

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA CIVIL

***PREVISÃO MULTIVARIADA DA DEMANDA
HORÁRIA DE ÁGUA EM SISTEMAS URBANOS DE
ABASTECIMENTO***

Carla Silva da Silva

Campinas
2003

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA CIVIL

***PREVISÃO MULTIVARIADA DA DEMANDA HORÁRIA DE ÁGUA
EM SISTEMAS URBANOS DE ABASTECIMENTO***

Carla Silva da Silva

Orientador: Prof. Dr. Paulo Sérgio Franco Barbosa

Tese apresentada à Comissão de Pós-graduação da Faculdade de Engenharia Civil Universidade Estadual de Campinas, como parte dos pré-requisitos para obtenção do título de Doutor em Engenharia Civil, na área de concentração Recursos Hídricos.

Campinas, 02 Setembro de 2003
SP - Brasil

Este trabalho teve suporte financeiro da Fundação de Amparo à Pesquisa de São Paulo (FAPESP), em forma de bolsa de Doutorado.

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

Si31p	Silva, Carla Silva da Previsão multivariada da demanda horária de água em sistemas urbanos de abastecimento / Carla Silva da Silva. - Campinas, SP: [s.n.], 2003. Orientador: Paulo Sérgio Franco Barbosa Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Civil. 1. Redes neurais. 2. Abastecimento de água. I. Barbosa, Paulo Sérgio Franco. II. Universidade Estadual de Campinas. Faculdade de Engenharia Civil. III. Título.
-------	---

AGRADECIMENTOS

Ao Professor Dr. Paulo Sérgio Franco Barbosa, pela confiança, amizade e orientação.

Ao Professor Dr. Kamel Zahed Filho e a SABESP, pelo fornecimento dos dados relativos ao Sistema Adutor Metropolitano Alça Leste.

À Professora Dr^a Rosangela Ballini, pelas sugestões.

A todos funcionários da Faculdade de Engenharia Civil (FEC).

À minha família pelo carinho e apoio.

Ao meu noivo, pela compreensão e carinho.

Aos meus amigos de república, Lu, Dani, Ali, Cacá, Guiga, pelo apoio, carinho e ajuda.

A minha amiga Rosiléa, pelo carinho, ajuda e incentivo.

As minha amigas Lydiane, Vivien, Laura Abreu e Maria Alice, pelo muitos momentos de alegria que passamos juntas, pelo carinho, amizade e ajuda.

Ao meu amigo Rogério, por toda ajuda prestada.

A todos os meus colegas de Pós-graduação, em especial aos amigos, Jairo, Neusa, Lubienska, Oranda e Laura Maria, pela convivência.

À FAPESP pelo apoio financeiro.

ÍNDICE

RESUMO.....	i
ABSTRACT.....	ii
LISTA DE FIGURAS.....	iii
LISTA DE TABELAS.....	viii
1 – Introdução.....	01
1.1 – Motivação Para a Utilização de Redes Neurais Artificiais.....	03
1.2 – Justificativa.....	04
1.3 – Descrição do Trabalho.....	05
2 – Objetivo do Trabalho.....	06
3 – Revisão Bibliográfica.....	07
3.1 – A Importância da Previsão da Demanda na Indústria em Geral.....	07
3.2 – Aspectos da Previsão de Demanda.....	08
3.3 – Previsão Segundo o Tipo de Produção.....	09
3.4 – A Previsão Move a Cadeia de Suprimentos.....	09
3.5 – O Que é Previsão.....	10
3.6 – Métodos de Previsão de Demanda.....	10
3.7 – Previsão de Demanda de Água em Sistemas Urbanos de Abastecimento.....	12
3.7.1 – Introdução.....	12
3.7.2 – Estudos Sobre Previsão de Demanda.....	15
3.7.3 – A Previsão de Demanda de Água em São Paulo-SP e Campinas-SP.....	25
3.8 – Redes Neurais Artificiais.....	33
3.8.1 – Fundamentos de Redes Neurais Artificiais.....	33
3.8.2 – Breve Histórico.....	35
3.8.3 – Neurônio Artificial.....	37
3.8.4 – Topologia das Redes Neurais Artificiais.....	39
3.8.5 – Redes do Tipo Perceptron de Múltiplas Camadas (MLP).....	43
3.8.6 – Função de Ativação.....	46
3.8.7 – Processo de Aprendizagem e Generalização.....	47
3.8.7.1 – Aprendizado Supervisionado.....	50
3.8.7.2 – Regra de Aprendizagem de Correção do Erro.....	51
3.8.7.3 – Modos de Treinamento de RMC.....	59
3.8.7.4 – Normalização dos Dados de Entrada.....	60
3.8.7.5 – Inicialização dos Pesos.....	61

