UNIVERSIDADE DE SÃO PAULO - USP
ESCOLA POLITÉCNICA - POLI
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E SANITÁRIA

CLÁUDIA CRISTINA DOS SANTOS

**MODELAGEM DE BACIAS URBANAS COM REDES NEURAIS
ARTIFICIAIS**

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Mestre em Engenharia.

São Paulo
2001

UNIVERSIDADE DE SÃO PAULO - USP
ESCOLA POLITÉCNICA - POLI
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E SANITÁRIA

CLÁUDIA CRISTINA DOS SANTOS

**MODELAGEM DE BACIAS URBANAS COM REDES NEURAIS
ARTIFICIAIS**

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Mestre em Engenharia.

Área de Concentração:
Engenharia Hidráulica e Sanitária

Orientador:
Augusto José Pereira Filho

São Paulo
2001

Santos, Cláudia Cristina

Modelagem de bacias urbanas com redes neurais artificiais. São Paulo, 2001

105p.

Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Hidráulica e Sanitária.

1. Redes neurais artificiais 2. Previsão de vazão 3. Auto regressivo I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Hidráulica e Sanitária II.t

"Se você não conseguir fazer uma coisa grandiosa hoje, faça alguma coisa pequena, mas faça.

Viva um dia de cada vez ...

e será mais fácil continuar vivendo. O importante é não parar, pois mesmo um pequeno avanço na direção certa, já é um grande progresso.

Continue andando e fazendo, e o que parecia fora do alcance esta manhã vai parecer um pouco mais próximo ao anoitecer.

A cada momento intenso e apaixonado que você dedica a seu objetivo um pouco mais você se aproxima dele.

Se você para completamente é muito mais difícil recomeçar, então continue andando.

Vá rápido quando puder e devagar quando for obrigado, mas siga seguro em sua direção."

"O sentido da existência não é ganhar a vida mas fazer a própria vida."

A grande guerreira, batalhadora e incentivadora dos filhos, minha mãe Maria. Ao meu namorado Wagner pelo amor, carinho, compreensão, confiança e constante incentivo.

AGRADECIMENTOS

Agradeço

Aos meus pais, Agenor e Maria que junto com Deus me proporcionaram a vida. Ao meus irmãos; Claudio, Valéria, Viviane e Wagner meu namorado pela união, pelo carinho, pelo companheirismo e constante apoio. Aos meus sobrinhos Camila, Vinícius, Isabela, Enzo e Letícia pelos momentos de alegria.

Ao professor Dr. Augusto José Pereira Filho pela orientação, apoio, incentivo, amizade, freqüente estímulo e ensinamentos úteis no desenvolvimento deste trabalho.

Ao Dr. Nelson Jesus Ferreira pelo incentivo, amizade e ajuda para melhorar a versão final deste trabalho.

Ao amigo Msc. Clovis Monteiro do Espirito Santo pelo apoio técnico e científico, constante ajuda e pela oportunidade de discussões.

Ao professor Dr. Kokei Uehara pela oportunidade de aprender com sua sabedoria, pelo incentivo e colaboração com sugestões na banca de qualificação.

Ao professor Ruben La Laina membro da banca de qualificação, o qual colaborou com sugestões e críticas dada a este trabalho.

Aos secretários da pós-graduação, Odorico e Ricardo pela disponibilidade e compreensão no atendimento.

Aos professores do departamento de PHD pelo meu desenvolvimento profissional.

À Fundação Centro Tecnológico de Hidráulica pelo fornecimento dos dados de chuva e vazão.

Ao Dr. Kuo-lin Hsu pelo fornecimento do algoritmo LLSSIM e suporte técnico.

Ao Instituto Nacional de Pesquisas Espaciais onde trabalho e pude desenvolver este trabalho.

Aos amigos que cultivei neste anos de pós-graduação: Mirléia, Alexandre e Roberto.

Enfim, quero agradecer a todas as pessoas que de algum modo colaboraram de forma direta ou indireta para a realização deste trabalho.

A todos, muito obrigado!

ÍNDICE

LISTA DE FIGURAS	iii
LISTA DE TABELAS	vii
LISTA DE SIGLAS, ABREVIATURAS E SÍMBOLOS	viii
RESUMO	x
ABSTRACTS.....	xi
1 - INTRODUÇÃO	1
2 - REVISÃO BIBLIOGRÁFICA	4
3 – MATERIAIS E MÉTODOS	15
3.1 - REDES NEURAIIS ARTIFICIAIS	15
3.1.1 – COMPARAÇÃO ENTRE O SISTEMA NERVOSO CENTRAL (SNC - CÉREBRO) E O COMPUTADOR	16
3.1.2. – NEURÔNIO BIOLÓGICO.....	19
3.1.3 – NEURÔNIO ARTIFICIAL	23
3.1.4 – FUNÇÕES DE ATIVAÇÃO	27
3.1.5 – DEFINIÇÕES DE REDES NEURAIIS	29
3.1.6 – ARQUITETURAS DA REDE NEURAL	30
3.1.6.1 – Número de Camadas da Rede Neural	31
3.1.6.2 – Tipos de Conexão.....	33
3.1.7 – APRENDIZADO	34
3.1.8 – ARQUITETURAS DE REDE NEURAIIS ARTIFICIAIS	38
3.1.8.1 – Perceptron	38
3.1.8.2 – Adaline	40
3.1.8.3 – Rede Perceptron Feedforward Multicamadas - MLP (Multi Layer Perceptron)	42
3.2 - ALGORITMO DE TREINAMENTO PARA REDES NEURAIIS MULTICAMADAS	45
3.3 - MODELOS AUTO-REGRESSIVOS.....	50
3.4 - ÁREA DE ESTUDO	52
3.5 - DADOS UTILIZADOS	54
3.5.1 – RADAR METEOROLÓGICO.....	54
3.5.2 – RADAR METEOROLÓGICO DE SÃO PAULO	56
3.5.3 – DADOS DE RADAR	59
3.5.4 – REDE TELEMÉTRICA DO ALTO TIETÊ.....	60
3.5.3.1 – Funcionamento da Rede Telemétrica de São Paulo.....	61
3.5.5 – DADOS TELEMÉTRICOS.....	62
4 - RESULTADOS	69

4.1 - TREINAMENTO.....	69
4.2 - VERIFICAÇÃO	79
4.3 - MODELO AUTOREGRSSIVO	85
4.4 - ERROS DE FASE E AMPLITUDE.....	88
4.5 - PREVISÃO IDEAL.....	91
5 – CONCLUSÕES	94
6 - RECOMENDAÇÕES.....	96
7 - REFERÊNCIAS BIBLIOGRÁFICAS	97
ANEXOS	105

LISTA DE FIGURAS

FIGURA 3.1: ESQUEMA SIMPLIFICADO DE UM COMPUTADOR ELETRÔNICO MOSTRANDO OS COMPONENTES BÁSICOS E SUAS INTER-RELAÇÕES (ADAPTADO DE GUYTON; HALL, 1997).....	17
FIGURA 3.2: COMPONENTES DE UM NEURÔNIO (FONTE: OSÓRIO; VIEIRA, 1999).....	20
FIGURA 3.3: JUNÇÃO DE DOIS NEURÔNIOS ATRAVÉS DA SINAPSE.	21
FIGURA 3.4: NEURÔNIO ARTIFICIAL (FONTE: OSÓRIO; VIEIRA, 1999).....	24
FIGURA 3.5: NEURÔNIO ARTIFICIAL DE MCCULLOCH-PITTS (ADAPATADO DE HAYKIN, 1994).....	25
FIGURA 3.6: NEURÔNIO ARTIFICIAL COM TENDÊNCIA.	26
FIGURA 3.7: ILUSTRAÇÃO DE NEURÔNIOS NATURAIS E ARTIFICIAIS (FONTE TAFNER ET AL, 1995).....	27
FIGURA 3.7: FUNÇÕES DE ATIVAÇÃO OU TRANSFERÊNCIAS MAIS UTILIZADAS: (A) LINEAR, (B) RAMPA, (C) DEGRAU, (D) GUASSIANA, (E) LOGÍSTICA (SIGMÓIDE) E (F) TANGENTE HIPÉRBOLICA	28
FIGURA 3.8: REDE NEURAL DE CAMADA ÚNICA (ADAPATADO DE HAYKIN, 1994).	31
FIGURA 3.9: REDE DE MÚLTIPLAS CAMADAS (ADAPATADO DE HAYKIN, 1994).....	32
FIGURA 3.10: APRENDIZADO SUPERVISIONADO (ADAPATADO DE HAYKIN, 1994).....	35
FIGURA 3.11: APRENDIZADO NÃO SUPERVISIONADO (ADAPATADO DE HAYKIN, 1994).....	36
FIGURA 3.13: PADRÕES LINEARMENTE SEPARÁVEIS: DADOS QUE CAEM EM LADOS OPOSTOS DO HIPERPLANO E PODEM SER SEPARADOS POR UMA LINHA RETA. OS PADRÕES QUE NÃO PERTENCEM À DETERMINADA CLASSE MAS QUE FORAM A ELA DESIGNADAS, SÃO MINORIA E REPRESENTAM UMA PORCENTAGEM DE ERRO ADMISSÍVEL (FONTE: BISHOP, 1995).....	39
FIGURA 3.14: PERCEPTRON UMA CAMADA (ADAPATADO HAYKIN, 1994).	39
FIGURA 3.15: DIAGRAMA DE BLOCOS DO ADALINE (ADAPATADO DE HAYKIN, 1994) ..	41
FIGURA 3.16: PADRÕES NÃO LINEARMENTE SEPARÁVEIS: PADRÕES QUE CAEM EM DETERMINADAS POSIÇÕES DO HIPERPLANO QUE NÃO PODEM SER SEPARADOS POR UMA LINHA RETA. SOLUÇÕES NÃO LINEARES, NORMALMENTE, APRESENTAM PERCENTUAIS DE ERRO NA CLASSIFICAÇÃO	

INFERIORES À SOLUÇÕES LINEARES PARA A GRANDE MAIORIA DOS PROBLEMAS (FONTE: BISHOP, 1995).	42
FIGURA 3.17: ARQUITETURA MULTICAMADAS PERCEPTRON COM DUAS CAMADAS ESCONDIDAS (ADAPATADA DE HAYKIN, 1994).	43
FIGURA 3.18: MÍNIMOS LOCAIS (1 E 2) E O MÍNIMO GLOBAL (1).	44
FIGURA 3.20: A CIRCUNFERÊNCIA PONTILHADA INDICA A LOCALIZAÇÃO E A ÁREA DE ABRANGÊNCIA DO RADAR DE SÃO PAULO EM RELAÇÃO AO ESTADO. E MOSTRA A LOCALIZAÇÃO DA BACIA DO RIO TAMANDUATEÍ NA ÁREA DE ABRANGÊNCIA DO RADAR.	57
FIGURA 3.21: DISTRIBUIÇÃO ESPACIAL DA CHUVA ACUMULADA A PARTIR DOS CAPPI'S DO RADAR DE SÃO PAULO NA ALTURA DE 3,0 KM, EM 07 DE FEVEREIRO DE 1994 ÀS 07H 03 MIN.	59
FIGURA 3.22: BACIA DO TAMANDUATEÍ E ISÓCRONAS EM ÁREA DE 2 KM X 2 KM, E AS COORDENADAS X, Y CENTRADAS NO RADAR METEOROLÓGICO DE SÃO PAULO.	60
FIGURA 3.23: LOCALIZAÇÃO DA REDE TELEMÉTRICA DO ALTO TIETÊ. A FIGURA 3.22A MOSTRA A LOCALIZAÇÃO DOS POSTOS PLUVIOMÉTRICOS E A 3.22B A LOCALIZAÇÃO DOS POSTOS FLUVIOMÉTRICOS (FONTE DAEE, 1999).	61
FIGURA 3.24: O PONTO VERDE REPRESENTA A LOCALIZAÇÃO DO POSTO FLUVIOMÉTRICO DO GLICÉRIO NA BACIA DO RIO TAMANDUATEÍ. A LINHA EM ABÓBORA INDICA O DIVISOR D'ÁGUA DA BACIA. OBSERVA-SE TAMBÉM O RIO TAMANDUATEÍ E SEUS PRINCIPAIS AFLUENTES.	62
FIGURA 3.25: PERFIL TRANSVERSAL DO PONTO ONDE ESTÁ LOCALIZADO O POSTO DO GLICÉRIO (FIG. 3.24) NO RIO TAMANDUATEÍ.	63
FIGURA 3.26: COTA (H) EM FUNÇÃO DA VAZÃO (Q) OBTIDO A PARTIR DA EQUAÇÃO TEÓRICA 3.25.	64
FIGURA 3.27: COMPARAÇÃO ENTRE A CURVA CHAVE TEÓRICA E DO CTH.	65
FIGURA 3.28: EVENTOS DE CHEIA DO RIO TAMANDUATEÍ PARA OS ANOS DE 1991(A), 1992(B), 1993(C), 1994(D) E 1995(E).	67
FIGURA 4.1: SÉRIES TEMPORAIS DE VAZÕES ESTIMADAS COM A RNA (CURVA VERMELHA) E VAZÕES MEDIDAS NO POSTO FLUVIOMÉTRICO DO GLICÉRIO NA BACIA DO ALTO TIETÊ (CURVA AZUL). AS VAZÕES FORAM NORMALIZADAS ENTRE 0,1 E 0,9, PELO VALOR MÁXIMO DE $650 \text{ m}^3\text{s}^{-1}$. RESULTADOS OBTIDOS A PARTIR	

DO TREINAMENTO COM DADOS DE CHUVA E OS DE VAZÃO DO PERÍODO DE 1991 A 1995.	70
FIGURA 4.2: DIAGRAMA DE ESPALHAMENTO ENTRE A VAZÃO OBSERVADA E A VAZÃO ESTIMADA PELO TREINAMENTO PRELIMINAR DA RNA. O AJUSTE LINEAR E COEFICIENTE DE CORRELAÇÃO ENTRE AS VARIÁVEIS ESTÃO INDICADOS.	71
FIGURA 4.3: SÉRIES TEMPORAIS DE VAZÃO ESTIMADA (A) E NÍVEL ESTIMADO (B) PELA RNA (CURVA VERMELHA) COM VETOR (8,1,1) (A E B) E (8,5,1) (C) OBSERVADAS(CURVA AZUL).	73
FIGURA 4.4: DIAGRAMA DE ESPALHAMENTO DAS SÉRIES TEMPORAIS DE VAZÃO (A E C) E NÍVEL (B) ESTIMADA PELO TREINAMENTO CONFORME FIG. 4.3. ESTÃO INDICADOS O AJUSTE LINEAR E O COEFICIENTE DE CORRELAÇÃO.	74
FIGURA 4.5: SÉRIES TEMPORAIS ESTIMADAS DE VAZÃO(A) E NÍVEL (B) (CURVA VERMELHA) E OBSERVADA (CURVA AZUL). RNA TREINADA COM UM VETOR 9,1,1.....	75
FIGURA 4.6: DIAGRAMA DOS ESPALHAMENTO DAS SÉRIES TEMPORAIS DE VAZÃO (A) E NÍVEL (B) E OBSERVADA CONFORME FIG. 4.5. ESTÃO INDICADAS O AJUSTE LINEAR DA DISPERSÃO E COEFICIENTE CORRELAÇÃO.	76
FIGURA 4.7: SÉRIES TEMPORAIS DE VAZÃO COM VETOR (78,1,1) (A) E (77,1,1) (C) ESTIMADAS (CURVA VERMELHA) E OBSERVADA (CURVA AZUL) E RESPECTIVOS DIAGRAMA DE ESPALHAMENTO (B) E (D).....	77
FIGURA 4.8: EVOLUÇÃO DA CHUVA OBTIDA PELO RADAR A CADA 30 MINUTOS.....	78
FIGURA 4.9: SÉRIES TEMPORAIS DE VAZÃO (A E C) E NÍVEL (B) ESTIMADAS COM A RNA (CURVA VERMELHA) E OBSERVADA (CURVA AZUL). SIMILAR A FIG. 4.3, EXCETO PARA O CONJUNTO DE VERIFICAÇÃO.	81
FIGURA 4.11: SIMILAR A FIG. 4.5, EXCETO PARA O CONJUNTO DE VERIFICAÇÃO.	84
FIGURA 4.13: SÉRIES TEMPORAIS DE VAZÕES ESTIMADA DA AR (CURVA VERMELHA) E OBSERVADA (CURVA AZUL). FORAM UTILIZANDO OS MESMOS DADOS DO TREINAMENTO (A) E VERIFICAÇÃO (B).	86
FIGURA 4.14: SIMILAR A FIG. 4.11 COM O VETOR 9,1,1.	87
FIGURA 4.15: ERROS DE FASE E AMPLITUDE PARA O TREINAMENTO E VERIFICAÇÃO, UTILIZANDO AS OPÇÕES 1 E 3. A) ERRO DE FASE E B) ERRO DE AMPLITUDE..	89
FIGURA 4.16: ERROS DE FASE E AMPLITUDE PARA O TREINAMENTO E VERIFICAÇÃO, UTILIZANDO AS OPÇÕES 2 E 4. A) ERRO DE FASE E B) ERRO DE AMPLITUDE.	90

FIGURA 4.17: EVOLUÇÃO TEMPORAL DO NÍVEL PREVISTO (VERMELHO) E OBSERVADO (AZUL). OS DADOS CORRESPONDEM AO PERÍODO DE 1991 A 1995 (TAB. 4.9). A) PREVISÃO PARA 30 MINUTOS, B) 60 MINUTOS, C) 90 MINUTOS, D) 120 MINUTOS, E) 150 MINUTOS E F) 180 MINUTOS.....	92
FIGURA 4.18: COEFICIENTE DE CORRELAÇÃO (R^2) OBTIDO DAS PREVISÕES DE 30, 60, 90, 120, 150 E 180 MINUTOS.	93
FIGURA 4.19: ERROS DE FASE(VERMELHO) E AMPLITUDE(AZUL) PARA AS PREVISÕES DE 30, 60, 90, 120, 150 E 180 MINUTOS.	93

LISTA DE TABELAS

TABELA 3.1: QUADRO COMPARATIVO ENTRE O CÉREBRO HUMANO E O COMPUTADOR. (FONTE TAFNER ET AL, 1996).....	17
TABELA 3.2: QUADRO COMPARATIVO ENTRE COMPUTADORES E NEUROCOMPUTADORES (FONTE TAFNER ET AL, 1996).....	18
TABELA 3.3: FUNÇÕES DE ATIVAÇÃO (TRANSFERÊNCIAS) MAIS UTILIZADAS.	28
TABELA 3.4: CARACTERÍSTICAS DO RADAR METEOROLÓGICO DE SÃO PAULO (ADAPTADA FCTH, 1987).....	57
TABELA 3.5: DADOS UTILIZADOS NO TREINAMENTO, VERIFICAÇÃO E PREVISÃO DA RNA.	68
TABELA 4.1: CENÁRIOS UTILIZADOS PARA O TREINAMENTO DA RNA.	69
TABELA 4.2: EVENTOS EXCLUÍDOS DA FIGURA 4.1.	71
TABELA 4.3: EVENTOS UTILIZADOS PARA O TREINAMENTO DA REDE NEURAL. ESTÃO INDICADOS A DATA E O NÚMERO DE HORAS.....	72
TABELA 4.4: COEFICIENTES DE CORRELAÇÃO PARA OS VÁRIOS TREINAMENTOS.	76
TABELA 4.5: DADOS UTILIZADOS NA VERIFICAÇÃO DA RNA.....	80
TABELA 4.6: COEFICIENTES DE CORRELAÇÃO PARA AS VÁRIAS VERIFICAÇÃO.....	83
TABELA 4.7: ERROS DE FASE E AMPLITUDE, PARA AS OPÇÕES 1 E 3 PARA TREINAMENTO E VERIFICAÇÃO DOS MODELOS AR E RNA	88
TABELA 4.8: ERROS DE FASE E AMPLITUDE, OPÇÕES 2 E 4 PARA TREINAMENTO E VERIFICAÇÃO DOS MODELOS AR E RNA	89
TABELA 4.9: EVENTOS UTILIZADOS PARA PREVISÃO DE NÍVEL.	91

LISTA DE SIGLAS, ABREVIATURAS E SÍMBOLOS

ADALINE	–	Adaptative Linear Element ou Elemento Linear Adaptativo
AR	–	Modelo Auto Regressivo
a_t	–	Ruído branco
CTH	–	Centro Tecnológico de Hidráulica
DAEE	–	Departamento de Águas e Energia Elétrica
e_0	–	Erro médio quadrático
EPs	–	Elementos de Processamento
$f(.)$	–	Função de transferência
$g_{non}(.)$	–	Função de mapeamento não linear
$F[w]$	–	Função Custo
FGLICE	–	Posto fluviométrico do Glicério
IA	–	Inteligência Artificial
LLSSIM	–	Algoritmo Linear Least Squares SIMplex
LMS	–	Linear Mean Square
LLS	–	Linear Least Square ou Mínimos Quadrado Linear
MADALINE	–	Many ADALINE
MCP	–	McCulloch-Pitts
ms_e	–	erro médio quadrático
$ms_{ediss.}$	–	erro de amplitude
$ms_{edisp.}$	–	erro de fase
n_a	–	número de camadas de entrada
n_b	–	número de camadas de saída
n_h	–	número de camadas escondidas
Q	–	Vazão
R	–	Taxa de precipitação
R^2	–	Coefficiente de correlação de ajuste linear.
RADAR	–	RADio Detection And Ranging
RMSP	–	Região Metropolitana de São Paulo
RNA	–	Rede Neural Artificial
RNB	–	Rede Neural Biológica

SNC	–	Sistema Nervoso Central
$t_1(p)$	–	Saída alvo
$X_1, \dots, X_n$	–	Sinais de entrada da rede neural
Z	-	Refletividade
$Z_1(p)$	–	Saída da rede neural
Y	–	Saída da rede neural
$W_1, \dots, W_n$	–	Pesos sinápticos
θ_k	–	Função limiar (threshold)
$\varphi(\cdot)$	–	Função de ativação
μ_k	–	Saída da combinação linear
$\phi_1, \dots, \phi_p$	–	Conjunto finitos de pesos do modelo AR.
$\sigma(\cdot)$	–	Operdor desvio padrão
$\langle \cdot \rangle$	-	Operador média
ρ	-	coeficiente de correlação

RESUMO

Redes Neurais Artificiais (RNA's) vem sendo utilizada em diversas áreas do conhecimento inclusive para a previsão de séries temporais. O objetivo deste trabalho é utilizar uma RNA para o diagnóstico e prognóstico de vazão em bacias urbanas da Região Metropolitana de São Paulo (RMSP) com dados do radar meteorológico de São Paulo e os dados telemétricos da bacia do Alto Tietê. Uma RNA do tipo feedforward multicamadas, com aprendizado supervisionado e com o algoritmo de treinamento Linear Least Square SIMplex (LLSSIM, Hse et al. 1996) foram aplicados à bacia do Rio Tamanduateí. Dividiu-se os eventos disponíveis em três grupos; para o treinamento, verificação e previsão ideal com a RNA.

