MARTINS, EDUARDO SÁVIO; CLARKE, ROBIN T. e REIS JR., DIRCEU S. (2006). *Regionalização de Parâmetros de Modelos Hidrológicos*. Artigo disponível em <<http://www.funceme.br>>
- ANA – Agência Nacional das Águas. Sítio Eletrônico: www.ana.gov.br.
- BARROS, FRANCISCO V. F. (2007). *Uso de Algoritmos Evolucionários na Calibração de Modelos Hidrológicos e na Operação de Sistemas de Reservatórios* – Disponível em: <<http://www.ene.unb.br/adolfo/ISI>>. Acesso em 25/09/2006.
- BOS. A, e VRENG, A. *Parameter Optimization of the HYMOD Model Using SCEM-UA and MOSCEM-UA*. University of Amsterdam, 2006.
- FUNCEME – Fundação Cearense de Meteorologia e Recursos Hídricos.
- HAYKIN, SIMON (2001). *Redes Neurais: Princípios e Prática* (2ª ed). Editora Bookman, Porto Alegre, RS.
- KASABOV, NIKOLA K. (1998) *Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering*. The MIT Press, Massachusetts Institute of Technology, Cambridge, Massachusetts.
- KOVÁCS, ZSOLT L. (2002) *Redes Neurais Artificiais – Fundamentos e Aplicações* (3ª ed.). Livraria da Física Editora, São Paulo – SP.
- LOPES, J.E.G. ; BRAGA JR, B. P. F. ; CONEJO, JOÃO GILBERTO LOTUFO . SMAP, A SIMPLIFIED HIDROLOGIC MODEL. IN: SYMPOSIUM ON RAINFALL RUNOFF MODELING, 1981, MISSISSIPPI, 1981.
- SANTOS, CLÁUDIA CRISTINA (2001) *Modelagem de Bacias Urbanas com Redes Neurais Artificiais*. Dissertação apresentada à Escola Politécnica da Universidade de São Paulo – USP.
- SIRH – Secretaria de Informação de Recursos Hídricos (2006). Dados disponíveis no Sítio eletrônico: <<http://www.srh.ce.gov.br>>. Acesso em 17/07/2009.
- VALENÇA, M. J. S. . *Aplicando Redes Neurais: Um Guia Completo*. 1ª ed. Recife: Livro Rápido - Elógica, 2005. v. 800. 284 p.
- VIEIRA, P. P. B. V; DINIZ, L. S; LACERDA, E.G.M; de CARVALHO, A. C. P. L. F; LUDERMIR, T. M. *Sistemas Inteligentes – Aplicação a Recursos Hídricos e Ciências Ambientais*. ABRH, 1999.