Realizou o treinamento e verificação da rede com dados de vazão estimada e nível medido. Os erros de fase e amplitude foram utilizados para avaliar o desempenho da rede em cada uma das configurações empregadas. Estes indicam a importância da memória da bacia para o bom desempenho da RNA. Verifica-se também que nem sempre o aumento do número de camadas escondidas melhoram os resultados, bem como o aumento da quantidade de dados. Comparou-se ainda a performance da RNA contra um modelo auto regressivo sendo a primeira menos dependente da memória da bacia. Por último, realizou previsões do tipo ideal com resultados satisfatórios até 1 hora e 30 minutos de antecedência. Além deste período os erros crescem exponencialmente.

ABSTRACTS

Artificial Neural Networks (ANN) have been widely used in several areas of science for many purposes, including time series forecasting. The objective of this work is to apply an ANN to simulate and to forecast streamflow at the outlet of the Tamanduateí basin. This urban basin is located within the Metropolitan Area of São Paulo (MASP). Radar and telemetric data are input to a multi-layer feedforward ANN. It is trained with the Linear Least Square SIMplex training algorithm (LLSSIM; Hse et al, 1996). Available flood events were divided up in three independent groups for training, verification and forecasting.

The training and the verification of estimated streamflow and measured river stage were carried out. Phase and amplitude errors were used to evaluate the performance of the ANN for each configuration. The results indicate a better performance of the ANN when previous streamflow or river stage are input to the ANN. Furthermore, the increase of hidden layers not necessarily improve the results. The ANN was compared to an auto-regressive model. The former is less dependent on the basin memory. The ANN Forecasts yielded satisfactory results up to one and half-hour in advance. For longer time periods the errors tend to grow exponentially.

1 - INTRODUÇÃO

O rápido processo de urbanização das últimas décadas tem ocorrido de maneira desordenada. A impermeabilização dos solos e a diminuição das áreas vegetadas reduzem a infiltração e aumentam o escoamento superficial. Durante períodos de chuva intensa podem ocorrer inundações e alagamentos devido ao maior volume d' água escoado superficialmente. Além disso, a ocupação de áreas ao longo do leito dos rios causa grandes transtornos principalmente nos períodos de inundação natural das várzeas ribeirinhas. Estes eventos de enchente causam grandes impactos sócio - econômicos.

O desenvolvimento urbano desenfreado tem provocado maiores e mais freqüentes inundações. As grandes metrópoles como São Paulo sofrem com as grandes enchentes principalmente no período de verão. Desta forma, é de grande importância prever eventos de enchente de modo a melhor coordenar as ações da defesa civil. Uma melhor antecipação pode ser obtida por meio do monitoramento dos sistemas de tempo, quantificando os volumes d'água esperados e as respectivas vazões nas bacias de interesse.

O processo de transformação de chuva sobre a bacia em vazão do rio é não linear. Representações simplificadas são freqüentemente utilizadas devido à limitação de dados hidrometeorológicos. A técnica de redes neurais não requer conhecimento explícito da bacia e tem produzido bons resultados na modelagem de processos hidrológicos de transformação de chuva em vazão.

A simulação matemática dos processos envolvidos no ciclo hidrológico é bastante complexa (SINGH, 1988). Processos como a precipitação, evaporação, infiltração e escoamento em rios dependem de um grande número de fatores físicos, dificultando a análise quantitativa e qualitativa. Por exemplo, o escoamento em canais e rios são influenciados por fatores como a topografia da bacia, a cobertura vegetal, tipo do solo, distribuição espacial e temporal da precipitação, atividades humanas na bacia, urbanização, entre outros.

Os projetos de engenharia e análise de impactos ambientais necessitam de séries temporais de vazão no canal em bacias, muitas vezes, sem medição. Uma variedade de métodos analíticos têm sido desenvolvidos com o propósito de estimar a vazão no canal a partir da chuva incidente sobre a bacia. Todavia, esses métodos apresentam restrições e deficiências por serem fundamentados em simplificações dos fenômenos hidrológicos e hidráulicos naturais. O conhecimento dos processos de transformação chuva–vazão são de grande interesse, em projetos de engenharia, gerenciamento de recursos hídricos, e manejo da bacia. Esses processos não são satisfatoriamente descritos por modelos simples, porque são não lineares, e as variáveis envolvidas apresentam heterogeneidades temporais e espaciais.

As RNAs têm sido utilizadas com sucesso para modelar relações envolvendo séries temporais complexas de entrada-saída em várias áreas (VEMURI, 1994). O sucesso das RNAs para modelar sistemas dinâmicos em vários campos da ciência e da engenharia sugere que elas possam ser também aplicadas no processo de transformação chuva-vazão, especialmente nos casos onde o conhecimento dos processos hidrológicos seja muito limitado.

As principais vantagens das RNAs na modelagem de bacias hidrográficas são:

- Resolvem sistemas mal-definidos ou não claramente compreendidos;
- Não requerem conhecimento dos processos físicos;
- Podem ser aplicadas em sistemas sem soluções específicas;
- Treinamento contínuo da rede (e.g., sistemas dinâmicos);
- Os erros de medição não são amplificados;
- Permitem uma otimização entre os dados de entrada e saída.

Desta forma, a RNA pode ser utilizada para transformar chuva em vazão sem mesmo se conhecer as características hidrológicas da bacia. Essa técnica pode ser uma alternativa viável na previsão do escoamento no canal quando somente as séries temporais de entrada e saída estão disponíveis e a dinâmica hidrológica da bacia é pouco conhecida. Por outro lado, a RNA não substitui os modelos conceituais fundamentados nas leis físicas.

Neste trabalho tenta-se integrar a previsão de vazão utilizando redes neurais para obter resultados mais confiáveis e precisos em tempo real. Desta forma, utilizou-se uma das sub-bacias do rio Tietê, localizada na parte mais urbanizada da cidade de São Paulo, o Rio Tamanduateí. O trabalho está organizado da seguinte forma.

Primeiro faz-se uma revisão sobre redes neurais, dos modelos autoregressivos. A seguir, descreve-se o algoritmo LLSSIM utilizado para treinar e validar a RNA. Os dados utilizados para treinar, verificar e prever com a RNA são descritos. Por último são apresentados os resultados obtidos com a RNA, as conclusões e as recomendações para futuros trabalhos.

2 - REVISÃO BIBLIOGRÁFICA

As Redes Neurais Artificiais (RNAs) começaram a ser desenvolvidas visando simular sistemas naturais utilizando-se de estruturas análogas às Redes Neurais Biológica (RNB). O cérebro humano é interligado por meio das sinapses. A complexidade da conectividade entre os neurônios é responsável pelas características atribuídas à inteligência.

No início, a comunidade científica tentou entender o funcionamento do cérebro humano. A agilidade e a eficiência com que o cérebro realiza suas funções constituem o objetivo a ser alcançado pelos sistemas de Inteligência Artificial (IA), que baseiam seus estudos na simulação computacional de aspectos da inteligência humana. Com o desenvolvimento da IA surgiu a idéia de representar por meio de determinados programas computacionais o funcionamento do processo de aprendizagem do cérebro humano. Assim, a tentativa de simular a rede neural do cérebro deu origem à RNA. Portanto, uma RNA pode ser definida como uma estrutura computacional que tem como objetivo permitir a implementação de modelos matemáticos que representem, de forma simplificada, a forma como o cérebro humano processa as informações que adquire.

O primeiro trabalho sobre RNA surgiu na década de 40 com o neurofisiologista *McCULLOCH* e o matemático *PITTS* cujas idéias foram publicadas em 1943 no artigo "*A Logical Calculus of the Ideas Immanent in Nervous Activity*" (McCULLOCH; PITTS, 1943). Neste trabalho McCULLOCH; PITTS estabeleceram uma analogia entre o processo de comunicação das células nervosas vivas e o processo de comunicação por transmissão elétrica, ou seja, em dado instante de tempo o neurônio está ativo ou inativo. E com isto propuseram a criação de neurônios formais. Em 1947 eles conseguiram demonstrar que era possível conectar os neurônios formais e gerar uma rede capaz de executar funções complexas.

O neurônio artificial criado por McCULLOCH; PITTS tentou se assemelhar ao neurônio de uma RNB, porém a RNA ainda não se assemelhou totalmente ao sistema de

processamento paralelo que ocorre nas células biológicas. O aprendizado de uma RNA é fundamentado em modelos que possam ser implementados para desempenhar funções inerentes ao cérebro humano.

As pesquisas com redes neurais artificiais tentam simular o cérebro humano, principalmente a sua capacidade de aprender e se adaptar a eventuais mudanças. Assim as RNAs, podem executar tarefas que os programas convencionais não conseguem realizar, pois não têm essa característica de aprendizagem e adaptabilidade.

O psicólogo *DONALD HEBB* (1949) em sua publicação “*The Organization of Behavior*” contribuiu significativamente ao estudo das redes neurais. Ele elaborou uma teoria fundamentada no processo de aprendizagem que ocorre no cérebro humano, que serviu de base para a aprendizagem das redes neurais. Na verdade, *HEBB* sugeriu que a conectividade do cérebro mudasse continuamente quando um organismo aprendesse a diferenciar as tarefas funcionais, e se as ligações neurais fossem criadas por essa mudança. O aprendizado é geralmente um processo interativo de adaptação aplicado aos parâmetros da rede (pesos e limiares), onde os conhecimentos são armazenados após cada interação.

O estudo de *HEBB* inspirou o desenvolvimento de modelos computacionais de aprendizagem e sistemas adaptáveis. *NATHANIEL ROCHESTER et al.* (1956), desenvolveram um modelo de RNA no qual simulavam a interconexão de centenas de neurônios e um sistema para verificar o comportamento da rede diante dos estímulos externos. Talvez tenha sido a primeira tentativa de simulação em computador para testar uma teoria de RNA fundamentado no aprendizado de *Hebb*.

A *Rede Perceptron* criada por *FRANK ROSENBLAT* (1958) se tornou muito popular. Seu livro “*Principles of Neurodynamics*, de 1962 (*ROSENBLAT*, 1962), forneceu várias idéias sobre os Perceptrons, que são redes de neurônios de limiar fundamentado no modelo de *McCULLOCH* e *PITTS*. Demonstrou-se que, se fossem acrescentadas sinapses ajustáveis, os neurônios artificiais de *McCULLOCH* e *PITTS* poderiam ser “treinados” para classificar certos tipos de padrões em duas categorias, dada sua saída binária

WIDROW; HOFF em 1960 desenvolveram a primeira rede capaz de imitar o cérebro humano utilizando processadores paralelos (ao invés de um único processador), com a estruturação da *Rede ADALINE*, (Adaptative Linear Element). Mais tarde eles estruturaram uma nova rede denominada MADALINE (Many ADALINE).

A credibilidade da Rede Perceptron não durou muito. Em 1969, *MARVIN MINSKY*; *SEYMOUR PAPERT* publicaram o livro “*Perceptron*” , no qual fizeram críticas severas às redes neurais, argumentando que os Perceptrons apresentavam limitações em suas aplicações, não possuíam capacidade de aprendizado para resolver problemas simples e nem uma adequada sustentação matemática. Além disso, provaram formalmente que uma rede formada de uma única camada de neurônios, independente do algoritmo de aprendizagem, é capaz apenas de resolver problema de associação de padrões, quando os conjuntos de pares de padrões são linearmente separáveis. Sabia-se que as redes Perceptron com mais de uma camada de neurônios, chamadas MultiLayered Perceptrons ou ainda redes feedforward, tinham o poder computacional de aprender padrões linearmente dependentes, contudo não se conhecia um algoritmo de aprendizagem que pudesse realizar tal associação.

Apesar de terem surgidos trabalhos significativos na década de 60 e 70, como os de *WERBOS*, *ANDERSON*, *GROSSBERG* (*HAYKIN*, 1994), os resultados e observações feitas por *MINSKY*; *PAPERT* foram devastadores, deixando assim a RNA em segundo plano durante estas décadas. Mas no início da década de 80, as pesquisas com as RNAs voltaram a recuperar sua credibilidade com os trabalhos do físico e biólogo *JOHN HOPFIELD* (1982).

A incapacidade das redes Perceptron em resolver problemas de associação de padrões para um conjunto de padrões não linear foi eliminada por *RUMELHART et al.* (1986) . A solução encontrada foi a “*Generalized Delta Rule*”, mais conhecida como “*Backpropagation Error Correction Algorithm*”, em 1986, para redes Perceptron de multicamadas de neurônios com entradas e saídas analógicas. As funções de ativação foram substituídas por funções contínuas sigmoidais. Um resultado similar chamado *The Learning Logic* já havia sido encontrado independentemente por *PARKER* (1985), porém sem repercussão na época.

As RNAs podem ser entendidas como conjuntos bem estruturados de unidades de processamentos, interligadas por canais de comunicação, cada qual tendo um determinado peso correspondente a um valor numérico. Elas consistem de várias unidades de processamento (neurônios artificiais) interconectadas entre si, formando uma determinada disposição estrutural de camadas (entrada, intermediárias e saída) e conexões entre as camadas.

As RNB usam milhões de neurônios em suas tarefas. Já as RNAs estão restritas a algumas centenas. Os trabalhos utilizando RNAs para resolver problemas em engenharia civil iniciaram depois dos anos 80. *FLOOD*; *KARTAM* (1994a, b) mostraram conceitos, métodos de usar as RNAs, e o potencial para aplicações na área da engenharia civil. As aplicações das RNAs utilizando séries temporais tem crescido muito dentro da área de recursos hídricos, obtendo bons resultados nas previsões de cheias em rios.

A chuva é um elemento do ciclo hidrológico, e sua grande variabilidade espacial e temporal faz-se com que seja difícil fazer sua previsão. A hidrologia e a climatologia são áreas que tem grande interesse neste elemento. A medida de chuva geralmente é feita pontualmente. Os métodos para previsão de chuva depende da aplicação e das escalas de tempo e espaço de interesse. Em aplicações hidrológicas grandes escalas temporais estão associados a grandes escalas espaciais. *FRENCH et al. (1992)* utilizaram uma RNA para fazer a previsão do campo de intensidade de chuva no espaço e no tempo, utilizando uma rede típica de três camadas: camada de entrada, escondida e saída. O algoritmo de treinamento utilizado foi o “back-propagation”, onde campos de chuva de entrada e saída foram apresentados à rede como um conjunto de treinamento. Depois que a rede foi treinada, a RNA foi utilizada para a previsão da intensidade de chuva para 1 hora.

A vazão num rio ou canal é um processo complexo influenciado por fatores como a topografia, a cobertura vegetal, tipos de solo, características do canal, presença de aquíferos, distribuição da precipitação, área urbanizada. Os projetos de engenharia e análise de impacto no meio ambiente freqüentemente requerem a estimativa da vazão,

ou suas propriedades estatísticas em lugares onde não se tem dados de vazão. Uma grande variedade de métodos têm sido desenvolvidos para este propósito, incluindo os modelos paramétricos e os modelos empíricos. As redes neurais “feedforward” estão sendo amplamente utilizada neste tipo de aplicação, mas este tipo de rede tem suas limitações. A arquitetura da rede deve ser fixa no processo. Se a arquitetura for muito pequena a rede pode não ter graus de liberdade suficientes para aprender corretamente o processo do escoamento ou, se a rede for muito grande, pode não convergir durante o treinamento ou, pode dar um peso muito grande aos dados e memorizar a vazão histórica antes da generalização.

KARUNANITHI et al. (1994) utilizaram o algoritmo de correlação cascata, que é um algoritmo construtivo que pode automaticamente sintetizar a arquitetura de uma rede como parte do seu processo de treinamento. O objetivo de KARUNANITHI et al. era avaliar a capacidade de previsão de um modelo de rede neural diferente, antes de se concentrar na seleção da arquitetura apropriada para a rede e a convergência do algoritmo de treinamento.

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

Os modelos de RNAs têm sido úteis e eficientes quando utilizados para resolver problemas cujos processos envolvidos são difíceis de serem descritos por equações físicas. HSU et al. (1995) utilizaram este tipo de modelo para simular processos hidrológicos não lineares numa bacia. Para identificar a estrutura e os parâmetros da rede “feedforward” com três camadas foi utilizado um novo procedimento, mostrando também qual o potencial desta nova ferramenta na previsão de vazão. Fez-se uma

comparação entre modelos baseado na capacidade individual de cada um, para representar os processos hidrológicos.

Com o passar dos anos tem sido desenvolvido vários modelos para previsão de chuva-vazão de variados graus de complexidade e sofisticação. SHAMSELDIN et al. (1996) desenvolveram um sistema geral para gerenciamento da previsão de chuva-vazão, no qual as estimativas das descargas obtidas de modelos diferentes devem ser eficientemente combinadas, tornando-se uma boa ferramenta para ser utilizadas em sistemas operacionais de previsão de vazão de um rio. A essência deste conceito é que a saída de cada modelo capte certos aspectos importantes de informações disponíveis sobre o processo a ser modelado. Desse modo, produz-se uma fonte de informações que pode ser diferente de outros modelos. A combinação dessas várias fontes de informações de saída possibilitam ao usuário se utilizar de todas as informações de entrada. Com esse conceito de combinação, a saída estimada por diferentes modelos de chuva-vazão para produzir uma combinação global de saída, pode ser uma boa alternativa sobre o uso de um modelo simples individual de chuva-vazão. Três métodos de combinação de saída de modelos foram considerados: o método de média simples (SAM), o método dos pesos médios (WAN) e o método de redes neurais (NNM). A estimativa das descargas de cinco modelos de chuva-vazão de 11 bacias foram utilizados para testar o desempenho desses três métodos de combinação. Os resultados confirmaram que pode-se obter uma melhor estimativa de descarga pela combinação das saídas de diferentes modelos.

SHAMSELDIN (1997) utilizou a técnica de RNA para fazer a modelagem da transformação chuva-vazão. O objetivo era avaliar o desempenho da técnica comparando com alguns modelos de chuva-vazão tradicionais. Dependendo da natureza do problema, a RNA pode ter múltiplas entradas e múltiplas saídas. SHAMSELDIN no seu trabalho utilizou-se de múltiplas entradas mas apenas uma saída. Como em outros modelos empíricos, a rede neural deve ser calibrada usando dados observados de entrada-saída. Os valores ótimos dos parâmetros são obtidos pelo método de busca. A rede usada foi a multicamadas “feedforward”, por ser considerada como boa função aproximadora (NIELSEN, 1991). A forma da rede foi testada usando diferentes tipos de informações de entrada, como exemplo, chuva, chuva sazonal histórica e informação do

vizinho mais próximo. Com os dados de seis bacias hidrográficas, aplicou-se a técnica para quatro diferentes cenários onde alguns ou todos esses tipos de entradas foram utilizadas. A performance da técnica foi comparada com modelos que utilizam informações de entrada similar: o modelo linear simples (SLM), o modelo de perturbação linear baseado na sazonalidade (LPM) e modelo de perturbação linear do vizinho mais próximo (NNLPM). Os resultados com a RNA são promissores no contexto de modelagem chuva-vazão mas, como todos os modelos, tem resultados variáveis.

Os dados de nível de um rio são registrados num fluviômetro. Analisar e prever eventos futuros fundamentado nesses registros é uma tarefa difícil porque várias variáveis como chuva, infiltração e características do solo influenciam na altura do rio de uma maneira não linear. A previsão do nível de água num rio pode ser feito por métodos diretos ou indiretos. O método indireto inicialmente envolve a previsão da vazão ou por meio de um modelo chuva-vazão, ou pelo roteamento do fluxo observado num posto a montante do ponto em questão. A previsão de vazão deve antes ser convertida em nível por meio de uma curva chave, sendo necessário uma boa curva chave. A previsão de nível pelo método direto utiliza técnicas de correlação estatística. THIRUMALAI AH; DEO (1998) utilizaram uma RNA com este propósito, porque a técnica fornece soluções de um modelo livre e apropriada para a previsão de nível. Eles utilizaram dados de nível medidos em um posto à montante e também dados de séries históricas do posto em questão. A rede foi treinada usando três algoritmos: “backpropagation”, correlação cascata e gradiente conjugado. Em seguida fez-se uma comparação entre eles. Os resultados mostraram que é possível fazer previsão de nível em tempo real através das RNA's, e que as boas correlações entre os valores de nível observados e os da saída da rede são encontrados independentes do algoritmo de treinamento. E por último, uma rede dinamicamente adaptativa produz previsão de nível mais satisfatória que uma não adaptativa.

YANG et al. (1999) apresentaram um procedimento para integração de três modelos para a previsão de enchente. Os modelos utilizados foram a função de transferência linear (LTF), modelo auto regressivo integrado de média móvel (ARIMA) e o modelo de redes neurais (RNA). Depois de feito o treinamento os três modelos

foram comparados. Esse procedimento de integração é um novo procedimento para previsão de enchentes. Os resultados demonstraram que esse procedimento não somente tem uma estrutura simples, mas também não incluem hipóteses anteriores. Sendo considerado como apropriado para previsão de vazão.

A estimativa de chuva por radar é obtida por meio da relação do fator de refletividade. As relações usadas para obter a chuva dependem dos parâmetros do radar e da chuva média. XIAO; CHANDRASEKAR (1995), utilizaram RNA para obter a estimativa de chuva sem considerar qualquer relação ZxR . A técnica de RNA mapeou diretamente os múltiplos parâmetros do radar com as medidas de pluviômetro. A rede aproximou as relações de entradas-saídas baseando-se no grupo de medidas de radar e pluviômetro por meio de pesos. Então quando a rede conseguiu treinar adequadamente os dados ela pode generalizar as relações para novos conjuntos de dados.

No Brasil, Pernambuco foi o primeiro Estado a reunir um grupo de pesquisa nesta área, e o professor Clylton Galamba Fernandes, da Universidade Federal de Pernambuco (UFPE), há exatos 20 anos foi o primeiro brasileiro a defender uma tese de doutorado em redes neurais artificiais. As primeiras dissertações de mestrado brasileiras em redes neurais foram defendidas no Departamento de Informática da UFPE.

O gerenciamento das águas nos grandes reservatórios do Brasil é de responsabilidade do setor elétrico devido ao fato da energia elétrica gerada no país ser principalmente de origem hidroelétrica. A boa previsão de vazões é fundamental para garantir a operação adequada destes reservatórios, para minimizar prejuízos de ordem social, política e econômica das empresas do setor. Até recentemente, os modelos estocásticos para análise de séries temporais baseados principalmente na metodologia de BOX; JENKINS (1976) tem sido utilizados pelo Setor Elétrico Brasileiro.

BALLINI et al (1997) utilizaram a RNA e comparam os resultados ao método de Box-Jenkins. Eles utilizaram dados de vazão mensal de Furnas, Itumbiara e Sobradinho. Os resultados indicam a importância da padronização das séries temporais, mostrando as vantagens dos modelos de RNA quando esta não é realizada. Porém o desempenho das redes neurais é afetada por fatores como a topologia, os parâmetros de treinamento e

a natureza das séries temporais. TANG; FISHWICK (1991), demonstram que existem uma arquitetura de camadas escondidas ótima para cada tipo diferente de série temporal. Portanto, BALLINI et al. (1997) utilizaram o algoritmo “backpropagation” e trabalharam com duas abordagens para a previsão de vazões médias mensais. Numa primeira abordagem, a série de dados originais foi padronizada removendo a média e o desvio padrão sazonal e explorando assim a estrutura das funções de autocorrelação e autocorrelação parcial da série padronizada para determinar as entradas da rede. Na Segunda, explorou a estrutura das funções de autocorrelação e autocorrelação parcial da série original para definir as entradas da rede. Com isto a rede foi treinada para “aprender” e também reconhecer a sazonalidade supostamente estocástica.

A maior parte do tempo gasto na montagem de uma RNA é no processo de identificação de uma melhor estrutura (topologia), e no treinamento. Determinar uma boa estrutura é um caminho para diminuir esse tempo. KADOWAKI et al. (1997) observaram que existe uma relação entre a estrutura de autocorrelação da série temporal e a melhor escolha do número dos nós de entrada de uma rede neural. Com isto conseguiram propor uma metodologia para a determinação do número de entradas da RNA utilizada na previsão de vazões médias mensais, baseada em estudos das funções de autocorrelação (*f.a.c.*) e autocorrelação parcial (*f.a.c.p.*) dos dados históricos de vazões. Com alguns testes verificaram que a RNA é capaz de competir com os métodos convencionais como o de Box-Jenkins. Observaram que é relativamente mais fácil escolher um modelo de rede neural do que construir um modelo de Box-Jenkins.

A previsão de vazão para um posto fluviométrico em instantes de tempo posteriores $(t+1)$, $(t+2)$, ..., $(t+r)$ a partir de dados diários em (t) , e dados em instantes de tempo anteriores $(t-1)$, $(t-2)$, ..., $(t-k)$ de n postos à montante do posto, utilizando um critério em que a diferença entre o previsto e o observado deva ser menor do que um determinado valor, é um problema em hidrologia. Para este problema, SOUZA et al. (1995) utilizaram RNA definindo duas arquiteturas de rede. Na primeira a rede foi totalmente conectada, isto é, cada neurônio possuía conexões com cada um dos neurônios da camada anterior. Na Segunda, utilizou-se uma arquitetura onde cada conjunto de entrada foi conectado a um neurônio linear, obtendo desta maneira entradas conectadas a neurônios lineares e estes conectados a uma camada de neurônios não

lineares de tamanho variável. A função de transferência utilizada em ambas as arquiteturas foi a função sigmóide do tipo tangente hiperbólica (CARVALHO et al. 1998). Neste trabalho concluíram que a RNA é altamente eficiente para o mapeamento de problemas não lineares, podendo ser uma vantagem sobre os métodos estatísticos.

VALENÇA (1997) fez uma análise da aplicação de redes neurais perceptron de múltiplas camadas na simulação de transformação de chuva em vazão e na previsão de vazões médias mensais. Os resultados obtidos com redes neurais foram comparados com resultados obtidos de modelos tradicionais utilizando-se as vazões médias calculadas. O processo chuva-vazão utilizou o coeficiente de correlação e a previsão vazão-vazão, o erro percentual médio absoluto. VALENÇA concluiu que a grande vantagem da técnica de RNA está na sua versatilidade de permitir, no processo chuva-vazão, a incorporação da representatividade de cada posto pluviométrico em vez de se trabalhar com chuva média. Outro aspecto foi a possibilidade de considerar a regionalização levando-se em conta aspectos diversos da bacia, tais como: área da bacia, declividade, pluviometria média, coeficientes de forma da bacia, tipo de solo, etc. Na previsão mensal de vazão-vazão os resultados também comprovam a eficácia da técnica.

SARMENTO (1996) demonstra a possibilidade do uso da técnica de RNA na modelagem de variáveis hidrológicas mostrando duas aplicações. A primeira consiste na simulação da relação chuva-vazão mensal numa bacia da região semi-árida do Nordeste do Brasil, e a segunda na previsão de vazões médias diárias com intervalos de 1 e 2 dias fazendo uso das séries fluviométricas de uma bacia na região central da Alemanha. A série histórica de vazões utilizada na primeira aplicação foi dividida em duas sub-séries, sendo uma usada para treinamento e a outra para validação da rede. Os resultados obtidos da validação da rede foram comparados com os resultados da calibração de um modelo chuva-vazão identificado como MODHAC (LANNA; SCHWARZBACH, 1988). Na segunda aplicação, as vazões médias diárias previstas com intervalos de 1 e 2 dias se fundamentou nas vazões médias diárias registradas em dois postos localizados à montante, e a vazão no próprio posto para o qual se realizou a previsão. Sarmento concluiu que as RNA's devem ser usadas na modelagem de fenômenos naturais nos casos para os quais não se dispõe de uma formulação matemática explícita, capaz de reproduzir as relações entre as diversas variáveis envolvidas. E que para aplicação de

RNA na transformação de chuva-vazão em regiões semi-áridas a extensão da série requerida para a fase de treinamento da rede deve ser bastante superior àquelas que seria adequadas para bacias de rios perene.

BALLINI (1996) realizou estudos relativos à previsão de vazão em tempo real, concentrando-se no uso de duas RNA: a “Rede de Kohonen” e Rede Multicamadas com algoritmo “back-propagation”. Estas redes foram utilizadas para o reconhecimento das informações relativas aos dados de precipitação e vazão a serem recuperadas para realização das previsões de vazões diárias, observando-se qual era o potencial de utilização das duas redes. O Modelo de Kohonen foi utilizado devido ao fato desta rede utilizar o Método dos Vizinhos mais Próximos. Realizou-se neste trabalho uma análise comparativa dos resultados obtido pelo Modelo de Kohonen com resultados disponíveis pela implementação do Método dos Vizinhos mais Próximos. Também realizou uma análise comparativa dos resultados obtidos pela Rede Multicamadas e o Método dos Vizinhos mais Próximos. Com base nos resultados obtidos pelas rede de Kohonen e a Rede Multicamadas uma outra análise comparativa foi realizada para avaliar o desempenho de ambas na tarefa de previsão chuva-vazão. Os resultados mostraram que o Método dos Vizinhos Mais Próximo e a Rede Multi-Camadas apresentaram uma performance superior a Rede de Kohonen para previsão chuva-vazão.

3 – MATERIAIS E MÉTODOS

3.1 – REDES NEURAIS ARTIFICIAIS

O cérebro é um processador de informações altamente complexo, não linear e paralelo. A capacidade de organização dos neurônios faz com que seu desempenho no reconhecimento de padrões e percepção sejam maior do que o mais rápido computador hoje existente, ainda que, sua velocidade de processamento seja relativamente baixa comparada àquele.

Enquanto a maioria dos computadores operam de modo seqüencial, proporcionando maior eficiência na resolução de tarefas nas quais devem ser seguidas etapas, o cérebro humano funciona de modo paralelo, e por seus neurônios estarem interligados entre si é muito mais eficiente na resolução de tarefas com muitas variáveis.

Nos últimos anos, vêm sendo desenvolvidos modelos matemáticos que procuram imitar o funcionamento do cérebro humano, sendo que o desenvolvimento destes modelos tem por objetivo produzir alguma forma de inteligência artificial. Os modelos neurais procuram aproximar o processamento dos computadores ao do cérebro. As redes neurais possuem um grau de interconexão similar à estrutura do cérebro. No computador convencional, a informação é transferida de forma que haja um relacionamento do tempo com o sinal de sincronismo.

Neste capítulo faz-se um paralelo entre o cérebro e o computador. A partir do neurônio biológico, no qual as redes neurais artificiais se baseiam, o neurônio artificial será apresentado. Na seqüência, conceitos básicos sobre as Redes Neurais Artificiais (*RNA*) e sua modelagem serão apresentados.

3.1.1 - COMPARAÇÃO ENTRE O SISTEMA NERVOSO CENTRAL (SNC - CÉREBRO) E O COMPUTADOR

Quando os computadores eletrônicos foram desenvolvidos, percebeu-se que esses tinham muitas das características do SNC humano. O computador tem um circuito de entrada similar à porção sensorial do SNC e circuitos de saída similares à porção motora do SNC. Nas vias de condução entre as entradas e saídas, estão os mecanismos para executar diferentes tipos de computações.

Segundo GUYTON; HALL (1997), nos computadores simples, os sinais de saída são controlados diretamente pelos sinais de entrada, operando de um modo semelhante ao dos reflexos simples da medula espinhal humana. Nos computadores mais complexos, a saída é determinada tanto pelos sinais de entrada quanto pelas informações que já foram armazenadas na memória do computador, o que é análogo aos mecanismos dos reflexos e aos mecanismos do processamento de nosso sistema nervoso superior. Além disso, à medida que os computadores se tornaram mais complexos, foi necessário acrescentar outra unidade, chamada de *unidade processadora central*, que determina a seqüência de todas as operações. Esta unidade é análoga ao mecanismo existente em nosso cérebro que nos permite dirigir a atenção primeiro a um pensamento ou sensação ou atividade motora, depois a outro, e assim por diante, até que ocorram seqüências complexas de pensamento ou ação.

A figura 3.1 apresenta um esquema simplificado de um computador moderno. Este esquema se assemelha ao SNC. Os componentes básicos de um computador comum são análogos aos do SNC humano e, portanto, o cérebro é basicamente um computador que continuamente seleciona informações sensoriais e as utiliza juntamente com as informações armazenadas para computar o curso diário da atividade corporal.

Figura 3.1: Esquema simplificado de um computador eletrônico mostrando os componentes básicos e suas inter-relações (Adaptado de GUYTON; HALL, 1997).

A tabela 3.1 mostra uma comparação entre o cérebro humano e o computador. O sistema nervoso é formado por cerca de 100 bilhões de neurônios, onde cada neurônio comunica com até 10 mil outros. Sua resposta pode ser modificada dependendo do comportamento das ações.

Parâmetros	Cérebro	Computador
Material	Orgânico	Metal e plástico
Velocidade	Milisegundos	Nanosegundos
Eficiência Energética	10^{-16} J/operação/s	10^{-6} J/operação/s
Tipo de Processamento	Paralelo	Sequencial
Armazenamento	Adaptativo	Estático
Controle de Processos	Distribuído	Centralizado
Número de elementos processados	10^{11} à 10^{14}	10^5 à 10^6
Ligações entre elementos processados	10.000	<10

Tabela 3.1: Quadro comparativo entre o cérebro humano e o computador. (Fonte TAFNER et al, 1996)

Segundo CARVALHO FILHO; MARAR (1993), a dificuldade de compreender o sistema nervoso é milhões de vezes superior à do funcionamento dos computadores mais avançados existentes. Uma vez que os processos que ocorrem a nível biológico apresentam um grande número de variáveis correlacionados de forma corporal, provocando uma explosão exponencial de possibilidades do comportamento neuronal, fazendo com que os sistemas biológicos apresentem uma aparência não determinística.

Os computadores convencionais são adequados para a realização de cálculos e processos seqüenciais. Sendo que eles são mais apropriados para realizar cálculos do que os seres humanos. Por outro lado, os seres humanos realizam com facilidade tarefas como o reconhecimento de imagens e faces, leitura de manuscritos ou a análise de cenas.

Os computadores que se utilizam dos sistemas de inteligência artificial, buscam resolver problemas de reconhecimento de padrões de fácil processamento tal como o neurofisiológico. Assim, os modelos neurais visam aproximar o processamento dos computadores ao do cérebro humano. Com um grau de interconexão similar a estrutura do cérebro. A tabela 3.2 mostra uma comparação entre o computador e as redes neurais.

Computadores	Neurocomputadores
Executa programas	Aprende
Executa operações lógicas	Executa operações não lógicas, transformações, comparações
Depende do modelo ou do programador	Descobre as relações ou regras dos dados e exemplos
Testa uma hipótese por vez	Testa todas as possibilidades em paralelo

Tabela 3.2: Quadro comparativo entre computadores e neurocomputadores (Fonte TAFNER et al, 1996).

3.1.2. - NEURÔNIO BIOLÓGICO

O sistema nervoso possui uma vasta complexidade de ações e de controle. Ele recebe milhões de *bits* de informações dos diferentes órgãos sensoriais e os integram para determinar a resposta a dada pelo corpo. Ele é formado por um conjunto muito complexo: *os neurônios*. Esses têm um papel essencial na determinação do funcionamento, comportamento do corpo humano e raciocínio; todas as funções e movimentos do organismo são determinadas por estas pequenas células.

Estima-se que o sistema nervoso central possui cerca de 100 bilhões de neurônios interligados (GUYTON; HALL, 1997) numa rede, capaz de processar milhões de informações e realizar cerca de 60 trilhões de ligações sinápticas. As sinapses transmitem estímulos por todo o corpo humano. Esta rede permite o processamento e armazenamento de grande quantidade de informação.

A célula nervosa é constituída de três partes principais: *corpo celular ou soma*; *dendritos* (semelhantes aos galhos de uma árvore) e *axônio* (um prologamento fino e longo). Estes componentes são mostrados na figura 3.2. O corpo celular ou *soma* é responsável por coletar e combinar informações vindas de outros neurônios. Dele saem ramificações que são os *dendritos*. Os dendritos, por sua vez, recebem os estímulos transmitidos (impulsos nervosos) de outros neurônios e os conduzem ao corpo celular. Finalmente, o *axônio* é uma fibra tubular que pode medir até alguns metros, e é responsável por transmitir os estímulos para outras células.

Figura 3.2: Componentes de um neurônio (Fonte: OSÓRIO; VIEIRA, 1999)

Os neurônios estão conectados uns aos outros através de sinapses. Os sinais entram no neurônio através de sinapses nos dendritos neuronais ou no corpo celular. O sinal de saída trafega através de um único axônio que deixa o neurônio. O axônio tem muitos ramos separados para outras partes do sistema nervoso ou para a periferia do corpo. Uma característica fundamental da maioria das sinapses é a propagação do sinal numa única direção. Isto permite que os sinais sejam conduzidos nas direções adequadas ao desempenho das funções nervosas necessárias. O conjunto entre os neurônios e as sinapses formam uma grande rede, denominada de rede neural.

A figura 3.3 mostra a comunicação de dois neurônios através da sinapse. Observa-se que a sinapse é o ponto de junção de um neurônio com um outro. Portanto, é um elemento importante para o controle da transmissão de sinais, ou seja, é a região onde os impulsos nervosos são transmitidos entre dois ou mais neurônios. Ressalta-se que as sinapses determinam as direções em que os sinais nervosos se movem. Algumas sinapses transmitem sinais de um neurônio para um outro com maior ou menor facilidade. Assim, as sinapses desempenham uma ação seletiva, freqüentemente

bloqueando os sinais fracos e permitindo que sinais fortes passem, selecionando e amplificando certos sinais fracos e canalizando os sinais em várias direções.

Figura 3.3: Junção de dois neurônios através da sinapse.

A comunicação é realizada através de impulsos. Um impulso recebido por um neurônio A é processado e, ultrapassado um limite de ação, dispara um segundo impulso, que produz uma substância neurotransmissora. Esta flui do corpo celular para o axônio que pode estar conectado a um dendrito de um outro neurônio.

O impulso nervoso é a transmissão de um sinal codificado de um dado estímulo ao longo da membrana do neurônio. Dois tipos de fenômenos estão envolvidos no processamento do impulso nervoso: *elétrico e químico*. Eventos elétricos propagam um sinal dentro do neurônio por meio de canais diretos conduzindo os impulsos elétricos de uma célula para a próxima, transmitindo os sinais elétricos em qualquer direção. Os processos químicos transmitem o sinal de um neurônio a outro ou a uma célula muscular. Os processos químicos ocorrem no fim do axônio, ou seja, na sinapse. O axônio libera substâncias químicas que são os neurotransmissores, os quais se unem a receptores químicos na membrana do neurônio seguinte. Esses transmissores por sua vez age sobre as proteínas receptoras na membrana do próximo neurônio para excitar, inibi-lo ou modificar sua sensibilidade de alguma maneira. Ao contrário do impulso elétricos, os impulsos químicos transmitem os sinais sempre em uma única direção isto é, de um neurônio que secreta o transmissor, chamado de neurônio pré-sináptico, para o neurônio sobre o qual age o transmissor, chamado de neurônio pós-sináptico.

A membrana dos neurônios podem produzir e transmitir sinais elétricos e químicos. Esta membrana contém proteínas com funções específicas de, por exemplo, mover íons, acelerar reações químicas. A membrana que envolve o exterior do corpo do neurônio gera impulsos nervosos (elétricos), uma função vital do sistema nervoso, e central à sua capacidade computacional. O corpo, por sua vez, combina os sinais recebidos e, se o valor resultante for acima do limiar de excitação do neurônio, um impulso elétrico é produzido e propagado através do axônio para os neurônios seguinte.

O neurônio pode controlar a frequência de pulsos, aumentando ou diminuindo a polaridade na membrana pós-sináptica, inibindo ou excitando a geração dos pulsos num outro neurônio. Esse controle determina o funcionamento, o comportamento e o raciocínio do ser humano.

O armazenamento de informação ou *memória* também está ligado a função das sinapses. Quando certos tipos de sinais sensoriais passam através de seqüências de sinapses, a transmissão destes ficam mais evidentes ou eficientes em pulsos subsequentes. Esse processo é denominado de *facilitação*. Então, uma vez que as lembranças tenham sido armazenadas no sistema nervoso, elas se tornam parte do mecanismo de processamento. Os processos de pensamento do cérebro comparam novas experiências sensoriais com as lembranças armazenadas, as lembranças ajudam a selecionar as novas informações sensoriais e a canalizá-las para dentro de áreas de armazenamento apropriadas para uso futuro ou para dentro de áreas motoras para causar respostas corporais imediatas (GUYTON; HALL, 1997).

Biologicamente, um neurônio passa adiante um estímulo conforme a intensidade dos estímulos recebidos provenientes dos neurônios que com ele estão conectados. No mundo artificial, o mesmo efeito é simulado, dentro das possibilidades tecnológicas.

3.1.3 - NEURÔNIO ARTIFICIAL

O neurônio artificial possui diferentes nomes na bibliografia. Entre os sinônimos mais conhecidos encontram-se: *Elementos de Processamento (EPs)*, *Nó* e *Nodo*. Esses neurônios artificiais possuem uma estrutura e funcionamento muito similar aos neurônios biológicos.

O modelo de neurônio proposto por McCULLOCH; PITTS em 1943 é uma simplificação do que se sabia à respeito do neurônio biológico naquela época. Eles interpretaram o funcionamento do neurônio biológico como sendo um circuito de entradas binárias combinadas por uma soma ponderada (com pesos) produzindo uma entrada efetiva.

A figura 3.4 mostra a relação entre os neurônios biológicos e o modelo de neurônio artificial. Como pode ser visto na figura, os sinais de entradas $X_1, X_2, \dots, X_N$ representam os dendritos, os pesos $W_1, W_2, \dots, W_N$ são acoplados aos sinais de entrada, e representam os pesos sinápticos que têm a função de simular o comportamento das sinapses e podem ser positivos ou negativos. O efeito de uma sinapse particular i no neurônio pós-sináptico é dado pela ativação, onde os pesos determinam “em que grau” o neurônio deve considerar sinais de disparo que ocorrem naquela conexão. Então, o sinal passa através de uma função de ativação que determina a potência do sinal de saída. E por último, tem-se o sinal de saída que representa axônio/sinapses.

Figura 3.4: Neurônio Artificial (Fonte: OSÓRIO; VIEIRA, 1999).

Pode-se dizer que o neurônio artificial ou matemático é constituído basicamente, de uma função de combinação e uma função de transferência (ativação). A função de combinação, como o próprio nome diz, é responsável por compor a informação de entrada do neurônio. Se ela for linear, passa a representar a somatória das entradas ponderadas pelos respectivos pesos. Os pesos das conexões denominados de pesos sinápticos, é análogo ao neurônio biológico, e representam matematicamente o peso de cada informação com relação a um dado neurônio. A função de ativação é responsável pela intensidade do sinal a ser transmitido pelas conexões para os neurônios das camadas adjacentes. Tipicamente, o intervalo da amplitude normalizada de saída de um neurônio está no intervalo unitário (0,1) ou, alternativamente, (1,-1) (GALVÃO; VALENÇA, 1999). A figura 3.5 mostra a representação do modelo de neurônio artificial de McCULLOCH-PITTS (MCP) (1943), no qual se encontra presente uma função limiar (threshold) θ_k , que diminui a entrada líquida para a função de ativação.

Figura 3.5: Neurônio Artificial de McCULLOCH-PITTS (Adaptado de HAYKIN, 1994).

O neurônio biológico é ativado quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação (threshold). O corpo do neurônio, por sua vez, é emulado por um mecanismo simples que faz a soma dos valores da ativação recebidos pelo neurônio (soma ponderada), e decide se o neurônio será ativado, comparando a soma obtida ao limiar (threshold) do neurônio. No neurônio de MCP, a ativação do neurônio é obtida da aplicação de uma “função de ativação” e depende do valor da soma ponderada das suas entradas. Matematicamente, pode-se descrever o neurônio k por meio do seguinte par de equações:

$$\mu_k = \sum_{j=1}^p w_{kj} x_j \quad (3.1)$$

e

$$y_k = \varphi(\mu_k - \theta_k) \quad (3.2)$$

onde,

$x_1, x_2, \dots, x_p$ são os sinais de entrada;

$w_{k1}, w_{k2}, \dots, w_{kp}$ são os pesos sinápticos do neurônio k ;

μ_k é a saída da combinação linear;

θ_k é o limiar (threshold);

$\varphi(\cdot)$ é a função de ativação e

y_k é o sinal de saída do neurônio.

O modelo do neurônio MCP pode ser reformulado como na Figura 3.6. Nela, o efeito da função limiar é obtido por meio de duas modificações: (1) adiciona-se uma nova entrada de valor fixo $X_0 = +1$, e (2) adiciona-se um novo peso sináptico $W_{k0} = b_k$, sendo b_k o valor negativo do limiar.

Figura 3.6: Neurônio Artificial com Tendência.

Segundo CARVALHO et al (1998), as redes MCP com uma camada permitem apenas a implementação de funções linearmente separáveis; os pesos negativos representam disparos inibidores com pesos fixos e não ajustáveis. A combinação de diversos neurônios artificiais formam uma *rede de neurônios*, ou simplesmente uma *rede neural*. As entradas podem ser conectadas a muitos neurônios com vários pesos,

resultando numa série de saídas uma para cada neurônio. Essas conexões, em comparação com o sistema biológico, representam o contato dos dendritos com outros neurônio formando a sinapse. Pode-se verificar na figura 3.7 a analogia entre os neurônios naturais e artificiais.

Figura 3.7: Ilustração de neurônios naturais e artificiais (Fonte TAFNER et al, 1995).

3.1.4 - FUNÇÕES DE ATIVAÇÃO

A função de ativação ou de transferência, $\phi(\cdot)$ define o nível de ativação do sinal de entrada, ou seja, tem a finalidade de calcular um novo estado de ativação para o elemento de processamento (EP). A função de transferência converte a somatória da ativação das entradas em ativação de saída. Esta função diferencia a decisão neural baseada no potencial interno do neurônio e determina o valor a ser enviado aos demais neurônios. As funções de ativação mais utilizadas são mostradas na tabela 3.3 e na figura 3.7.

FUNÇÃO	EQUAÇÃO
LINEAR	$\varphi(v) = kv$, onde $k = \text{constante}$
RAMPA	$\varphi(v) = \begin{cases} 1, \forall v \geq 1 \\ v, \forall v < 1 \\ -1, \forall v \leq -1 \end{cases}$
DEGRAU (THRESHOLD)	$\varphi(v) = \begin{cases} 1, \forall v \geq 0 \\ 0 \forall v < 0 \end{cases}$
GUASSIANA	$\varphi(v) = e^{-v^2}$
LOGÍSTICA (SIGMÓIDE)	$\varphi(v) = \frac{1}{1 + e^{-v}}$
TANGENTE HIPERBÓLICA	$\varphi(v) = \tanh(v) = \frac{1 - e^{-2v}}{1 + e^{-2v}}$

Tabela 3.3: Funções de Ativação (transferências) mais utilizadas.

Figura 3.7: Funções de ativação ou transferências mais utilizadas: (a) Linear, (b) Rampa, (c) Degrau, (d) Guassiana, (e) Logística (Sigmóide) e (f) Tangente Hipérbolica .

A função Linear (Fig. 3.7a) é utilizada para armazenar entrada e saída de dados. A função Rampa (Fig. 3.7b) representa uma função não linear simplificada. Ela é linear entre os limites inferior e superior, e bloqueia os valores de saída superiores ao limite. A função Guassiana (Fig. 3.7d) utilizada para o treinamento de uma rede de função de base radial (RBF – Radial Basis Function).

As funções sigmóide (Fig. 3.7e e 3.7f), são caracterizadas pelo seu formato em S alongado, são funções semi-lineares, contínuas, monotonicamente crescentes e limitadas por assíntotas horizontais (LOESCH; SARI, 1996). É possível definir várias funções sigmóides. As funções sigmóides são utilizadas em diversos modelos. A função sigmóide e a função tangente hiperbólica são exemplos de função logística (Tab. 3.3). A função logística ou sigmóide é a função de ativação ou transferência mais utilizada em RNA (KOVÁCS, 1996). As funções sigmóide e tangente hiperbólica são deriváveis em toda sua extensão, são simétricas e possuem todas as derivadas contínuas, características importantes para demonstração de teoremas matemáticos. Dessa forma, tem-se um neurônio totalmente ativado ($\phi(\cdot)=1$), desativado ($\phi(\cdot)=0$) ou parcialmente ativado ($0<\phi(\cdot)<1$).

Pode-se fazer uma analogia com o sistema hidrológico, onde $\phi(\cdot) = 1$ corresponde ao escoamento completo da precipitação superficialmente, $\phi(\cdot) = 0$ equivale a infiltração completa, e ($0<\phi(\cdot)<1$) corresponde a situações não extremas (PEDROLLO, 1999).

3.1.5 - DEFINIÇÕES DE REDES NEURAIS

HAYKIN (1994) define RNA como:

“As RNAs são processadores massivamente paralelos e distribuídos que têm uma propensão natural para armazenar o conhecimento proveniente da

experiência e torná-lo útil. Desta forma, assemelhando-se ao cérebro humano em dois aspectos:

1. o conhecimento é adquirido pela rede através de um processo de aprendizado e
2. as intensidades das conexões entre neurônios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento”

CARVALHO et al (1998) definiram RNA como sendo sistemas paralelos distribuídos compostos por unidades de processamento simples (EP's) que computam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos que armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. A solução de problemas com RNA passa inicialmente por uma fase de *aprendizagem*, onde um conjunto de exemplos é apresentado para a rede, que extrai automaticamente as características necessárias para representar a informação fornecida. Essas características são utilizadas posteriormente para gerar respostas para o problema.

GALVÃO; VALENÇA (1999) definiram RNA como um sistema constituído por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas (uma camada de entrada, uma camada ou várias intermediárias e uma de saída) e são responsáveis pela não-linearidade da rede, por meio do processamento interno de certas funções matemáticas.

3.1.6 - ARQUITETURAS DA REDE NEURAL

A elaboração de uma RNA depende do tipo de problema. Assim, a arquitetura da RNA restringe o tipo de aplicação da mesma, e é determinada pelo:

- número de camadas da rede;
- número de nós em cada camada;
- tipo de conexão entre os nós e
- topologia da rede.

3.1.6.1 - Número de Camadas da Rede Neural

Quanto ao número de camadas as redes podem ser:

- 1) **Redes de Camada Única:** Existe apenas um EP entre qualquer entrada e qualquer saída da rede (Fig. 3.8). Essa rede recebe tal denominação pois a camada de entrada do EP de origem não é levada em consideração porque nenhum cálculo é realizado nesta camada.

Um exemplo de rede de camada única é a *Memória Associativa Linear* (HAYKIN, 1994). Nesta aplicação, a rede associa um padrão de entrada (vetor) a um de saída, e a informação é armazenada na rede por virtude das modificações realizadas nos pesos sinápticos da rede.

Figura 3.8: Rede Neural de camada única (Adaptado de HAYKIN, 1994).

2) **Redes de Múltiplas Camadas:** Existe mais de um neurônio entre uma entrada e uma saída da rede (Fig.3.9).

Figura 3.9: Rede de Múltiplas Camadas (Adaptado de HAYKIN, 1994).

Geralmente os EP's são organizados em camadas, e essas camadas podem ser de três tipos:

- **Camada de Entrada:** responsável pela distribuição da informação para as camadas intermediárias escondidas, recebida do meio externo, ou seja, onde os padrões são apresentados;
- **Camadas Intermediárias ou Escondidas:** onde ocorrem o processamento, por meio das funções de combinação e ativação. Portanto, nesta camada é onde é realizada a maior parte do processamento, através das conexões ponderadas. Podem ser consideradas como extratoras de características, ou seja, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa do problema;
- **Camada de Saída:** responsável pela resposta da rede, onde o resultado final é apresentado. Ela recebe os estímulos da camada intermediária e constrói o padrão de resposta.

A Figura 3.9 representa uma rede que possui 4 EP's na camada de entrada, 4 EP's na camada intermediária e 2 EP's na camada de saída. O número de neurônios e camadas em uma dada rede depende do problema a ser resolvido.

3.1.6.2 - Tipos de Conexão

Os EP's podem ter conexões do tipo:

- 1) ***Feed-forward ou acíclica:*** a passagem do sinal pela rede é unidirecional. Cada EP de uma camada recebe suas entradas vindas à partir de uma camada precedente, e envia seus sinais de saída em direção a camada seguinte. Portanto, a saída de um neurônio na *i-ésima* camada da rede não pode ser usada como entrada do EP em camadas de índice menor ou igual a *i*. As redes feed-forward são referenciadas como sistemas de mapeamento não-linear estático instantâneo (LOKE, 1995).
- 2) ***Feedback ou cíclica:*** a passagem do sinal pela rede é feito através de caminhos fechados ou loops. Há fluxo de informações para camadas anteriores e comunicação lateral. Os EP's são conectados diretamente às entradas externas. Estas unidades servem também de saídas da rede. Portanto, a saída de algum neurônio na *i-ésima* camada da rede é usada como entrada dos EP's em camadas de índice menor ou igual a *i*. As redes feedback são referenciadas como sistemas não-lineares dinâmicos (LOKE, 1995).

As redes podem também ser classificadas quanto sua conectividade:

- ***Rede fracamente (ou parcialmente) conectada:*** guarda sua estrutura distinta (LOESCH; SARI, 1996);
- ***Rede completamente conectada:*** criada pela fusão de duas ou mais redes dentro de uma nova estrutura. Este processo produz uma rede híbrida (LOESCH; SARI, 1996) e pode ser tratada como uma rede simples.

Os resultados ou generalizações da RNA dependem da quantidade de informações sobre o problema a ser resolvido. Então, é importante a definição de algoritmos que não somente otimizem os pesos para uma dada arquitetura, mas também

otimizem a própria arquitetura. Isso significa, em particular, a otimização do número de camadas e do número de EP's por camadas.

3.1.7 - APRENDIZADO

As Redes Neurais Artificiais *aprendem* com seu ambiente e melhoram seu desempenho. A solução de um problemas por meio de RNA passa primeiramente pela fase de *aprendizagem* onde a rede extrai informações relevantes de padrões de informação apresentados gerando uma representação própria do problema. Isso ocorre por meio de um processo iterativo de ajustes aplicado a seus pesos, o *treinamento*.

O aprendizado ocorre quando a rede obtém uma solução generalizada para uma classe de problemas. Esta generalização é obtida por meio de um conjunto de regras bem definidas para a solução de um problema, onde a rede “*assimila*” uma determinada função. Estas regras são denominadas de *algoritmo de aprendizado ou de treinamento*. Existem muitos tipos de algoritmos de treinamento específicos para determinados modelos de redes neurais, cada qual com suas vantagens e desvantagens. Esses algoritmos basicamente diferem entre si no ajuste dos pesos.

Uma definição geral de aprendizado no contexto de RNA pode ser expressa da seguinte forma (HAYKIN, 1994):

“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, sendo o tipo específico de aprendizagem realizada definido pela maneira particular como ocorrem os ajustes realizados nos parâmetros.”

Diversos métodos de treinamento de redes foram desenvolvidos, podendo ser agrupados em paradigmas de aprendizado. O aprendizado é classificado de acordo com seu ambiente de funcionamento. Nesse contexto existem os seguintes paradigmas de

aprendizado: *Aprendizado Supervisionado, Não Supervisionado, Por Reforço e Por Competição*. Algumas regras de aprendizado são (HAYKIN, 1994; CARVALHO et al, 1998): *correção de erros, aprendizado hebbiano, aprendizado de Boltzmann e modelo de Kohonem*.

- ***Aprendizado Supervisionado:***

Um agente externo é utilizado para treinar a RNA, similar a um professor que indica a resposta para o padrão de entrada. Com o objetivo de ajustar os parâmetros da rede de maneira que, a rede encontre uma relação entre os pares de entrada-saída. A figura 3.10 ilustra o mecanismo de aprendizado supervisionado. A rede deve possuir pares de entrada e saída, ou seja, um conjunto de entrada e um de saída. Para cada entrada verifica-se a saída obtida, gerada a partir dos cálculos com os erros que a rede possui, comparando-a a saída desejada. Esse procedimento é realizado até que os pesos da rede armazenem o conhecimento desejado. Essa treino iterativo com todo o conjunto de entrada e saída prossegue até que a taxa de acerto seja satisfatória. Esta técnica produz resultados satisfatórios em aplicações reais.

O aprendizado supervisionado depende do professor, sem o qual novas estratégias e situações não são assimiladas. A *regra delta* e o algoritmo *Backpropagation* são os algoritmos mais utilizados no treinamento de redes múltiplas camadas (CARVALHO et al, 1998).

Figura 3.10: Aprendizado supervisionado (Adaptado de HAYKIN, 1994).

Há duas formas de aprendizado supervisionado:

- ❖ **Off-line:** Quando os dados do conjunto de treinamento não mudam. Uma vez obtida uma solução, esta deve permanecer fixa. Caso novos dados sejam acrescentados no conjunto de treinamento, um novo treinamento deve ser feito.
- ❖ **On-line:** Quando o conjunto de dados está em constante mudança, e a rede permanece em contínuo processo de adaptação.

- **Aprendizado Não Supervisionado:**

Conhecido também como auto-supervisionado. Ocorre quando não existe um agente externo, ou seja, sem o professor para indicar a resposta desejada para os padrões de entrada. Apesar da semelhança entre o aprendizado supervisionado com o aprendizado nos seres humanos, muitos dos sistemas biológicos ocorrem por meio da aprendizagem não supervisionada. Como exemplo, os estágios iniciais dos sistemas de visão e audição (CARVALHO et al, 1998). A figura 3.11 mostra o mecanismo do aprendizado não supervisionado. Para o treinamento da rede são necessários apenas os valores de entrada. Essas entradas são processadas pela rede de maneira que ela se organize e classifique, utilizando os seus próprios critérios. Esse tipo de rede utiliza os neurônios como classificadores e os dados de entrada como os elementos para classificação. O processo de classificação é feita pela rede neural e o seu algoritmo de aprendizado. A auto-organização demonstrada em redes neurais não supervisionadas envolve o processo de competição e o de cooperação entre os neurônios da rede. Muitos pesquisadores têm utilizado esse tipo de rede como detector de características, por causa da sua capacidade de aprender a discriminar estímulos que ocorrem em partes espacialmente diferentes (TAFNER et al., 1996).

Figura 3.11: Aprendizado não supervisionado (Adapatado de HAYKIN, 1994).

O aprendizado não supervisionado possui várias formas. Por exemplo, a rede *feed-forward* com múltiplas camadas, onde a livre organização procede de camada por camada. Esse processo de aprendizado consiste em modificar repetidamente o peso sináptico de todas as conexões do sistema em resposta às entradas (CARVALHO et al, 1998).

- ***Aprendizado por Reforço:***

A resposta da rede é avaliada externamente. Esse aprendizado é um caso particular do aprendizado supervisionado. A diferença entre eles reside no conjunto de respostas desejadas (supervisionado) e na medida de desempenho (reforço). Neste caso, a informação de realimentação fornecida à rede é se a saída determinada está correta ou não. Ou seja, não se fornece a resposta correta para o padrão de entrada. O aprendizado por reforço (Fig. 3.12) é uma forma *on-line* de aprendizado onde se obtém um mapeamento da entrada-saída por meio de um processo de busca e erro desenvolvido para maximizar o índice de desempenho escalar.

Figura 3.12: Aprendizado por reforço supervisionado (Adaptado de Haykin, 1994).

- ***Aprendizado por Competição:***

Trata-se um caso particular do aprendizado não supervisionado. Como o próprio nome diz, os neurônios de saída da RNA competem entre si e apenas um neurônio é ativado. Portanto, neste aprendizado, dado um padrão de entrada, as unidades de saída disputam entre si para saber qual delas será ativada, similar a uma competição para decidir qual unidade de saída será saída ativada e terá seu peso atualizado no treinamento. Neste tipo de aprendizado apenas uma unidade prevalece, e é conhecido como “*winner takes all*”.

Um ciclo corresponde a utilização de todos N pares de entrada e saída do conjunto de treinamento, sendo que a correção dos pesos num ciclo pode ser executado de duas maneiras:

- 1) **Modo Padrão** : A correção dos pesos é realizada a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos se baseia somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.
- 2) **Modo Batch**: Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede. Seu erro médio é calculado e a partir deste erro se faz as correções do pesos.

3.1.8 - ARQUITETURAS DE REDE NEURAIIS ARTIFICIAIS

3.1.8.1 - Perceptron

O Perceptron, a rede neural pioneira, é a forma mais simples de RNA para classificar um tipo especial de padrão denominado de “*linearmente separável*”. Isto é, padrões que ficam em lados opostos de um hiperplano. Essa rede é capaz de classificar apenas padrões linearmente separáveis. Ou seja, padrões que caem em determinadas posições de um hiperplano na qual podem ser separados por uma linha reta (figura 3.13).

Figura 3.13: Padrões linearmente separáveis: dados que caem em lados opostos do hiperplano e podem ser separados por uma linha reta. Os padrões que não pertencem à determinada classe mas que foram a ela designados, são minoria e representam uma porcentagem de erro admissível (Fonte: BISHOP, 1995).

Basicamente, o Perceptron constitui de uma camada simples com ajuste dos pesos sinápticos e um limiar (Fig. 3.14). O algoritmo de ajuste dos parâmetros livres dessa rede foi desenvolvido por ROSENBLATT em 1962. ROSENBLATT provou que o algoritmo converge se o padrão (vetor) do treinamento for delineado por duas classes separáveis linearmente. O algoritmo também estabelece a superfície de separação na forma de um hiperplano entre as duas classes.

Figura 3.14: Perceptron uma camada (Adaptado HAYKIN, 1994).

Assim, o algoritmo de treinamento do modelo Perceptron permite distinguir classes no conjunto de entradas, se estas forem linearmente separáveis em termos de algum espaço de decisão. Os Perceptrons tomam decisões, e determinam se um padrão

de entrada se encaixa ou não em um certo padrão. O algoritmo de treinamento do Perceptron corresponde ao *Teorema de Convergência Perceptron*. Nesse teorema, ROSENBLATT postula que o Perceptron pode aprender tudo o que ele pode representar. Desta forma, há diferença entre *representação* e *aprendizagem*. A *representação* é a capacidade de uma rede simular uma função específica, enquanto que a *aprendizagem* requer a existência de um procedimento sistemático de ajuste dos pesos da rede para produzir esta função.

3.1.8.2 - Adaline

Elemento Linear Adaptativo o ADALINE (*Adaptive Linear Element*) foi estudado primeiramente por WIDROW; HOFF (1960). O Adaline é um classificador de padrão adaptativo que se utiliza de um algoritmo de aprendizado um pouco mais avançado que o Perceptron. Esse algoritmo recebe o nome de *LMS (Linear Mean Squared ou Regra dos Mínimos Quadrados)*. É conhecido também como *Regra Delta de WIDROW-HOFF* que minimiza a soma dos quadrados dos erros lineares sobre o conjunto de treinamento.

O objetivo do processo adaptativo no Adaline pode ser expresso como: *Dado um conjunto de padrões de entrada e uma saída desejada, encontra-se um conjunto ótimo de pesos sinápticos $w_1, w_2, \dots, w_p$, e o limiar θ , para minimizar o erro quadrático médio atual e_a .* A Figura 3.15 mostra um diagrama de blocos do Adaline. Observa-se nesta figura que o Adaline consiste de uma função de combinação linear, uma função de transferência de limites rígidos, e um mecanismo para ajuste dos pesos. As entradas $x_1, x_2, \dots, x_p$ variam entre -1 e $+1$ e são processadas pela função de combinação linear, e pela função de transferência de limites rígidos, que tem associado a ela um limiar θ , com limites entre 0 e $+1$. A função de transferência de limites rígidos é alimentado por uma saída desejada d , cujo valor está entre $+1$ e -1 . Os pesos $w_1, w_2, \dots, w_p$ e o limiar θ são ajustado com algoritmo LMS. A combinação linear da saída u , produzida pela resposta das entradas $x_1, x_2, \dots, x_p$, é subtraída da saída desejada d produzindo um erro e . O erro e é utilizado para atualizar o algoritmo LMS.

Figura 3.15: Diagrama de blocos do Adaline (Adaptado de HAYKIN, 1994)

A saída do Adaline é obtida pela passagem da saída da combinação linear u através da função de transferência de limite rígidos. Assim a saída é:

$$y = \begin{cases} +1 & \text{se } u \geq \theta \\ -1 & \text{se } u < \theta \end{cases} \quad (3.3)$$

Pode-se dizer que o modelo Adaline possui saídas binárias bipolares ($y \in [-1, +1]$) e tem seus pesos adaptados em função do erro de sua saída linear ($y = \sum_i w_i x_i$), antes da função de ativação, que é minimizada por meio de uma função custo, onde os pesos de entrada w_i são quadráticos.

Deste modo, o Adaline aprende usando uma lei de redução de erros LMS entre a saída atual e a saída desejada. O Perceptron usa uma diferença ponderada simples. Assim, o Adaline é obtido para uma saída linear do EP, enquanto o ajuste do Perceptron é obtido para saída do EP após a aplicação da função de ativação. Ou seja, o algoritmo do Perceptron é baseado no erro da saída não linear, já o Adaline na saída linear.

3.1.8.3 - Rede Perceptron Feedforward Multicamadas - MLP (Multi Layer Perceptron)

Como visto anteriormente, as redes de apenas uma camada (Perceptron), resolvem apenas problemas linearmente separáveis. MINSKY; PAPERT (1969) demonstraram que o Perceptron não resolvia problemas não linearmente separáveis. Em 1986, RUMELHART et al. (1986) desenvolveram o algoritmo de treinamento *backpropagation*, demonstrando que era possível treinar com eficiência redes com camadas intermediárias. Isto resultou no modelo de RNA mais utilizado atualmente, as Redes Perceptron MultiCamadas (MLP). Portanto, a MLP é uma extensão do Perceptron, mas com algumas particularidades.

Esta rede é utilizada no reconhecimento de padrões, filtragem de sinal, compressão de dados e comparação de padrões heteroassociativos, que associa um padrão a outro. As redes *feedforward multicamadas* possuem um melhor desempenho devido à passagem unidirecional do sinal pela rede. O processamento da informação ocorre no sentido progressivo através das interconexões entre os neurônios das camadas adjacentes. Além disso, estas redes podem ser utilizadas para classificação de padrões não linearmente separáveis (Fig. 3.16).

Figura 3.16: Padrões não linearmente separáveis: padrões que caem em determinadas posições do hiperplano que não podem ser separados por uma linha reta. Soluções não lineares, normalmente, apresentam percentuais de erro na classificação inferiores às soluções lineares para a grande maioria dos problemas (Fonte: BISHOP, 1995).

Uma rede neural *feedforward* típica é representada na Figura 3.17. Observa-se na figura uma camada de entrada, duas camadas escondidas e uma camada de saída. Neste tipo de rede pode-se ter uma ou mais camadas escondidas. Cada camada é plenamente interconectada à camada vizinha. A saída de cada EP, que não esteja na última camada propaga sua saída para todos os EPs da camada posterior.

Figura 3.17: Arquitetura Multicamadas Perceptron com duas camadas escondidas (Adaptada de HAYKIN, 1994).

Esta rede pode ser numa grande variedade de mapeamentos complexos. Isto porque os elementos de processamento das camadas escondidas aprendem a responder às características da entrada. Essas características se referem às correlações de atividades entre os diferentes EPs de entrada, possibilitando uma representação *abstrata* da informação de entrada nas camadas escondidas. Além da capacidade de abstração, a rede possui capacidade de *generalização*, sendo capaz de classificar corretamente um padrão complexo mesmo quando este não pertença ao conjunto de treinamento da rede.

O algoritmo *backpropagation* é utilizado para treinamento desta arquitetura. Durante o treinamento com esse algoritmo, a rede opera em uma seqüência de dois passos. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada á saída desejada

para esse padrão particular e o erro sejam calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado.

As redes que utilizam o *backpropagation* operam com uma variação da regra delta, denominada de *Regra Delta Generalizada*. Este algoritmo procura minimizar o erro obtido pela rede por meio do método do gradiente descendente. O objetivo deste gradiente é buscar um mínimo global. Sendo que, o mínimo global é considerado como um solução teórica ótima, pois apresenta o menor erro possível.

No treinamento de uma RNA complexa, a solução obtida pode não corresponder à global pois a função pode apresentar mínimos locais (Fig. 3.18). Quando o tipo de superfície de erro não é conhecida *a priori*, o algoritmo verifica uma grande quantidade de possibilidades até determinar a melhor solução. A taxa de aprendizado é um elemento muito importante neste processo, pois ela controla o tempo de aprendizado levando em conta a taxa de convergência entre a solução atual e o mínimo global. Portanto, o treinamento das redes multicamadas com *backpropagation* pode requerer um número excessivo de iterações, resultando em um tempo de treinamento consideravelmente longo. Uma maneira de otimizar a Regra Delta Generalizada é introduzir o termo “*momentum*”, que é uma constante que determina o efeito das mudanças passadas dos pesos na direção atual do movimento no espaço de pesos. E que tem por objetivo permitir o aumento da taxa de aprendizagem, sem que ocorram oscilações, bem como atuar no aumento da velocidade de convergência.

Figura 3.18: Mínimos locais (1 e 2) e o mínimo global (1).

As redes Perceptron multicamadas podem ser vistas como aproximadores universais de funções. As redes neurais multicamadas com uma única camada escondida e a função sigmóide podem aproximar qualquer função contínua arbitrária. (GALVÃO; VALENÇA, 1999).

Desta maneira, os passos necessários para o desenvolvimento de aplicação utilizando RNA são:

1. Coleta de dados;
2. Separar em conjunto de treinamento e verificação;
3. Configuração da rede;
4. Treinamento;
5. Verificação e
6. Integração da rede.

3.2 - ALGORITMO DE TREINAMENTO PARA REDES NEURAIIS MULTICAMADAS

Neste trabalho utilizou-se o *Linear Least Squares SIMplex* “LLSSIM”. Trata-se de um algoritmo híbrido para treinamento de RNA’s do tipo feedforward de três camadas. Este algoritmo foi HSU et al. (1995). O LLSSIM é uma combinação do algoritmo dos Mínimos Quadrados Linear e da otimização do algoritmo “Simplex” com inicialização múltiplas. Com isto, obtém-se os mínimos globais ou próximo do global, com poucas iterações. Além disto, o algoritmo utiliza uma partição do conjunto de pesos para implementar duas estratégias de treinamento, onde os pesos utilizados na entrada da camada escondida são calculados a partir de uma versão de múltiplas inicializações do algoritmo de otimização não linear “Simplex” (MSDS) (DUAN, et al., 1992). Os pesos da saída na camada escondida são calculados a partir da estimativa dos Mínimos Quadrados (LLS) (SCALERO; TEPEDELENLIOGLU, 1992). A partição de

pesos permite a redução do espaço de busca e, portanto, do processo de treinamento. O algoritmo Simplex melhora as características de busca global a partir de múltiplas entradas aleatórias evitando-se os mínimos locais (HSU et al., 1996).

Havendo m conjuntos de padrões de entrada-saída, com n_0 entradas, n_2 saídas e n_1 neurônios escondidos, num treinamento por cíclico (batch) (GUPTA et al, 1997), o padrão de entrada é representado por $[x_1(p), x_2(p), \dots, x_{n_0}(p)]^T$, a saída da rede por $[z_1(p), z_2(p), \dots, z_{n_2}(p)]^T$, e a saída alvo por $[t_1(p), t_2(p), \dots, t_{n_2}(p)]^T$. Então, a função a ser minimizada (função custo) pode ser expressa por:

$$F[w] = \frac{1}{2} \sum_{p=1}^m \sum_{k=1}^{n_2} (t_k(p) - z_k(p))^2 \quad (3.4)$$

onde,

$$z_k(p) = f\left(\sum_{j=0}^{n_1} w_{kj}^0 y_j(p)\right) \quad (3.5)$$

$$y_j(p) = f\left(\sum_{i=0}^{n_0} w_{ji}^h x_i(p)\right) \quad (3.6)$$

onde,

$x_i(p)$ representa o i -ésimo sinal de entrada do p -ésimo padrão;

x_0 é a tendência de entrada;

w_{ji}^h é o peso da entrada da camada escondida conectada a i -ésima entrada do j -ésimo neurônio escondido;

$y_j(p)$ representa a saída do j -ésimo neurônio da camada escondida;

w_{kj}^0 é o peso da saída da camada escondida conectado à resposta do j -ésimo neurônio escondido do k -ésimo neurônio de saída;

$z_k(p)$ representa a saída do k -ésimo neurônio de saída;

$t_k(p)$ é a saída alvo do p -ésimo padrão, e

$f(\cdot)$ é a função de transferência não linear, monótona e limitada entre 0 e 1.

A função custo pode ser reescrita como,

$$F[w] = \frac{1}{2} \sum_{p=1}^m \sum_{k=1}^{n_2} (t_k(p) - z_k(p))^2$$

$$= \frac{1}{2} \sum_{p=1}^m \sum_{k=1}^{n_2} \left[t_k(p) - f \left(\sum_{j=0}^{n_1} w_{kj}^0 f \left(\sum_{i=0}^{n_0} w_{ji}^h x_i(p) \right) \right) \right]^2 \quad (3.7)$$

e a função de transferência $f(.)$ é a função sigmóide na forma da função logística:

$$f(u) = \frac{1}{1 + \exp(-u)} \quad (3.8)$$

O objetivo do treinamento da rede é obter os pesos w_{ji}^h e w_{kj}^0 que minimizem o valor da função custo (3.7). A estratégia de treinamento do LLSSIM utiliza a divisão dos pesos em dois grupos, os pesos na entrada da camada escondida w_{ji}^h e os pesos na saída da camada escondida w_{kj}^0 . Define-se $TS_k(p)$ como sendo o valor do alvo p transformado pelo inverso da função logística do nó de saída k :

$$TS_k(p) = \ln \{ t_k(p) / [1 - t_k(p)] \} \quad (3.9)$$

Define-se a partir da equação acima uma nova função erro:

$$F[w] = \frac{1}{2} \sum_{p=1}^m \sum_{k=1}^{n_2} (TS_k(p) - s_k^o(p))^2$$

$$= \frac{1}{2} \sum_{p=1}^m \sum_{k=1}^{n_2} \left[TS_k(p) - \sum_{j=0}^{n_1} w_{kj}^0 f \left(\sum_{i=0}^{n_0} w_{ji}^h x_i(p) \right) \right]^2 \quad (3.10)$$

Nesta representação os alvos transformados $TS_k(p)$ são lineares em relação aos pesos da saída da camada escondida w_{kj}^0 , e os pesos da entrada da camada escondida são não linear w_{ji}^h . Assumindo que os valores dos pesos da entrada da camada escondida são conhecidos, os pesos ótimos da saída da camada escondida, condicionados a partir dos valores dos pesos de entrada da camada escondida podem ser calculados explicitamente usando o método dos mínimos quadrados linear (LLS)

fazendo a derivada da função F_l relativa aos pesos da camada escondida e igualando a zero, tem-se:

$$\frac{\partial F_l}{\partial w_{kj}^0} = - \sum_{p=1}^m (TS_k(p) - s_k^0(p)) y_j(p) = 0 \quad (3.11)$$

A equação acima pode ser reescrita como:

$$\begin{aligned} \sum_{p=1}^m TS_k(p) y_j(p) &= \sum_{p=1}^m \sum_{l=0}^{n_l} w_{kl}^0 y_l(p) y_j(p) \\ &= \sum_{p=1}^m y_j(p) \sum_{l=0}^{n_l} y_l(p) w_{kl}^0 \end{aligned} \quad (3.12)$$

Definindo-se:

$$R_{jl} = \sum_{p=1}^m \sum_{l=0}^{n_l} y_j(p) y_l(p) \quad (3.13)$$

$$Q_j = \sum_{p=1}^m TS_k(p) y_j(p) \quad (3.14)$$

Os pesos na saída da camada escondida, w_k^0 , são obtidos de um sistema de equações lineares:

$$w_k^0 = R^{-1} Q \quad (3.15)$$

onde,

$w_k^0 = [w_{k0}^0, w_{k1}^0, \dots, w_{kn1}^0]^T$ são os pesos condicionais ótimos para saída da camada escondida pois seus valores dependem dos valores selecionados pelos pesos de entrada da camada escondida.

A estrutura da RNA é utilizada para modelar processos não lineares que relacionam entradas e saídas, como por exemplo, a transformação da chuva sobre uma bacia em vazão num rio. O conjunto de dados de chuva e vazão utilizados foram normalizados de acordo com uma função sigmóide na faixa $[T_{\text{máx}}, T_{\text{min}}]$, usando a equação:

$$N_i = T_{\min} + \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} (T_{\max} - T_{\min}) \quad (3.16)$$

onde,

- N_i valor normalizado;
- X_i valor à normalizar;
- $X_{\min}$ valor mínimo do conjunto de dados;
- $X_{\max}$ valor máximo do conjunto de dados;
- $T_{\min}$ valor mínimo de normalização;
- $T_{\max}$ valor máximo de normalização e
- i tempo.

A série de precipitação foi normalizada entre [0 , 1] e a de vazão entre [0,1 , 0,9]. A vazão foi normalizada nesta faixa para evitar a saturação do sinal de saída da RNA (SMITH, 1993). A vazão de saída no instante t , $z(t)$, relaciona as entrada $x(t-j)$ e saídas $z(t-j)$ em instantes anteriores numa estrutura geral de modelo não linear:

$$z(t) = g_{non}(z(t-1), \dots, z(t-n_a), x(t-1), \dots, x(t-n_b)) + e(t) \quad (3.17)$$

onde,

- $g_{non}()$ é a função de mapeamento não linear;
- $e(t)$ é o mapeamento do erro à ser minimizado;
- n_a e n_b são os número de entradas e saídas em instantes de tempo anteriores que contribuem na saída atual e
- t é o tempo.

Esta estrutura recebe a notação de RNA (n_a, n_b, n_h, n_0) onde,
 $n_a + n_b$ é o número de nós na camada de entrada,
 n_h é o número de nós na camada escondida e
 n_0 é o número de nós na camada de saída.

Na identificação de um modelo de RNA, os valores de n_a , n_b e n_h devem ser selecionado, e os valores dos pesos da rede w_{ji}^h e w_{kj}^0 devem ser estimado de maneira que a previsão do erro seja minimizada.

3.3 - MODELOS AUTO-REGRESSIVOS

As séries temporais são conjuntos de observações feitas num determinado período de tempo. Em hidrologia, um conjunto de vazões medidas ou sintética de um rio é uma seqüência de números ou valores produzidos por um processo aleatório ao longo do tempo (FIERING; JACKSON, 1971).

As séries temporais podem ser discretas ou contínuas. A série temporal discreta, é obtida da amostragem de uma série temporal contínua onde os intervalos de tempo são igualmente espaçados (MORETTIN; TOLOI, 1981 e MORETTIN, 1982). As séries temporais podem ser descritas por modelos estocásticos, que utilizam leis de probabilidade. Um dos modelos utilizados para análise destas séries é o modelo **Auto-Regressivos (AR)**. O modelo AR é *paramétrico* e utilizado para *previsão e controle* de séries temporais.

Supõem-se, que a série temporal é estacionária, ou seja, aleatória no tempo com média constante, num equilíbrio estável (MORETTIN 1982). Em geral, o *i*th elemento de uma série temporal, x_i , é decomposto em partes:

$$x_i = d_i + e_i \quad (3.17)$$

onde,

d_i é a parte determinística, obtida de uma regra funcional exata proveniente de parâmetros e valores históricos. Geralmente d_i é função da vazão média, da variância das vazões e de vazões anteriores tais como x_{i-1} , x_{i-2} . O componente aleatório da equação (3.17) e_i , é um número aleatório obtido da amostra de um conjunto de números aleatórios com uma certa distribuição de probabilidade ou padrão. Assim, somente a parte determinística d_i é alterada no tempo. Considerando o modelo abaixo:

$$x_i = \phi_1 x_{i-1} + \phi_2 x_{i-2} + \dots + \phi_p x_{i-p} + a_i \quad (3.18)$$

onde,

$\phi_1, \phi_2, \dots, \phi_p$ são o conjunto finito de pesos e a_t um ruído branco.

Este processo definido pela equação (3.18) é conhecido como *processo auto-regressivo* de ordem p , ou simplesmente processo AR(p). Por exemplo, o processo auto-regressivo de primeira ordem ($p=1$), e o de segunda ordem ($p=2$):

$$\begin{aligned}x_i &= \phi_1 x_{i-1} + a_i \\x_i &= \phi_1 x_{i-1} + \phi_2 x_{i-2} + a_i\end{aligned}$$

O operador auto regressivo de ordem p é definido por:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) x_i = a_i,$$

então podemos escrever (3.18) como:

$$\phi(B) x_i = a_i \tag{3.19}$$

de modo que x_i só depende de x_{i-1} e do ruído no instante i , e é denominado de processo de MARKOV (FIERING; JACKSON, 1971). O processo AR(p) é estacionário (BOX; JENKINS, 1976) se $\phi(B) \neq 0$ possuir raízes fora do círculo unitário (MORETIN; TOLOI, 1982).

3.4 - ÁREA DE ESTUDO

A bacia do Rio Tamanduateí (Fig. 3.19), no leste do Estado de São Paulo, é um dos mais importantes tributários da Bacia do Alto Tietê. Ela está localizada na margem esquerda do Rio Tietê, na Região Metropolitana de São Paulo (RMSP) (DAEE, 1988), com sua cabeceira no município de Mauá, atravessa os municípios de Diadema, São Caetano do Sul e a zona leste e central da cidade de São Paulo até desaguar no Rio Tietê. O Ribeirão dos Meninos é seu principal tributário e nasce no município de São Bernardo do Campo, atravessa a cidade de Santo André e se conflui com o Rio Tamanduateí em São Caetano do Sul. A área de drenagem é de 310 Km². O tempo de concentração da bacia (TUCCI, 1994) é de 4 horas. Com mais de 80% de área urbanizada (CTO, 1997).

A área urbanizada da bacia se encontra próxima a foz, onde a topografia é bastante plana. A parte não urbanizada é constituída de solo argiloso. A canalização do rio na área urbanizada, foi projetada para uma vazão de pico de 485 m³s⁻¹ e um período de retorno de 500 anos (CTO, 1997).

Figura 3.19: Mapa de localização da Bacia do Rio Tamanduateí no Estado de São Paulo.

As cidades e os principais reservatórios da Bacia do Alto Tietê estão indicados por letras maiúsculas. A linha em abóbora indica o divisor d'água da Bacia do Rio Tamanduateí. A circunferência pontilhada indica a área de abrangência do radar.

3.5 - DADOS UTILIZADOS

3.5.1 - RADAR METEOROLÓGICO

RADAR é um acrônimo de *R*ADIO *D*ETECTION AND *R*ANGING, ou detecção de alvos e medida de distância por rádio. Os radares surgiram na Segunda Guerra Mundial para aplicações militares e depois começaram a ser utilizados para pesquisas na área de meteorologia.

O Radar é um dispositivo eletrônico que transmite um sinal eletromagnético, recebe de volta sinal de alvos e pode determinar vários aspectos dos mesmos, a partir das características dos sinais recebidos (RINEHART, 1994).

O radar é composto por quatro componentes básicos:

1. Transmissor onde o sinal de alta frequência é gerado;
2. Antena que envia e recebe os sinais;
3. Receptor que recebe, filtra e amplifica o sinal de retorno;
4. Sistema de Visualização que mostra na tela os alvos detectados.

O Radar Meteorológico é um sensor ativo que transmite pulsos de energia eletromagnética em intervalos de tempo regulares, concentrados em um feixe de pequena abertura através de uma antena rotativa. Os alvos iluminados pelo feixe do Radar podem absorver parte desta energia e irradiá-la em diversas direções. A fração da energia que retorna ao Radar é medida pelo receptor e, conhecendo-se o intervalo de tempo entre a emissão e retorno do eco, é possível determinar a distância do alvo.

O Radar Meteorológico permite a obtenção de medidas contínuas provenientes do retorno dos alvos em tempo real com alta resolução espacial. A potência de retorno esta relacionada com o espectro de gotas no volume iluminado e é denominado de

refletividade. A partir deste espectro, pode-se determinar a taxa de precipitação (mm h^{-1}), o conteúdo de água líquida (g m^{-2}) e fator de refletividade ($\text{mm}^6 \text{m}^{-3}$).

Para se estabelecer uma relação entre medidas do Radar Meteorológico e as medidas de precipitação, é necessário ter conhecimento da distribuição do tamanho de gotas contidas no volume iluminado pelo Radar. Um alvo meteorológico contendo um espectro de tamanho de gotas, distribuídas aleatoriamente dentro do volume iluminado pelo feixe do radar, produz uma refletividade (Z) dada por:

$$Z = \int_0^{\infty} N(D) D^6 dD = \sum D_i^6 \quad (3.21)$$

onde,

Z é a refletividade em mm^6/m^3 ;

N(D) é o número de gotas com diâmetro D.

A taxa de precipitação por unidade de tempo (R) é obtida da integração do espectro de gotas por unidade de área, por unidade de tempo dos volumes de cada gota (BATTAN, 1973), dada por:

$$R = \frac{\pi}{6} \int_0^{\infty} N(D) D^3 V_t(D) dD \quad (3.22)$$

onde:

$V_{(t)}$ é velocidade terminal das gotas de diâmetro D.

Então, a partir do espectro de gotas e das respectivas velocidades terminais das mesmas pode-se calcular a refletividade e a sua respectiva taxa de precipitação. MARSHALL; PALMER (1948) obtiveram uma relação entre as taxas de precipitação e a refletividade das mesmas a partir do espectro das gotas em sistemas de precipitação estratiformes, dada por:

$$Z = aR^b \quad (3.23)$$

onde,

R é a taxa de precipitação (mm h^{-1});

Z é a refletividade ($\text{mm}^6 \text{m}^{-3}$);

$a = 200$;

$b = 1,6$.

Os parâmetros a e b são constantes estimados. Existem dois métodos para determinar os valores de a e b ; o meteorológico e o estatístico. No método meteorológico, a taxa de precipitação R e a refletividade do radar Z são determinadas diretamente pela distribuição do tamanho de gotas, conforme as equações 3.21 e 3.22 sendo os valores de a e b calculados de Z e R . A relação não é uniforme, pois depende do número de gotas com diâmetro D . A relação $Z \times R$ de MARSHALL e PALMER (equação 3.23) foi obtida medindo-se a quantidade e o diâmetro das gotas, estimando-se a velocidade terminal (V_t) em função do diâmetro e ajustando-se uma função exponencial para a distribuição do tamanho de gotas.

O problema fundamental na estimativa de chuva com o Radar é determinar o espectro de gotas, pois dois espectros de gotas diferentes podem produzir a mesma refletividade, porém taxas de precipitações diferentes. Para longos intervalos de integração, as diferenças entre estimativas de chuva acumulada obtidas com diferentes relações Z - R é pequena devido à variação temporal do espectro de gotas.

3.5.2 – RADAR METEOROLÓGICO DE SÃO PAULO

O Radar Meteorológico de São Paulo está localizado na cabeceira da bacia do Alto Tietê junto à Barragem de Ponte Nova na divisa dos municípios de Salesópolis e Biritiba-Mirim no estado de São Paulo (Fig. 3.20), numa altitude de 916m (datum IGG) com máxima visada livre horizontal. Este ponto dista 100 km da cidade de São Paulo. As coordenadas geográficas da posição do Radar são $23^{\circ}36'07''\text{S}$ e $45^{\circ}58'40''\text{W}$. A área de monitoramento corresponde a um círculo de raio 180 Km.

Figura 3.20: A circunferência pontilhada indica a localização e a área de abrangência do radar de São Paulo em relação ao Estado. E mostra a localização da Bacia do Rio Tamanduateí na área de abrangência do radar.

As principais características do Radar Meteorológico de São Paulo estão descritas na tabela 3.4.

Diâmetro do refletor	4 m
Tipo do refletor	Parabólico
Ganho da antena	38 dBz
Largura do feixe	2°
Tipo de polarização	Horizontal
Elevação	- 4° a 90°
Rotação máxima em azimuth	6 rpm
Taxa de elevação máxima	18° s ⁻¹
Duração do pulso	1,6 µs
Potência de transmissão	650 kW
Frequência do transmissor	2,7 – 2,9 GHz (banda S)
Frequência de repetição do pulso	250 pps
Distância máxima quantificada	180 km
Taxa mínima de precipitação quantificada	0,50 mmh ⁻¹ (190 km)
Mínimo sinal detectável	18 dBz (190 km)

Tabela 3.4: Características do Radar Meteorológico de São Paulo (Adaptada FCTH, 1987)

O sistema computacional do radar utilizado neste trabalho controla automaticamente a antena e a aquisição dos dados do seu campo de refletividade. A cada 10 minutos faz-se uma varredura em azimute e elevação de até 30° num raio de 180 km. A varredura completa leva cerca de 4 minutos. A refletividade do radar é convertida em taxa de precipitação pela relação Z-R de MARSHALL e PALMER (1948).

A resolução espacial é de 2 km x 2 km. A área de cobertura do radar abrange o litoral sul paulista desde Iguape até Angra dos Reis no Rio de Janeiro, abrangendo também as cidades limítrofes de Miracatu, Sorocaba, Porto Feliz, Mogi-Guaçu, sul de Minas Gerais e o Vale do Paraíba.

Os produtos disponíveis são:

- Mapas CAPPI (Constant Altitude Plan Position Indicator) que apresentam taxas de precipitação nas altitudes entre 1,5 e 18 km, num raio de 180 km, com resolução de 2 km x 2km.
- Mapas de precipitação ACUMULADA; computadas por meio da medida das taxas de precipitação e acumulada no intervalo de tempo estabelecido num raio de 180 km.
- Mapas ECHO TOP – topo de nuvens com $0,5 \text{ mmh}^{-1}$.
- CORTE TRANSVERSAL (num dado azimute ou direção).
- Mapas de PREVISÃO – por extrapolação linear das taxas de precipitação.

Utilizou-se neste estudo os CAPPI's, na altitude de 3,0 km sobre a bacia do Rio Tamanduateí. A figura 3.21 mostra uma imagem de chuva acumulada de CAPPI do radar de São Paulo.

Figura 3.21: Distribuição espacial da chuva acumulada a partir dos CAPPI's do radar de São Paulo na altura de 3,0 km, em 07 de fevereiro de 1994 às 07h 03 min.

3.5.3 - DADOS DE RADAR

Os dados de chuva foram estimados a partir das medições da refletividade do radar por meio da relação Z-R de MARSHALL e PALMER. A chuva acumulada pode ser calculada da seguinte forma:

$$CA = \sum_{i=1}^n \frac{R}{6} \quad (3.24)$$

onde:

CA é a chuva acumulada;

R é a precipitação;

n é o número de dados de chuva acumulada e

1/6 é igual 10 min.

A chuva acumulada foi estimada em intervalos de 30 minutos sobre oito isócronas. Desta forma, os dados de entrada da RNA tem resolução temporal de 30 minutos e descretizados em 8 valores de precipitação. A bacia do Rio Tamanduateí foi referenciada nas coordenadas do radar meteorológico de São Paulo e subdividida em oito isócronas (Fig. 3.24). A região em estudo corresponde a aproximadamente 4% da área de abrangência do radar.

Figura 3.22: Bacia do Tamanduateí e isócronas em área de 2 km x 2 km, e as coordenadas x, y centradas no radar meteorológico de São Paulo.

3.5.4 - REDE TELEMÉTRICA DO ALTO TIETÊ

A Rede Telemétrica do Alto Tietê é composta por 22 postos pluviográficos e 18 postos fluviográficos. A figura 3.22 mostra as redes pluviográfica e a rede fluviográfica do Alto Tietê. A rede telemétrica do Alto Tietê monitora automaticamente as chuvas e os níveis d'água dos principais rios da bacia do Alto Tietê (DAEE, 1999).

Figura 3.23: Localização da Rede Telemétrica do Alto Tietê. A figura 3.22a mostra a localização dos postos pluviométricos e a 3.22b a localização dos postos fluviométricos (Fonte DAEE, 1999).

3.5.3.1 - Funcionamento da Rede Telemétrica de São Paulo

A chuva é coletada por um cilindro padrão e é armazenada num recipiente tipo caçamba basculante que permite medir a chuva igual a 0,1 mm. Neste recipiente está acoplado um ímã que no movimento de basculação passa por um relé emitindo um sinal para a estação remota (ER) que incrementa 0,1 mm ao valor armazenado (PESSOA et al, 1992).

Os dados de níveis são medidos por um transdutor de nível, constituído por um disco sensor com 20 peças de ferro, localizadas em sua circunferência. Este disco está conectado a um sistema de bóia, que se move pela variação de nível do rio ou reservatório, num poço de medição. O sentido de giro determina a subida ou descida do nível com 1 cm de resolução na ER (PESSOA et al, 1992).

A rede telemétrica do Alto Tietê é controlada pelo Centro Tecnológico de Hidráulica (CTH) do Departamento de Águas e Energia Elétrica (DAEE). Ela tem sido utilizada no monitoramento de enchentes em São Paulo. A comunicação de dados é feita por uma linha telefônica privada, rádio e sistema de microondas da Eletropaulo (PESSOA et al., 1992).

Neste trabalho, utilizou-se os dados de nível do rio medidos no posto Fluviométrico do Glicério (FGLICE), localizado à jusante da bacia do Rio Tamanduateí, nas coordenadas geográficas $23^{\circ}32'56''\text{S}$ e $46^{\circ}37'35''\text{W}$. A cota zero da régua é de 717,41 m e a resolução temporal dos dados é de 10 minutos. A figura 3.23 mostra a localização do posto fluviométrico.

Figura 3.24: O ponto verde representa a localização do posto fluviométrico do Glicério na bacia do Rio Tamanduateí. A linha em abóbora indica o divisor d'água da bacia. Observa-se também o Rio Tamanduateí e seus principais afluentes.

3.5.5 - DADOS TELEMÉTRICOS

Selecionou-se os eventos para os quais haviam dados telemétricos e de radar simultaneamente. Os eventos selecionados são do período de 1991 a 1995. Os dados de vazão foram obtidos a partir dos níveis medidos. Os dados de nível foram transformados em vazão por meio de uma curva chave. A curva chave teórica para seção em estudo foi obtida pelo método hidráulico (PINTO et al., 1976). Esse método leva em consideração o perfil da seção transversal do local em que se deseja obter a curva chave do rio. A figura 3.25 mostra a seção transversal do canal do Rio Tamanduateí no posto Glicério

(Fig. 3.24). Com o perfil transversal obte-se a relação Vazão (Q) x Nível (h). Utilizou-se o processo de STEVENS (PINTO, 1976), que basea-se na fórmula de CHÉZY:

$$Q = \frac{1}{n} R^{2/3} A \sqrt{i} \quad (3.25)$$

onde: Q é vazão em m³/s;

n é o coeficiente de Manning e é adimensional;

R é o raio hidráulico em m;

A é área do canal em m² e

i é declividade do canal m/m.

Figura 3.25: Perfil transversal do ponto onde está localizado o posto do Glicério (Fig. 3.24) no Rio Tamanduateí.

A curva chave de um canal segue uma equação do tipo:

$$Q = A (h - h_0)^n \quad (3.26)$$

onde : Q é a vazão em m³s⁻¹;

h é o nível d'água da régua corresponde à vazão Q, medida pelo linígrafo, em m;

h₀ é o nível d'água mínimo em m;

A e n são constantes.

A partir da equação 3.25 calcula-se a vazão com as variáveis do perfil transversal. Os parâmetros são a área, o perímetro molhado, o raio hidráulico, o coeficiente de Manning (n), a declividade (i) e a altura h. O coeficiente de Manning utilizado é $n=0,020$, a declividade é $0,00074 \text{ m m}^{-1}$ considerando concreto liso. Da vazão, obte-se a cota (h) em função da vazão, conforme mostrado na figura 3.26.

Figura 3.26: Cota (h) em função da Vazão (Q) obtido a partir da equação teórica 3.25.

Aplicando-se o logaritmo em ambos os lados da equação (3.26) obtém-se:

$$\log Q = \log A + n \log (h - h_0) \quad (3.27)$$

Definindo-se : $q = \log Q$

$$a = \log A$$

$$H = \log (h - h_0)$$

Tem-se:

$$q = a + nH \quad (3.28)$$

Os parâmetros “a” e “n” são estimados pelo método dos mínimos quadrados. O valor h_0 é obtido por meio do processo iterativo. Para cada valor de h_0 , faz-se uma regressão linear entre os valores de $\log Q$ e $\log (h - h_0)$. O melhor valor de h_0 é obtido para R^2 igual a 1. O melhor ajuste foi para $h_0=0$, com os seguintes parâmetros: $a=1,2625$ e $n=1,58$. Portanto, a curva chave teórica obtida para o Rio Tamanduateí é:

$$Q_{\text{TEO}} = 18,3 \cdot h^{1,58} \quad (3.29)$$

onde: Q_{TEO} = vazão ($\text{m}^3 \text{s}^{-1}$);

h = cota (m).

Uma outra curva chave foi obtida pelo CTH a partir de medições de cota e vazão, de novembro a dezembro de 1998:

$$Q = 10,64 h^{1,89} \quad (3.30)$$

As curvas chave teórica e experimental estão na figura 3.27. A curva experimental tende a superestimar as vazões abaixo de $300 \text{ m}^3 \text{s}^{-1}$ e subestimá-las acima deste. Isto se deve ao fato de ter sido obtida para o período de cheia.

Figura 3.27: Comparação entre a curva chave teórica e do CTH.

Tendo em vista o curto período de medição de vazão para obtenção da curva chave, optou-se pela curva teórica. Portanto, selecionou-se os eventos de cheia mais significativos para cada ano, a partir da curva chave teórica para os quais havia dados de Radar. Os eventos de vazão selecionados para o período de 1991 a 1995 estão mostrados na Figura 3.28. Vários eventos significativos foram descartados por não haver dados de chuva, também os com falhas de dados de vazão.

(a)

(b)

(c)

(d)

(e)

Figura 3.28: Eventos de cheia do Rio Tamanduateí para os anos de 1991(a), 1992(b), 1993(c), 1994(d) e 1995(e).

O ano de 1995 (fig. 3.28e) possui a menor série de dados, e o de maior o ano de 1994 (fig. 3.28d). A maioria das vazões estão entre $50 \text{ m}^3\text{s}^{-1}$ e $250 \text{ m}^3\text{s}^{-1}$, enquanto que a máxima é de $350 \text{ m}^3\text{s}^{-1}$. A tabela 3.5 mostra os dados utilizados para o treinamento, a verificação e a previsão da RNA. Nota-se que os meses de janeiro, fevereiro, março, outubro, novembro e dezembro são os mais chuvosos, com as maiores cheias. As chuvas de origem convectivas são mais frequentes neste período e produzem grandes volumes de chuva em áreas isoladas, causando inundações (TUCCI, 1994).

1991		1992		1993		1994		1995	
Dia	Horas	Dia	Horas	Dia	Horas	Dia	Horas	Dia	Horas
19/03	9,0	13/01	6,0	02/04	9,5	07/01	4,5	11/01	9,0
04/04	3,5	14/01	4,0	03/04	11,5	09/01	15,5	12/01	17,0
08/04	6,0	22/01	19,5	14/09	8,5	17/01	6,0	24/03	5,5
25/04	15,0	29/01	19,5	15/09	14,0	19/01	7,5	09/04	6,5
07/05	18,5	30/01	2,5	16/09	4,5	01/02	11,0	11/04	8,0
15/05	21,5	06/02	11,5	24/09	16,5	02/02	7,5	12/04	14,0
21/06	19,5	08/02	24,0	25/09	4,0	03/02	9,0		
23/06	12,0	25/02	10,5	27/09	20,0	05/02	13,5		
24/06	17,0	27/02	11,0	05/09	15,5	06/02	24		
29/06	7,5	04/03	21,0	15/10	8,0	07/02	24		
13/07	15,0	11/04	7,5	26/10	9,5	08/02	23,5		
07/08	3,0	30/04	5,0	06/11	1,5	09/02	6,0		
08/08	11,5	01/05	11,0	07/11	9,5	11/02	9,5		
30/09	19,0	13/05	24,0	05/12	6,0	12/02	9,5		
05/10	17,0	19/05	18,0	08/12	9,5	13/02	19,0		
06/10	17,0	23/05	13,0	10/12	12,0	14/02	9,0		
10/10	20,5	06/07	11,0	11/12	13,5	15/02	8,5		
02/11	13,0	07/07	9,0	19/12	9,5	17/02	8,5		
		08/07	22,5	25/12	9,0	18/02	9,5		
		25/11	20,0	27/12	7,5	22/02	8,0		
		26/11	19,0	28/12	9,0	01/03	15,0		
		30/11	7,0	29/12	7,5	02/03	8,0		
		01/12	15,0			06/03	12,0		
		10/12	11,0			10/03	7,0		
		11/12	24,0			19/03	4,0		
						22/03	13,0		
						26/03	20,5		
						27/03	3,5		
						31/03	12,0		
						27/05	24,0		
						22/06	18,0		
						25/06	15,5		
						23/07	6,5		
						20/10	11,5		
						21/10	9,5		
						22/10	13,0		
						26/10	24,0		
						27/10	12,0		
						16/11	3,5		
						17/11	9,5		
						18/11	24		
						28/11	14,0		
						05/12	16,0		
						12/12	5,5		
						22/12	6,5		
						23/12	8,0		

Tabela 3.5: Dados utilizados no treinamento, verificação e previsão da RNA.

4 - RESULTADOS

A RNA utilizada neste trabalho é do tipo supervisionada. O algoritmo utilizado para o treinamento foi o LLSSIM, e com ele foram treinadas várias opções de maneiras distintas. Na primeira delas, as precipitações das oito isócronas nos intervalos de tempo (t), (t-1), (t-2), (t-3), (t-4), (t-5), (t-6) e (t-7) foram utilizadas como dados de entrada da rede e a vazão no instante (t) como saída. Similarmente, na segunda opção acrescentou-se a vazão observada no instante anterior (t-1) na entrada. A terceira e a quarta opção são iguais ao primeiro e segundo respectivamente, para dados de nível. A tabela 4.1 mostra os dados utilizados nos vários treinamentos. As matrizes foram formatadas de acordo com o algoritmo utilizado. A partir destas matrizes realizou-se também a verificação da rede. Os resultados obtidos no treinamento e na verificação foram comparados com um modelo autoregressivo. Realizou-se então uma série de previsões com a chuva estimada pelo radar, considerando-a como chuva prevista (conhecida). A metodologia acima é descrita a seguir.

Opção	Entrada			Saída	
	Chuva	Vazão	Nível	Vazão	Nível
1	Sim	Não	—	Sim	—
2	Sim	Sim	—	Sim	—
3	Sim	—	Não	—	Sim
4	Sim	—	Sim	—	Sim

Tabela 4.1: Cenários utilizados para o treinamento da RNA.

4.1 - TREINAMENTO

Na fase de treinamento são apresentados padrões a rede. A rede tenta assimilar as características desses padrões, aprendendo os processos neles contidos. Os dados de chuva e vazão utilizados neste trabalho passaram por um controle de qualidade inicial. Sendo que, os hidrogramas de cheias foram inspecionados visualmente. Fez-se também

um treinamento preliminar da RNA para remover eventos que não condiziam com os dados de nível observados por causa de erros de estimativa de chuva ou vazão. Assim, os erros foram atribuídos aos dados de nível ou de chuva. Estes eventos foram retirados das séries utilizadas para o treinamento e verificação.

De um total de 100 eventos, 27 foram eliminados no treinamento da RNA com a configuração (8,1,1), conforme mostrado na figura 4.1. Observa-se nesta figura eventos com vazões subestimadas em relação as observadas. Alguns desses eventos foram eliminados pois tinha erros de amplitude grande. Os eventos que não tinha erros tão grandes foram mantidos, mas tentou mantê-los separados nos respectivos subconjuntos: de treinamento, verificação e previsão.

Figura 4.1: Séries temporais de vazões estimadas com a RNA (curva vermelha) e vazões medidas no posto fluviométrico do Glicério na bacia do Alto Tietê (curva

azul). As vazões foram normalizadas entre 0,1 e 0,9, pelo valor máximo de $650 \text{ m}^3 \text{ s}^{-1}$. Resultados obtidos a partir do treinamento com dados de chuva e os de vazão do período de 1991 a 1995.

Dos 27 eventos removidos (372 horas), 9 (125 horas) possuíam vazão abaixo de 0,2 e os demais não acompanharam os valores observados. A tabela 4.2 mostra o número de eventos excluídos de cada seção da Fig. 4.1. A dispersão entre a vazão observada e a vazão estimada pela RNA é mostrada na figura 4.2. O coeficiente de correlação indica que apenas 42% variação é explicada.

Figura	Quantidade de Eventos	Total Horário (min)	Eventos Excluídos Com Vazão < 0,2
1a	03	35,5	00
1b	04	72,5	03
1c	06	51,5	00
1d	04	42,0	03
1e	08	136,5	03
1f	02	34,0	00

Tabela 4.2: Eventos excluídos da figura 4.1.

Figura 4.2: Diagrama de espalhamento entre a vazão observada e a vazão estimada pelo treinamento preliminar da RNA. O ajuste linear e coeficiente de correlação entre as variáveis estão indicados.

Após a realização do controle de qualidade, dividiu-se as séries nos seguintes grupos: treinamento, verificação e previsão. Do total de eventos 30% foram utilizados no treinamento e outros 70% para a verificação. A tabela 4.3 mostra os eventos utilizados no treinamento.

1991		1992		1993		1994		1995	
Dia	Horas	Dia	Horas	Dia	Horas	Dia	Horas	Dia	Horas
21/06	19,0	29/01	19,5	24/09	16,5	09/01	15,5	09/04	6,5
24/06	17,0	30/01	2,5	25/09	4,0	01/02	11,0		
30/09	19,0	25/02	10,5	05/10	15,5	02/02	7,5		
10/10	20,5	11/04	7,5	08/12	9,5	22/12	6,5		
		08/07	22,5			23/12	8,0		
		25/11	20,0						
		26/11	8,0						

Tabela 4.3: Eventos utilizados para o treinamento da rede neural. Estão indicados a data e o número de horas.

Uma vez definidos os padrões de entrada, iniciou-se o treinamento da RNA com um vetor 8,1,1 (opção 1). A seguir, foram feitos vários testes variando-se as camadas escondidas até o total de 20 camadas. No teste seguinte utilizou um vetor 9,1,1 (opção 2). Por último, utilizou-se os dados de nível para verificar seu desempenho em relação a vazão (opção 3 e 4). A figura 4.3 mostra os resultados obtidos para as opções 1 e 3. O efeito da variação das camadas escondidas é ilustrado na Fig 4.3c, é mostrado nesta figura a configuração de um vetor 8,5,1. Observa-se na Fig. 4.3 que as vazões menores são super-estimadas. Alguns eventos estimados diferem significativamente dos eventos observados.

(a)

(b)

(c)

Figura 4.3: Séries temporais de vazão estimada (a) e nível estimado (b) pela RNA (curva vermelha) com vetor (8,1,1) (a e b) e (8,5,1) (c) observadas (curva azul).

Os gráficos de espalhamento estão representados na figura 4.4. Os resultados com nível e vetor (8,1,1) e vazão com vetor (8,5,1) produziram ajustes melhores.

(a)

(b)

(c)

Figura 4.4: Diagrama de espalhamento das séries temporais de vazão (a e c) e nível (b) estimada pelo treinamento conforme Fig. 4.3. Estão indicados o ajuste linear e o coeficiente de correlação.

Os resultados obtidos com as opções 2 e 4 estão mostrados na figura 4.5. O treinamento foi realizado com um vetor 9,1,1, que incluiu a vazão ou nível no instante ($t-\Delta t$) na entrada da bacia. Observa-se que os resultados melhoram significativamente com a inclusão da memória da bacia. Observa-se também que os resultados obtidos com os dados de nível são ligeiramente superiores.

(a)

(b)

Figura 4.5: Séries temporais estimadas de vazão(a) e nível (b) (curva vermelha) e observada (curva azul). RNA treinada com um vetor 9,1,1.

Com relação as dispersões dos dados que utilizam a memória da bacia (Fig 4.6) nota-se que são bem superiores àquelas em que não foram incluídos (Tabela 4.4).

(a)

(b)

Figura 4.6: Diagrama dos espalhamento das séries temporais de vazão (a) e nível (b) e observada conforme Fig. 4.5. Estão indicadas o ajuste linear da dispersão e coeficiente correlação.

Vetor	Coeficiente de Correlação – R^2
8,1,1 (Vazão)	0,525
8,1,1 (Nível)	0,540
8,5,1 (Vazão)	0,568
9,1,1 (Vazão)	0,948
9,1,1 (Nível)	0,956

Tabela 4.4: Coeficientes de Correlação para os vários treinamentos.

Para verificar o desempenho da rede quando todos os dados de precipitação do radar sobre a bacia (76 quadrículas), fossem utilizados na entrada. Utilizou-se um evento de 24h ocorrido em 07/02/1994, a evolução da chuva deste dia é observada na figura 4.8. A RNA foi treinada com as opções 1 e 2 (Fig. 4.7).

Figura 4.7: Séries temporais de vazão com vetor (78,1,1) (a) e (77,1,1) (c) estimadas (curva vermelha) e observada (curva azul) e respectivos diagrama de espalhamento (b) e (d).

Observa-se que o ajuste obtido utilizando-se o vetor 78,1,1 é excelente, sendo que seu coeficiente de correlação explica 99% da variação, e o vetor 77,1,1 explica 84%. Esta melhora significativa corresponde ao aumento do número de características fornecidas à rede. Entretanto este treinamento se torna inviável com o aumento do número de casos, pois o custo do treinamento é muito elevado.

Figura 4.8: Evolução da chuva obtida pelo radar a cada 30 minutos

Continuação da Figura 4.8

4.2 - VERIFICAÇÃO

Realizado o treinamento, o próximo passo foi realizar a verificação. A verificação é a fase onde outros dados que não fazem parte do treinamento são testados para verificar o desempenho do aprendizado da rede. Assim, os dados utilizados não foram utilizados anteriormente (Tabela 4.5). As mesmas opções do treinamento foram utilizadas na verificação.

1991		1992		1993		1994		1995	
Dia	Horas	Dia	Horas	Dia	Horas	Dia	Horas	Dia	Horas
23/06	12,0	13/01	6,0	14/09	8,5	17/01	6,0	11/01	9,0
13/07	15,0	140/01	2,0	15/09	14,0	19/01	7,5	12/01	17,0
05/10	17,0	06/02	11,5	16/09	4,5	03/02	9,0	11/04	8,0
06/10	17,0	08/02	24,0	27/09	6,5	05/02	8,0	12/04	14,0
02/11	13,0	27/02	11,0	15/10	4,0	06/02	24,0		
		04/03	21,0	05/12	6,0	07/02	24,0		
		23/05	13,0	10/12	12	08/02	23,5		
		06/07	11,0	11/12	13,5	09/02	6,0		
		07/07	9,0	25/12	9,0	11/02	9,5		
		01/12	15,0			13/02	16,0		
		10/12	11,0			14/02	9,0		
						17/02	8,5		
						22/02	8,0		
						10/03	7,0		
						22/03	13,0		
						22/06	18,0		
						23/07	6,5		
						22/10	13,0		
						17/11	9,5		
						18/11	24,0		
						28/11	14,0		
						12/12	5,5		

Tabela 4.5: Dados utilizados na verificação da RNA.

Os resultados obtidos da verificação utilizando-se as opções 1 e 3 estão mostrados na figura 4.9 e os respectivos diagrama de espalhamento na Figura 4.10. Observa-se que alguns dos eventos foram subestimados. Nota-se também que na verificação a rede super-estima os valores menores.

(a)

(b)

(c)

Figura 4.9: Séries temporais de vazão (a e c) e nível (b) estimadas com a RNA (curva vermelha) e observada (curva azul). Similar a Fig. 4.3, exceto para o conjunto de verificação.

Observou-se também que o aumento das camadas escondidas tornou os resultados piores (Tabela 4.6). Por outro lado, os dados de nível são ligeiramente superiores aos de vazão, como no treinamento.

(a)

(b)

(c)

Figura 4.10: Similar a Fig. 4.4 exceto para o conjunto de verificação.

Vetor	Coefficiente de Correlação – R^2
8,1,1 (Vazão)	0,452
8,1,1 (Nível)	0,488
8,5,1 (Vazão)	0,448
9,1,1 (Vazão)	0,951
9,1,1 (Nível)	0,949

Tabela 4.6: Coeficientes de Correlação para as várias verificação.

As figuras 4.11 e 4.12 mostram os resultados obtidos com as opções 2 e 4. Novamente os resultados obtidos com a incorporação da memória da bacia são melhores (Tab. 4.6). A série de dados de verificação e treinamento são independentes, e a de verificação é maior do que a de treinamento. Como os resultados dependem da série de dados não podemos compara-las de uma forma direta. Entretanto, na Tab. 4.5 e 4.6 nota-se que os resultados obtidos pelo vetor 9,1,1 com vazão tem um resultado um pouco melhor que no treinamento; isto não ocorre com as outras formas de treinamento.

Comparando-se as tabelas 4.5 e 4.6, verifica-se uma diminuição nos coeficientes de correlação da verificação quando não se inclui a memória da bacia. No treinamento sem memória os coeficientes de variação estão entre 52 e 56%, na verificação na faixa de 45% a 48%. Tanto o treinamento quanto a verificação com memória estão em torno de 95%.

(a)

(b)

Figura 4.11: Similar a Fig. 4.5, exceto para o conjunto de verificação.

(a)

(b)

Figura 4.12: Similar a Fig 4.6, exceto para o conjunto de verificação.

4.3 - MODELO AUTOREGRSSIVO

Utilizou-se o mesmo conjunto de dados anteriores para calcular os parâmetros do AR. Eles foram calculados por meio da função Regressão Múltiplas (FERRAZ et al, 1999). Os resultados da RNA, do AR e dos dados observados estão mostrados na figura 4.13 para o treinamento e verificação para a opção 1, e na figura 4.14 para a opção 3.

(a)

(b)

Figura 4.13: Séries temporais de vazões estimada da AR (curva vermelha) e observada (curva azul). Foram utilizando os mesmos dados do treinamento (a) e verificação (b).

Os resultados obtidos mostram que o ajuste obtido pela RNA é superior àqueles com o AR. Ambos os modelos não reproduziram algumas vazões observadas, possivelmente devido a calibração do radar. Tanto AR e RNA sempre super estimam as vazões baixas quando não se incorpora a memória da bacia. Provavelmente uma explicação para esta discrepância seja o caráter dinâmico da RNA. O AR requer um conjunto de dados com maior número de característica da bacia. Os resultados obtidos

no treinamento com a opção 2 estão mostrados na figura 4.14. Observa-se que o ajuste obtido é muito superior ao da opção 1. A inclusão da memória da bacia aumenta o peso dado a ela no caso da AR.

(a)

(b)

Figura 4.14: Similar a Fig. 4.11 com o vetor 9,1,1.

4.4 - ERROS DE FASE E AMPLITUDE

Os resultados foram avaliados quando ao erro de fase e amplitude, seguindo a metodologia de TAKACS (1985), expressa por:

$$mse = mse_{diss} + mse_{disp} \quad (4.1)$$

onde:

mse_{diss} é o componente de dissipação (amplitude) e

mse_{disp} é o componente de dispersão (fase) do erro médio quadrático.

Estes componentes podem ser determinadas da seguinte forma:

$$\begin{aligned} mse_{diss} &= [\sigma(Q_a) - \sigma(Q_p)]^2 + (<Q_a> - <Q_p>)^2 \\ mse_{disp} &= 2(1 - \rho)\sigma(Q_a)\sigma(Q_p) \end{aligned} \quad (4.2)$$

onde:

$Q_{a(p)}$ é a vazão observada (previsão),

$\sigma(.)$ é o operador desvio padrão

$<>$ é o operador média, e

ρ é o coeficiente de correlação entre Q_a e Q_p

Os resultados para as opções 1 e 3 estão na tabela 4.7 e das opções 2 e 4 na tabela 4.8 para o treinamento e a validação. Em geral os erros de fase são maiores que os erros de amplitudes

Modelo	Opção 1 e 3			
	Fase		Amplitude	
	Treinamento	Verificação	Treinamento	Verificação
AR	1.24E-03	3.40E-03	5.28E-03	1.12E-03
V(8,1,1)	4.94E-03	3.96E-03	9.17E-04	2.69E-04
V(8,5,1)	4.49E-03	3.97E-03	8.01E-04	2.82E-04
N(8,1,1)	5.86E-04	6.01E-03	1.14E-03	4.48E-04

Tabela 4.7: Erros de Fase e Amplitude, para as opções 1 e 3 para treinamento e verificação dos modelos AR e RNA

Modelo	Cenário 2 e 4			
	Fase		Amplitude	
	Treinamento	Verificação	Treinamento	Verificação
AR	6.26E-03	3.44E-04	8.32E-06	6.35E-06
V(9,1,1)	6.26E-04	3.66E-04	6.13E-06	2.77E-06
N(9,1,1)	7.68E-04	6.30E-04	4.92E-06	3.86E-05

Tabela 4.8: Erros de Fase e Amplitude, opções 2 e 4 para treinamento e verificação dos modelos AR e RNA

As figuras 4.15 e 4.16 mostram os erros de fase e amplitude das 4 opções utilizadas para a RNA, e os obtidos para o AR. Nota-se que os maiores erros de fase estão associados ao AR (Fig. 4.16a) e a RNA opção 3 (Fig. 4.15a), na fase de treinamento e verificação respectivamente. Por outro lado, na fase de treinamento o maior erro de amplitude esta associado ao AR (Fig. 4.15b). Observa-se ainda que a magnitude dos erros de fase são maiores que os de amplitude.

(a)

Figura 4.15: Erros de Fase e Amplitude para o treinamento e verificação, utilizando as opções 1e 3. a) erro de fase e b) erro de amplitude.

Figura 4.16: Erros de Fase e Amplitude para o treinamento e verificação, utilizando as opções 2 e 4. a) erro de fase e b) erro de amplitude.

Com a inclusão da memória do sistema os erros de amplitude diminuiriam. Os erros de amplitude estão relacionados com os erros obtidos de calibração do radar e da transformação da vazão, pois são erros sistemáticos. Entretanto, os erros de fase associam a sincronia dos dados de radar com os dados de nível, ou devido a imprecisão de separação das isócronas, ou seja, ao tempo de concentração.

4.5 - PREVISÃO IDEAL

A previsão ideal foi realizada com o objetivo de obter uma ferramenta para previsão de enchentes. A previsão observa até quando é possível obter um bom resultado da previsão de nível utilizando a previsão de chuva estimada pelo radar até três horas antecedência. A RNA utilizou-se dos dados de nível pois os resultados obtidos no treinamento foram um pouco melhor que do com vazão. Também, é mais simples se avaliar a enchente obtendo o nível da calha do rio do que com a vazão. Utilizou-se eventos independentes, com os dados no início do evento. As previsões foram realizadas de 30 minutos até 3 horas. Os eventos utilizados estão na tabela 4.9.

1991	1992	1993	1994	1995
19/03	13/01	03/04	07/01	24/03
04/04	14/01	24/09	17/01	
07/05	29/01	27/09	19/01	
15/05	11/04	26/10	02/02	
23/06	30/04	05/12	04/02	
29/06	26/11		05/02	
02/11			08/02	
09/11			09/02	
			18/02	
			02/03	
			10/03	
			19/03	
			31/03	
			16/11	
			17/11	
			12/12	

Tabela 4.9: Eventos utilizados para previsão de nível.

Os resultados obtidos para cada intervalo de tempo estão mostrados na figura 4.17 e os respectivos coeficiente de variação na figura 4.18. Observa-se na figura 4.18 que o melhor coeficiente de correlação ocorreu para previsão de 30 minutos. Nesta previsão, o valor de nível utilizado na entrada no instante t-1 corresponde ao valor de nível observado. A partir da previsão 60 minutos, o nível utilizado no instante t-1

passou a ser o obtido pela a RNA. Pode-se verificar que com o decorrer do tempo os resultados pioram e os erros são amplificados pela rede.

Figura 4.17: Evolução temporal do nível previsto (vermelho) e observado (azul). Os dados correspondem ao período de 1991 a 1995 (Tab. 4.9). a) previsão

para 30 minutos, b) 60 minutos, c) 90 minutos, d) 120 minutos, e) 150 minutos e f) 180 minutos.

Figura 4.18: Coeficiente de Correlação (R^2) obtido das previsões de 30, 60, 90, 120, 150 e 180 minutos.

A figura 4.18 mostra que as previsões são úteis até 90 minutos. A partir deste intervalo de tempo, os resultados degradam rapidamente. Os erros de fase e amplitude das previsões são mostrados na figura 4.19. Os erros de fase ainda continuam tendo magnitudes maiores do que os de amplitude.

Figura 4.19: Erros de fase(vermelho) e amplitude(azul) para as previsões de 30, 60, 90, 120, 150 e 180 minutos.

5 - CONCLUSÕES

Utilizou-se neste trabalho o conceito de redes neurais artificiais na modelagem hidrológica com dados de radar e dados de telemetria. Na previsão de vazão, tenta-se adequar a RNA como uma ferramenta para previsão de cheias para a RMSP.

A RNA demonstrou ser adequada no requer o conhecimento sobre os processos de transformação de chuva em vazão na bacia, sendo necessário apenas conhecimentos prévios. Os resultados mostram que a previsão com a RNA e dados de radar são úteis até 90 minutos a frente, já que a partir deste tempo, os valores do coeficiente de correlação e os erros de fase e amplitude degradam muito rapidamente.

A memória da bacia foi de grande importância no treinamento e verificação da RNA. Entretanto, mesmo sem a inclusão dessa característica obteve-se resultados satisfatórios. Esse procedimento é útil quando deseja ter apenas uma idéia do processo de vazão de uma bacia. Análises mais elaboradas demandam o acréscimo da memória.

Observou-se que o coeficiente de correlação no treinamento e verificação consegue explicar mais de 90% da variância total dos dados quando se tem a memória. Quando ela não é incluída a variância situa-se entre 45% a 56%. Quando utilizou todas as quadrículas do radar disponível na área da bacia, os resultados do treinamento tanto com a memória, quanto sem memória melhoram. No caso primeiro caso a variância explicada foi 99%, no segundo caso ela foi de 84%. Na prática isto se torna inviável pois este treinamento foi realizado com um total de 48 dados, ou seja um dia inteiro de dados (24 horas), e com ele obteve-se um tempo de processamento da rede de 2 minutos. Enquanto que quando aumentamos o banco de dados (todos os dados utilizados para o treinamento), e temos a média das chuvas nas oito isócronas o tempo foi de 27 segundos. Assim, se conjunto de dados aumentar no uso de todas as quadrículas o tempo de processamento vai aumentar, elevando assim o custo do processamento da rede.

Os erros associados à fase temporal entre os dados de radar e telemetria são maiores que os erros associados a calibração do radar. Os resultados melhoram um pouco com o nível d'água, isto devido a incorporação de erros sistemáticos.

6 - RECOMENDAÇÕES

- 1 - Estender o estudo desenvolvido neste trabalho para outras sub-bacias do Alto Tietê.
- 2 – Utilizar outras arquiteturas de RNA para verificar seu desempenho em função dos dados utilizados e verificar qual as vantagens.
- 3 – Utilizar dados de chuva de outras fontes (telemétrica e satélite) para comparar com esses dados de chuva de radar.

7 - REFERÊNCIAS BIBLIOGRÁFICAS

- BALLINI, R. **Redes neurais artificiais para previsão chuva/vazão.** São Carlos, 1996. 105p. Dissertação (Mestrado) - Instituto de Ciências Matemáticas, Universidade de São Paulo.
- BALLINI, R.; FRANÇA, E.; KADOWAKI, M.; SOARES, S.; ANDRADE, M. Modelos de redes neurais e box & jenkins para previsão de vazões médias mensais. *In: Simpósio Brasileiro de Recursos Hídricos*, 12^o, CD-ROOM, 1997.
- BATTAN, L.J. **Radar observation of the atmosphere.** Chicago, University of Chicago Press, 1973. 324p.
- BISHOP, C.M. **Neural networks for pattern recognition.** New York, Oxford University Press Inc., 1995.
- BOX, G.E.; JENKINS, G.M. **Time series analysis: forecasting and control.** 2^a ed., Oakland, Holden-Day, 1976.
- CARVALHO, A C. P.L.F.; BRAGA, A P.; LUDEMIR, T.B. Fundamentos de redes neurais artificiais. *In: 11^a Escola de Computação*, Rio de Janeiro, 1998. 246p.
- CARVALHO FILHO, E.C.B.; MARAR, J.F. O computador neural: uma máquina biologicamente inspirada. *In: Simp. Sobre o Cérebro*, Recife, 1993. – **Anais.** Recife, 1993, pp.73-84.
- CENTRO TÉCNICO OPERACIONAL - CTO **Estudo hidráulico e hidrológico da bacia do rio tamanduateí.** 1997. (Relatório Técnico)
- CRESPO, J.L.; MORA, E. Drought estimation with neural networks. *Advances in Engineering Software*, n^o 18, pp. 167-170, 1993.

DEPARTAMENTO DE ÁGUAS E ENERGIA ELÉTRICA Canalização do tamanduateí. **REVISTA ÁGUAS E ENERGIA ELÉTRICA**, DAEE, nº 12, p.30-41, 1988.

DEPARTAMENTO DE ÁGUAS E ENERGIA ELÉTRICA. Sistema de alerta – a inundações da região leste do estado de São Paulo. **REVISTA ÁGUAS E ENERGIA ELÉTRICA**, DAEE, 1999.

DUAN, Q.; SOROOSHIAN, S.; GUPTA, V.K. Effective and effecient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, 28(4), pp. 1015-1031, 1992.

FERRAZ, M. I. F; SÁFADI, T.; LAGE, G. Uso de modelos de séries temporais na previsão de séries de precipitação pluviais mensais no município de lavras-MG. *Revista Brasileira de Agrometeorologia*, vol. 7, nº 2, pp. 259-267, 1999.

FIERING, M.B.; JACKSON, B.B. Synthetic streamflows. 2^a ed, *American Geophysical Union.*, Washington, 1971. (Water Resources Monograph Series)

FLOOD, I.; KARTAM, N. Neural network in civil engineering. i: principles and understanding. *Journal of Computing in Civil Engineering*, vol. 8, nº 2, pp. 131–148, 1994a.

FLOOD, I.; KARTAM, N. Neural network in civil engineering. ii: systems and application. *Journal of Computing in Civil Engineering*, vol. 8, nº 2, pp. 149-162, 1994b.

FRENCH, M.N.; KRAJEWSKI, W.F. ; CUYKENDALL, R.R. Rainfall forecasting in space and time using a neural network. *Journal of Hydrology*, nº 137, pp. 1-31, 1992.

FUNDAÇÃO CENTRO TECNOLÓGICO **Radar meteorológico de Ponte Nova: atividades para instalação do radar de ponte Nova.** São Paulo, FCTH, 1987. 132p. (Relatório Parcial)

GALVÃO, C.O.; VALENÇA, M.J.S. **Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais.** 1^a ed. Porto Alegre, Editora da Universidade/UFRGS/ABRH, 1999. 246p. (Coleção ABRH de Recursos Hídricos; vol. 7.)

GUPTA, H.V.; HSU, K.; SOROOSHIAN, S. Superior training of artificial neural networks using weight-space partitioning. *In: International Conference on Neural Networks (ICNN'97)*, Texas, **Proceedings of the IEEE 1997**, pp.1919-1923, 1997.

GUYTON, A. C.; HALL, J. E. **Tratamento de fisiologia médica.** 9^a ed., Rio de Janeiro, Editora Guanabara Koogan S.A., 1997. Cap.45, pp. 510-537.

HAYKIN, S. **Neural networks: a comprehensive foundation.** Ontario, Prentice Hall International, Inc., 1994. 696p.

HEBB, D. **The organization of behavior: a neuropsychological theory.** New York, Wiley, 1949.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences of the U.S.A.*, nº 79, pp. 2554-2558, 1982.

HSU, K.; GUPTA, H. V; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*, vol. 31, nº 10, pp. 2517-2530, 1995.

HSU, K.L; GUPTA, H.V and SOROOSHIAN, S. **A superior training strategy for three-layer feedforward artificial neural networks.** Tucson, University of

Arizona, 1996. (Technique report, HWR nº 96-030, Departament of Hydrology and Water Resources)

KADOWAKI, M.; SOARES, S.; ANDRADE, M.G. Previsão de vazões mensais utilizando redes neurais multicamadas com algoritmo backpropagation. ***In: Simpósio Brasileiro de Redes Neurais***, 4^o, Goiânia, 1997.

KARUNANITHI, N.; GRENNEY, J.W.; WHITLEY, D.; BOVEE, K. Neural networks for river flow prediction. ***Journal of Computing in Civil Engineering***, vol. 8; nº 2, 1994.

KOVÁCS, Z.L. **Redes neurais artificiais: fundamentos e aplicações**. 2^a ed., São Paulo, Editora Collegium Cognitio, 1996. 174p.

LANNA, A.E.; SCHWARZBACH, M. **MODHAC – modelo hidrológico auto-calibrável**. Florianópolis, IPH – Instituto de Pesquisas Hidráulicas da UFRGS, 1988.

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

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

MARSHALL, J.S; PALMER, W.M.K. The distribution of raindrops with size. ***Journal of Meteorology***, 1948, 5: pp. 165-166.

McCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. ***Bulletin of Mathematical Biophysics***, 5: pp.115-133, 1943.

MINSKY, M. L.; PAPERT, S.A. **Perceptrons: an introduction to computational geometry**. Massachusetts, MIT Press, 1969.

MORETTIN, P.A., TOLOI, C.M.C. **Modelos para previsão de séries temporais.** Rio de Janeiro, IMPA-CNPq, vol. I , 1981.

MORETTIN, P. A. Séries temporais; uma introdução. *In: Minicurso do Congr. Nac. de Matemática Aplicada e Computacional – SBMAC*, 5^o, João Pessoa, Paraíba, 1982.

NIELSEN, R.H. **Neurocomputing.** USA, Addison-Wesley Publishing Company, 1991.

OSÓRIO, F. S.; VIEIRA, R. Tutorial de sistemas híbridos inteligentes. *In: Cong. Da Soc. Bras. Computação - ENIA'99 – Encontro Nacional de Inteligência Artificial*, Rio de Janeiro, 1999.

PARKER, D. B. **Learnig logic: casting the cortex of the human brain in silicon.** Cambridge, Center for Computational Research in Economics and Management Science, MIT, 1985. (Technical report)

PEDROLLO, O. C. Previsão hidrológica de curto prazo com chuvas efetivas determinadas pela função sigmóide. **RBRH – Revista Brasileira de Recursos Hídricos**, 1999, vol. 4, n^o 2, pp.19-30.

PESSOA, M.L. et alii. **telemetria e sensoriamento remoto com aplicações em hidrologia e meteorologia.** Curitiba, FINEP, 1992.

PINTO, N.L.S.; HOLTZ, A. C. T.; MARTINS, J.A.; GOMIDE, F.L.S. **Hidrologia básica.** São Paulo, Editora Edgard Blücher Ltda, 1976.

RINEHART, R.E. **Radar for meteorologists.** 2^a ed., North Dakota, Knight Printing Company, 1994. 334p.

ROCHESTER, N.; HOLLAND, J. N.; HAIBT, L. H.; DUDA, W.L. Tests on cell assembly theory of action of the brain, using a large digital computer. *IRE Transactions on Information Theory IT-2*, pp. 80-93, 1956.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, nº 65, pp. 386-408, 1958.

ROSENBLATT, F. **Principles of neurodynamics: perceptrons and the theory of brain mechanisms.** New York, Spartan Books, 1962.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, 323, pp. 533-536, 1986.

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

SCALERO, R.S; TEPEDELENLIOGIU, N. A fast new algorithm for training feedforward neural networks. *IEEE Trans. Signal Process.*, 40(1), pp. 202-210, 1992.

SHAMSELDIN, A.Y.; O'CONNOR, K.M.; LIANG, G.C. Methods for combining the outputs of different rainfall-runoff models. *Journal of Hydrology*, nº197, pp. 203-229, 1996.

SHAMSELDIN, A.Y. Application of a neural network technique to rainfall-runoff modelling. *Journal of Hydrology*, nº199, pp. 272-294, 1997.

SINGH, V.P. **Hydrologic systems - rainfall-runoff modeling.** New Jersey, Prentice Hall, vol 1, 1988.

SMITH, M. **Neural networks for statistical modeling.** New York, Van Nostrand Reinhold, 1993.

- SOUZA, M.S; MACHADO, D.; MARTINO, M.B. Determinação de vazões utilizando redes neurais. *In Simpósio Brasileiro de Recursos Hídricos*, 11^o, vol. I, pp. 63-68, 1995. **Anais**
- TAFNER, M. A.; XEREZ, M.; RODRIGUES FILHO, I.W. **Redes neurais artificiais: introdução e princípios de neurocomputação**. Blumenau, EKO / Editora da FURB, 1996. 199p.
- TAKACS, L.L. A two-step scheme for the advection equation with minimized dissipation and dispersion errors. *American Meteorological Society*, vol. 113, pp.1050-1065, 1985.
- TANG, Z.; ALMEIDA, C.; FISHWICK, P.A. Times series forecasting using neural networks vs. Box-Jenkins methodology. *In Simulations*, pp. 301-310. Simulations Councils, 1991.
- THIRUMALAI AH, K.; DEO, M.C. River stage forecasting using artificial neural networks. *Journal of Hydrologic Engineering*, vol. 3, n^o 1, 1998.
- TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. 1^a ed. Porto Alegre, Ed. Universidade/ABRH/EDUSP, 1993. (Coleção ABRH de Recursos Hídricos, vol. 4)
- VALENÇA, M.J.S. Aplicação de redes neurais na área de recursos hídricos. *In Simpósio Brasileiro de Recursos Hídricos*, 12^o, CD-ROOM, 1997.
- VEMURI, V.R. **Artificial neural networks – forecsating times series**. Los Alamitos, IEEE Computer Society Press, 1994.
- WIDROW, B.; HOFF, M. E. Adaptative switching circuits. *Instituto of Radio Engineers, Western Eletronic Show and Convetion*, pp. 96-104, 1960.

XIAO, R.; CHANDRASEKAR, V. Multiparameter radar rainfall estimation using neural network techniques. *In: Conf. On Radar Meteorology*, 27^a, Colorado, pp.199-201, 1995.

YANG, C.C.; CHANG, L.C.; CHEN, C.S. Comparison of integrated artificial neural network with time series modeling for flood forecast. *Journal of Hydroscience and Hydraulic Engineering*, vol.17, n^o 2, 1999.

ANEXOS

Tabela com as datas de dados de radar e telemetria. Os dados de radar contém os horários e localização de cada arquivo de dado. Na telemetria contém o nome do arquivo onde está localizado a transformação de nível em vazão e os horários disponíveis. Na tabela a seguir encontra em detalhe os horários disponíveis para os dados de radar.

DATA	RADAR	TELEMETRIA
19/03/91	00:03 a 20:33 Fita 156	00:00 a 12:50 190391.xls
04/04/91	00:03 a 23:53 Fita 169	00:00 a 18:50 04081314150491.xls
08/04/91	01:13 a 22:43 Fita 170	00:00 a 23:50 04081314150491.xls
13/04/91	00:13 a 23:53 Fita 173	00:00 a 23:50 04081314150491.xls
14/04/91	00:13 a 23:23 Fita 173	00:00 a 23:50 04081314150491.xls
15/04/91	01:23 a 23:53 Fita 173	00:00 a 14:10 04081314150491.xls
19/04/91	00:13 a 23:53 Fita 175 e 176	00:00 a 12:50; 14:40 a 15:50; 18:00 a 18:30; 20:00 a 23:50 192425260491.xls
24/04/91	19:33 a 23:53 Fita 176	00:00 a 00:40; 02:00; 05:10 a 05:20 a 06:30; 07:50 a 10:40; 12:00 a 13:00; 14:50 a 21:00; 23:00 a 23:50 192425260491.xls
25/04/91	02:13 a 21:23 Fita 177	00:00 a 01:50; 03:20 a 18:50; 20:00 a 23:50 192425260491.xls
26/04/91	00:53 a 11:53 Fita 178	00:00 a 06:30; 08:20 a 13:00; 14:40 a 18:50 192425260491.xls
06/05/91	00:03 a 23:53 Fita 181 e 182	00:30 a 01:10; 05:20 a 12:00; 13:30 a 13:40; 15:10 a 16:30; 17:50 a 23:20; 0607150591.xls
07/05/91	00:03 a 23:53 Fita 182 e 183	00:00 a 11:00; 12:20 a 12:40; 14:30 a 23:50 0607150591.xls
15/05/91	00:03 a 23:53 Fita 184 e 185	00:00 a 23:50 0607150591.xls
21/06/91	00:03 a 23:23 Fita 188 e 189	00:00 a 23:50 21222324290691.xls

22/06/91	08:13 a 23:53 Fita 189 e 190	00:00 a 23:50 21222324290691.xls
23/06/91	00:23 a 23:53 Fita 190	00:00 a 23:50 21222324290691.xls
24/06/91	00:03 a 23:23 Fita 190, 191 e 192	00:00 a 23:50 21222324290691.xls
29/06/91	00:03 a 18:33 Fita 192 e 193	00:00 a 18:50 21222324290691.xls
13/07/91	00:13 a 22:53 Fita 195 e 196	00:00 a 23:50 130791.xls
07/08/91	00:43 a 23:53 Fita 196 e 197	00:00 a 06:20; 15:40 a 23:50 0708090891.xls
08/08/91	00:13 a 20:43 Fita 197 e 198	00:00 a 11:10; 15:30 a 23:50 0708090891.xls
09/08/91	00:03 a 23:53 Fita 198	00:00 a 23:50 0708090891.xls
30/09/91	00:13 a 20:43 Fita 203 e 204	00:00 a 23:50 300991.xls
05/10/91	07:13 a 23:53 Fita 206	00:00 a 23:50 050607101091.xls
06/10/91	00:13 a 23:53 Fita 206 e 207	00:00 a 23:50 050607101091.xls
07/10/91	00:13 a 15:13 Fita 207 e 208	00:00 a 23:50 050607101091.xls
10/10/91	00:13 a 22:23 Fita 209	00:00 a 23:50 050607101091.xls
02/11/91	00:13 a 17:23 Fita 215	00:00 a 23:50 02091191.xls
09/11/91	00:03 a 17:23 Fita 217	00:00 a 23:50 02091191.xls
13/01/92	00:13 a 23:53 Fita 248 e 249	16:00 a 23:50 13140192.xls
14/01/92	00:03 a 23:53 Fita 243	00:00 a 23:50 13140192.xls
22/01/92	03:13 a 22:23 Fita 255	00:00 a 23:50 222930310192.xls
29/01/98	00:03 a 23:53 Fita 258	00:00 a 23:50 222930310192.xls
30/01/92	00:13 a 19:43 Fita 258 e 259	00:00 a 23:50 222930310192.xls
31/01/92	01:03 a 23:53 Fita 259 e 260	00:00 a 23:50 222930310192.xls
01/02/92	00:13 a 23:53 Fita 260 e 261	00:00 a 23:50 01060708090292.xls
06/02/92	00:13 a 23:53 Fita 263 e 264	00:00 a 23:50 01060708090292.xls
07/02/92	00:03 a 23:53 Fita 264 e 265	00:00 a 23:50 01060708090292.xls

08/02/92	00:13 a 23:53 Fita 265, 266 e 267	00:00 a 23:50 01060708090292.xls
09/02/92	00:03 a 22:03 Fita 267	00:00; 01:20 a 23:50 01060708090292.xls
19/02/92	00:23 a 23:53 Fita 270	00:00 a 13:40; 16:30 a 19:00; 23:40 a 23:50 192025270292.xls
20/02/92	00:03 a 20 23 Fita 270 e 271	00:00 a 16:50 192025270292.xls
25/02/92	00:03 a 23:43 Fita 273 e 274	00:00 a 23:50 192025270292.xls
26/02/92	00:23 a 23:53 Fita 274 e 275	00:00 a 23:50 192025270292.xls
27/02/92	00:13 a 23:53 Fita 275 e 276	00:00 a 23:50 192025270292.xls
01/03/92	08:13 a 22:03 Fita 276 e 277	00:00 a 23:50 010203040050690392.xls
02/03/92	02:13 a 23:53 Fita 278	00:00 a 23:50 010203040050690392.xls
03/03/92	00:03 a 23:53 Fita 278 e 279	00:00 a 23:50 010203040050690392.xls
04/03/92	00:03 a 23:53 Fita 279, 280 e 281	00:00 a 23:50 010203040050690392.xls
05/03/92	00:03 a 23:53 Fita 281 e 282	00:00 a 23:50 010203040050690392.xls
06/03/92	00:03 a 22:53 Fita 282 e 283	00:00 a 08:00; 11:40 a 14:40 010203040050690392.xls
09/03/92	13:53 a 23:53 Fita 284 e 285	16:50 a 23:50 010203040050690392.xls
11/04/92	16:03 a 23:13 Fita 304	00:00 a 23:50 1112130492.xls
12/04/92	14:52 a 23:53 Fita 304	00:00 a 03:00 1112130492.xls
13/04/92	00:03 a 23:53 Fita 304, 305 e 306	09:10 a 23:50 1112130492.xls
30/04/92	00:03 a 06:30 Fita 311 e 312	00:00 a 17:00; 17:20 a 23:50 300492.xls
01/05/92	13:13 a 23:53 Fita 312	00:00 a 23:50 01130592.xls
13/05/92	00:03 a 23:53 Fita 316 e 317	00:00 a 23:50 01130592.xls
19/05/92	00:03 a 23:43 Fita 319 e 320	00:00 a 23:50 19230592.xls
23/05/92	00:03 a 23:53 Fita 321 e 322	00:00 17:50 19230592.xls
06/07/92	13:07 a 23:53 Fita 325	00:00 a 23:50 0607080792.xls

07/07/92	00:03 a 23:53 Fita 325 e 326	00:00 a 23:50 0607080792.xls
08/07/92	00:03 a 22:53 Fita 326 e 327	00:00 a 23:50 0607080792.xls
17/07/92	00:03 a 23:53 Fita 329	00:00 a 17:50; 23:00 a 23:50 170792.xls
24/11/92	13:13 a 23:53 Fita 379	10:10 a 23:50 242526301192.xls
25/11/92	00:03 a 23:53 Fita 379, 380 e 381	00:00 a 23:50 242526301192.xls
26/11/92	00:03 a 20:03 Fita 381 e 382	00:00 a 23:50 242526301192.xls
30/11/92	17:13 a 23:53 Fita 382	00:00 a 23:50 242526301192.xls
01/12/92	00:03 a 23:43 Fita 382, 383 e 384	00:00 a 14:50 0110111292.xls
10/12/92	00:03 a 23:53 Fita 386 e 387	00:00 a 23:50 0110111292.xls
11/12/92	00:03 a 23:53 Fita 387, 388 e 389	00:00 a 23:50 0110111292.xls
02/04/93	02:03 a 22:23 Fita 459 e 460	00:00 a 09:10; 10:50 a 23:50 02030493.xls
03/04/93	11:03 a 23:23 Fita 460	00:00 a 23:50 02030493.xls
23/08/93	15:23 a 20:33 Fita 477	não tem dados
24/08/93	00:13 a 23:53 Fita 477, 478 e 479	não tem dados
03/09/93	10:53 a 23:23 Fita 479 e 480	não tem dados
04/09/93	03:23 a 05:33 Fita 480 e 481	não tem dados
07/09/93	16:03 a 23:53 Fita 481 e 482	não tem dados
08/09/93	00:03 a 22:23 Fita 482	não tem dados
11/09/93	02:13 a 15:53 Fita 484 e 485	00:00 a 23:50 0304070811150993.xls
15/09/93	00:03 a 23:43 Fita 485 e 486	00:00 a 23:50 0304070811150993.xls
16/09/93	00:13 a 23:13 Fita 486 e 487	00:00 a 23:50 1621232425270993.xls
21/09/93	05:53 a 20:53 Fita 487, 488 e 489	00:00 a 07:50; 11:30 a 12:10 16212223242526270993.xls
22/09/93	08:33 a 23:53 Fita 489 e 490	10:10 a 11:40; 12:00 a 17:00 16212223242526270993.xls
23/09/93	00:03 a 23:43 Fita 489, 490 e 491	16:10 a 18:40; 23:50 16212223242526270993.xls

24/09/93	00:23 a 23:53 Fita 491 e 492	00:00 a 23:50 16212223242526270993.xls
25/09/93	00:03 a 03:43 Fita 492	00:00 a 23:50 16212223242526270993.xls
26/09/93	18:43 a 23:13 Fita 492 e 493	00:00 a 23:50 16212223242526270993.xls
27/09/93	00:53 a 21:33 Fita 493 e 494	00:00 a 23:50 16212223242526270993.xls
03/10/93	14:03 a 23:03 Fita 495	00:00 a 23:50 0305
05/10/93	01:13 a 20:33 Fita 496	00:00 a 23:50 0305151093.xls
15/10/93	15:13 a 22:43 Fita 497	00:00 a 23:50 0305151093.xls
18/10/93	15:13 a 23:43 Fita 498	00:00 a 17:00 18192123261093.xls
19/10/93	00:03 a 23:53 Fita 498 e 499	14:10 a 23:50 18192123261093.xls
21/10/93	00:03 a 20:43 Fita 499	00:00 a 15:10 18192123261093.xls
23/10/93	00:03 a 18:23 Fita 499 e 500	não tem dados 18192123261093.xls
26/10/93	08:23 a 18:03 Fita 501	00:00 a 23:50 18192123261093.xls
06/11/93	22:43 a 23:53 Fita 502	00:00 a 23:50 06071193.xls
07/11/93	00:03 a 17:53 Fita 502	00:00 a 23:50 06071193.xls
17/11/93	00:03 a 23:53 Fita 503	00:00 a 22:10 17181193.xls
18/11/93	00:03 a 23:53 Fita 503 e 504	15:10 a 23:50 17181193.xls
05/12/93	00:13 a 21:33 Fita 510	00:00 a 23:50 050608101112.xls
06/12/93	15:13 a 18:33 Fita 510	00:00 a 23:50 050608101112.xls
08/12/93	00:03 a 22:13 Fita 510 e 511	00:00 a 23:50 050608101112.xls
10/12/93	06:59 a 23:53 Fita 511	00:00 a 23:50 050608101112.xls
11/12/93	00:03 a 13:13 Fita 511 a 512	00:00 a 23:50 050608101112.xls
19/12/93	14:53 a 23:53 Fita 514	00:00 a 23:50 1920252728291293.xls
20/12/93	01:43 a 16:53 Fita 514 e 515	00:00 a 23:50 1920252728291293.xls
25/12/93	13:53 a 22:03 Fita 515	00:00 a 23:50 1920252728291293.xls

27/12/93	14:03 a 20:03 Fita 515	00:00 a 23:50 1920252728291293.xls
28/12/93	13:13 a 21:43 Fita 516	00:00 a 23:50 1920252728291293.xls
29/12/93	00:23 a 23:53 Fita 516 e 517	00:00 a 23:50 1920252728291293.xls
07/01/94	13:33 a 23:53 Fita 519 e 520	00:00 a 23:50 070809130194.xls
08/01/94	00:03 a 23:53 Fita 520	00:00 a 18:40 070809130194.xls
09/01/94	00:13 a 23:53 Fita 520, 521 e 522	00:20 a 23:50 070809130194.xls
13/01/94	15:03 a 19:23 Fita 522	00:00 a 08:00 070809130194.xls
17/01/94	16:33 a 22:13 Fita 522	00:00 a 23:50 1718192728310194.xls
18/01/94	16:43 a 23:50 Fita 522	00:00 a 23:50 1718192728310194.xls
19/01/94	00:03 a 23:53 Fita 522	00:00 a 23:50 1718192728310194.xls
27/01/94	00:13 a 23:43 Fita 525 e 526	não tem dados
28/01/94	00:03 a 20:53 Fita 526	não tem dados
31/01/94	13:13 a 23:53 Fita 527	não tem dados
01/02/94	00:03 a 23:53 Fita 527 e 528	10:50 a 23:50 01a150294.xls
02/02/94	00:03 a 22:03 Fita 528	00:00 a 23:50 01a150294.xls
03/02/94	15:13 a 23:53 Fita 528	00:00 a 23:50 01a150294.xls
04/02/94	00:03 a 23:53 Fita 528 e 529	00:00 a 23:50 01a150294.xls
05/02/94	00:03 a 23:53 Fita 529	00:00 a 23:50 01a150294.xls
06/02/94	00:03 a 23:53 Fita 529 e 530	00:00 a 23:50 01a150294.xls
07/02/94	00:03 a 23:53 Fita 531 e 532	00:00 a 23:50 01a150294.xls
08/02/94	00:03 a 23:53 Fita 532 e 533	00:00 a 23:50 01a150294.xls
09/02/94	00:03 a 20:53 Fita 533 e 534	00:00 a 23:50 01a150294.xls
10/02/94	14:23 a 23:53 Fita 534	00:00 a 23:50 01a150294.xls
11/02/94	00:03 a 23:53 Fita 534 e 535	00:00 a 11:10;12:30 a 23:50 01a150294.xls

12/02/94	00:03 a 23:53 Fita 535 e 536	00:00 a 23:50 01a150294.xls
13/02/94	00:03 a 23:53 Fita 536 e 537	00:00 a 23:50 01a150294.xls
14/02/94	13:43 a 22:14 Fita 537	00:00 a 23:50 01a150294.xls
15/02/94	00:53 a 23:03 Fita 537 e 538	00:00 a 23:50 01a150294.xls
17/02/94	15:33 a 23:53 Fita 538	00:00 a 23:50 171822232728.xls
18/02/94	00:03 a 23:53 Fita 538 e 539	00:00 a 23:50 1718222327280294.xls
22/02/94	00:03 a 23:53 Fita 540 e 541	00:00 a 23:50 1718222327280294.xls
23/02/94	00:03 a 23:53 Fita 541	00:00 a 23:50 1718222327280294.xls
27/02/94	21:43 a 22:23 Fita 542	00:00 a 23:50 1718222327280294.xls
28/02/94	16:03 a 22:13 Fita 542	00:00 a 23:50 1718222327280294.xls
01/03/94	02:13 a 23:53 Fita 542 e 543	00:00 a 23:50 010206091011120394.xls
02/03/94	00:03 a 08:23 Fita 543	00:00 a 23:50 010206091011120394.xls
06/03/94	12:03 a 23:43 Fita 543 e 544	00:00 a 23:50 010206091011120394.xls
09/03/94	14:33 a 23:53 Fita 546	00:00 a 02:00; 02:20 a 06:10; 06:30 a 07:00; 07:20 a 23:50 010206091011120394.xls
10/03/94	00:03 a 23:53 Fita 546 e 547	00:00 a 21:40 010206091011120394.xls
11/03/94	00:13 a 23:03 Fita 547 e 548	não tem dados
12/03/94	11:59 a 23:53 Fita 548 e 549	não tem dados
19/03/94	15:03 a 23:43 Fita 550	00:00 a 18:50 19202227310394.xls
20/03/94	00:03 a 22:23 Fita 550 e 551	00:50 a 06:50; 08:50 a 18:50 19202227310394.xls
22/03/94	00:03 a 16:43 Fita 551 e 552	00:50 a 07:50; 09:50 a 18:50 19202227310394.xls
27/03/94	00:03 a 03:13 Fita 554	00:00 a 23:50 19202227310394.xls
31/03/94	13:03 a 23:53 Fita 555	00:00 a 23:50 19202227310394.xls
01/04/94	00:03 a 23:53 Fita 555 e 556	00:00 a 23:50 010494.xls

11/05/94	01:53 a 23:53 Fita 557	00:00 a 23:50 111314150594.xls
13/05/94	07:53 a 23:53 Fita 557 e 558	00:00 a 23:50 111314150594.xls
14/05/94	00:43 a 23:53 Fita 558, 559 e 560	00:00 a 23:50 111314150594.xls
15/05/94	00:03 a 23:33 Fita 560 e 561	00:00 a 23:50 111314150594.xls
24/05/94	10:43 a 15:23 Fita 562	00:00 a 23:50 24270594.xls
27/05/94	00:03 a 23:53 Fita 563 e 565	00:00 a 23:50 24270594.xls
04/06/94	05:43 a 19:03 Fita 564 e 565	00:00 a 23:50 04090694.xls
09/06/94	00:03 a 03:43 Fita 566	00:00 a 11:40; 23:50 04090694.xls
22/06/94	04:53 a 22:23 Fita 566 e 567	00:00 a 23:50 22250694.xls
25/06/94	00:03 a 15:03 Fita 567 e 568	00:00 a 23:50 22250694.xls
23/07/94	00:03 a 19:33 Fita 569 e 570	00:00 a 09:10 230794.xls
27/09/94	10:13 a 21:03 Fita 572	00:00 a 23:50 270994.xls
13/10/94	16:13 a 23:53 Fita 573	00:00 a 20:10 131094.xls
18/10/94	00:33 a 23:53 Fita 574 e 575	00:00 a 23:50 182021222324252627281094.xls
20/10/94	12:53 a 23:53 Fita 575 e 576	00:00 a 23:50 182021222324252627281094.xls
21/10/94	00:03 a 10:03 Fita 576	00:00 a 23:50 182021222324252627281094.xls
22/10/94	02:23 a 21:13 Fita 576 e 577	00:00 a 23:50 182021222324252627281094.xls
23/10/94	16:03 a 23:20 Fita 577	00:00 a 23:50 182021222324252627281094.xls
24/10/94	12:23 a 23:53 Fita 577 e 578	00:00 a 09:30; 11:50 a 23:50 182021222324252627281094.xls
25/10/94	00:03 a 23:53 Fita 578	00:00 a 23:50 182021222324252627281094.xls
26/10/94	00:03 a 23:53 Fita 579 e 580	00:00 a 23:50 182021222324252627281094.xls
27/10/94	00:03 a 21:03 Fita 580 e 581	00:00 a 23:50 182021222324252627281094.xls
28/10/94	15:13 a 23:53 Fita 581 e 582	00:00 a 11:20; 14:50 a 23:50 182021222324252627281094.xls

01/11/94	19:13 a 23:53 Fita 582	00:00 a 23:50 010213141194.xls
02/11/94	00:03 a 07:53 Fita 582	00:00 a 23:50 010213141194.xls
13/11/94	00:03 a 23:53 Fita 584 e 585	00:00 a 15:20 010213141194.xls
14/11/94	00:03 a 20:13 Fita 585 e 586	não tem dados
16/11/94	00:03 a 22:13 Fita 586	15:30 a 23:50 16171828291194.xls
17/11/94	08:33 a 23:53 Fita 586 e 587	00:00 a 23:50 16171828291194.xls
18/11/94	00:03 a 23:53 Fita 587 e 588	00:00 a 23:50 16171828291194.xls
28/11/94	00:03 a 21:33 Fita 589, 590 e 591	07:40 a 23:50 16171828291194.xls
29/11/94	07:03 a 15:33 Fita 591	00:00 a 18:00 16171828291194.xls
05/12/94	00:03 a 23:53 Fita 592 e 593	00:00 a 20:20 05060712131294.xls
06/12/94	00:03 a 23:53 Fita 593 e 594	não tem dados 05060712131294.xls
07/12/94	00:03 a 02:53 Fita 594	não tem dados 05060712131294.xls
12/12/94	00:03 a 23:23 Fita 595 e 596	15:00 a 19:20; 21:30 a 23:50 05060712131294.xls
13/12/94	17:13 a 21:43 Fita 596	00:00 a 17:50 05060712131294.xls
22/12/94	01:53 a 23:53 Fita 600, 601 e 602	16:50 a 23:50 222327281294.xls
23/12/94	00:03 a 20:53 Fita 602 e 603	00:00 a 11:20; 13:40 a 23:50 222327281294.xls
27/12/94	00:03 a 21:53 Fita 603	00:00 a 17:30 222327281294.xls
28/12/94	03:23 a 09:33 Fita 604	não tem dados
09/01/95	07:13 a 14:23 Fita 616	não tem dados
10/01/95	00:03 a 21:33 Fita 616 e 617	não tem dados
11/01/95	00:03 a 23:53 Fita 617 e 618	11:10 a 23:50 091011120195.xls
12/01/95	00:03 a 23:53 Fita 618 e 619	00:00 a 23:50 091011120195.xls
18/01/95	00:03 a 23:53 Fita 622 e 623	não tem dados
19/01/95	00:03 a 11:33 Fita 623	não tem dados

31/01/95	12:03 a 23:03 Fita 627	não tem dados
01/02/95	13:13 a 23:53 Fita 627 e 628	não tem dados
02/02/95	00:03 e 23:53 Fita 628 e 629	não tem dados
03/02/95	00:13 a 23:53 Fita 629 e 630	não tem dados
04/02/95	00:03 a 23:53 Fita 630, 631 e 632	não tem dados
05/02/95	00:03 a 23:53 Fita 632, 633 e 634	não tem dados
06/02/95	00:03 a 23:53 Fita 634, 635 e 636	não tem dados
17/02/95	00:03 a 23:03 Fita 643 e 644	não tem dados
18/02/95	00:13 a 23:50 Fita 644 e 645	não tem dados
19/02/95	00:03 a 23:53 Fita 646, 647 e 648	não tem dados
10/03/95	00:03 a 23:53 Fita 656, 657, 658	não tem dados
11/03/95	00:03 a 18:53 Fita 658	não tem dados
24/03/95	00:03 a 23:53 Fita 662, 663 e 664	00:00 a 06:50 2425300395.xls
25/03/95	00:03 a 06:23 Fita 664	não tem dados
30/03/95	00:03 a 23:53 Fita 665, 666 e 667	não tem dados
09/04/95	16:03 a 22:23 Fita 669	00:00 a 23:50 091011120495.xls
10/04/95	13:53 a 19:03 Fita 669	00:00 a 23:50 091011120495.xls
11/04/95	16:23 a 23:53 Fita 669 e 670	00:00 a 23:50 9504164.at
12/04/95	00:03 a 13:33 Fita 670	00:00 a 23:50 091011120495.xls
20/04/95	00:23 a 19:03 Fita 671 e 672	00:00 a 23:50 200495.xls
06/05/95	01:53 a 23:53 Fita 672 e 673	00:00 a 23:50 0607100595.xls
07/05/95	00:03 a 23:53 Fita 673 e 674	00:00 a 23:50 0607100595.xls
10/05/95	03:03 a 19:53 Fita 674 e 675	00:00 a 23:50 0607100595.xls
18/05/95	02:53 a 10:13 Fita 676	não tem dados

21/05/95	05:03 a 13:33 Fita 676 e 677	não tem dados
18/06/95	17:13 a 23:53 Fita 677	00:00 a 23:50 18250695.xls
25/06/95	07:03 a 14:53 Fita 678	00:00 a 23:50 18250695.xls
08/07/95	02:43 a 23:53 Fita 678 e 679	00:00 a 23:50 0809100795.xls
09/07/95	00:03 a 23:53 Fita 679 e 680	00:00 a 23:50 0809100795.xls
10/07/95	00:03 a 13:13 Fita 680 e 681	00:00 a 23:50 0809100795.xls
21/07/95	07:23 a 23:53 Fita 681 e 682	00:00 a 23:50 21220795.xls
22/07/95	00:03 a 20:33 Fita 682 e 683	00:00 a 23:50 21220795.xls
15/09/95	07:13 a 22:13 Fita 684	08:30 a 23:50 150995.xls
17/09/95	12:33 a 23:53 Fita 684 e 685	00:00 a 23:50 171819202324260995.xls
18/09/95	14:13 a 23:43 Fita 685	00:00 a 23:50 171819202324260995.xls
19/09/95	00:13 a 23:33 Fita 685 e 686	00:00 a 23:50 171819202324260995.xls
20/09/95	00:23 a 21:03 Fita 686	00:00 a 23:50 171819202324260995.xls
23/09/95	10:43 a 22:53 Fita 686	00:00 a 23:50 171819202324260995.xls
24/09/95	02:03 a 23:53 Fita 687 e 688	00:00 a 23:50 171819202324260995.xls
26/09/95	10:03 a 23:03 Fita 688	00:00 a 23:50 171819202324260995.xls