3.8.7.6 – Critérios de Parada.....	63
3.8.8 – Validação Cruzada.....	64
3.8.9 – Generalização.....	65
3.9 – Redes Neurais Artificiais Aplicadas a Previsão.....	65
4 – Metodologia.....	74
4.1 – Análise dos Dados Coletados.....	74
4.2 – Modelo de Redes Neurais.....	75
4.2.1 – Estrutura de RNA's para Previsão de Consumo de Água em Sistemas Urbanos de Abastecimento.....	75
4.2.2 – Treinamento Supervisionado da Rede Neural.....	77
4.2.3 – Processamento dos Dados de Entrada.....	80
4.2.4 – Função Objetivo.....	80
4.2.5 – Função de Ativação.....	82
4.2.6 – Algoritmo de Otimização.....	82
4.2.7 – Inicialização dos Pesos.....	83
4.2.8 – Estratificação dos Dados Amostrais.....	83
4.2.9 – Critério de Parada.....	83
4.3 – Programação.....	83
4.4 – Modelos de Previsão Baseados em Séries Temporais.....	85
4.4.1 – Análise de Séries Temporais.....	86
4.4.2 – Conceito de Processos Estocásticos.....	88
4.4.2.1 – Média e Variância de um Processo Estacionário.....	89
4.4.2.2 – Coeficientes de Autocovariância e Autocorrelação.....	90
4.4.3 – Função de Autocovariância e Autocorrelação.....	92
4.4.3.1 – Estimativa das Funções de Autocovariância e Autocorrelação.....	92
4.5 – Modelo Auto-Regressivo.....	93
4.5.1 – Função de Autocorrelação de Modelos Auto-Regressivos.....	94
4.5.2 – Função de Autocorrelação Parcial de Modelos Auto-Regressivos.....	95
4.5.3 – Erro Padrão das Estimativas de Autocorrelação Parcial.....	97
4.6 – Médias Móveis.....	98
4.7 – Análise dos Erros.....	99
4.8 – Impacto da Qualidade da Previsão nas Políticas Operacionais.....	100
4.9 – Estrutura de Aplicação dos Modelos.....	100

5 – Estudo de Caso.....	102
5.1 – Área de Estudo.....	102
5.2 – Aplicação dos Modelos de RNA's Multicamadas, Médias Móveis e Auto-Regressivo para a Previsão de Demanda.....	106
5.3 – Primeiro Caso: Estratificação sazonal dos Dados em Duas Estações (RNA 1.1).....	107
5.3.1 – Modelo de RNA's.....	112
5.3.1.1 – Simulação do Modelo em RNA's.....	113
5.4 – Segundo Caso: Previsão Univariada – Com Estratificação Sazonal dos Dados em Quatro Estações (RNA 1.2).....	117
5.4.1 – Modelo em RNA's.....	118
5.4.1.1 – Simulação do Modelo em RNA's.....	119
5.5 – Terceiro Caso: Estratificação Sazonal em Quatro Estações e Inclusão da Variável Temperatura (RNA 2.1.1, RNA 2.1.2 e RNA 2.1.3).....	127
5.5.1 – Modelo em RNA's.....	128
5.5.1.1 – Simulação do Modelo em RNA's.....	129
5.6 – Quarto Caso: Estratificação Sazonal dos Dados em Quatro Estações sem Inclusão da Variável Temperatura (RNA 2.2.1).....	134
5.6.1 – Modelo de RNA's.....	134
5.6.1.1 – Simulação do Modelo em RNA's.....	135
5.7 – Aplicação dos Modelo de Médias Móveis para a Previsão de Demanda – Estratificação dos Dados em Quatro Estações.....	137
5.8 – Aplicação do Modelo Auto-Regressivo para a Previsão de Demanda – Estratificação Sazonal dos Dados em Quatro Estações.....	138
5.8.1 – Análise da Série de Demandas.....	138
5.8.2 – Ajuste do Modelo Auto-Regressivo para a Série de Demandas.....	143
5.9 – Quito Caso: Previsão Multivariada – Com Estratificação Sazonal dos Dados em Quatro Estações (RNA 3.1, RNA 3.2 e RNA 3.3).....	144
5.9.1 – Modelo de RNA's.....	145
5.9.1.1 – Simulação do Modelo em RNA's.....	147
5.10 – Análise Estatística dos Modelos de Previsão.....	155
5.10.1 – Primeiro Caso: Estratificação dos Dados em Duas Estações (RNA 1.1).....	155
5.10.2 – Segundo Caso: Estratificação Sazonal dos Dados em Quatro estações (RNA 1.2).....	156
5.10.2.1 – Comparação dos Modelos.....	156

5.10.3 – Terceiro Caso: Estratificação Sazonal em Quatro Estações e Inclusão da Variável Temperatura (RNA 2.1.1, RNA 2.1.2 e RNA 2.1.3).....	161
5.10.4 – Quarto Caso: Estratificação Sazonal em Quatro Estações sem Inclusão da Variável Temperatura (RNA 2.2.1).....	163
5.10.5 – Comparação Entre o Terceiro e Quarto Casos.....	163
5.10.6 – Quinto Caso: Previsão Multivariada – Com Estratificação Sazonal dos Dados em Quatro Estações (RNA 3.1, RNA 3.2 e RNA 3.3).....	164
5.10.7 – Comparação Entre o Segundo Caso com a Previsão Multivariada.....	168
5.11 – Impacto da Previsão de Demanda no Desempenho Operacional de Um Sistema de Abastecimento.....	170
5.11.1 – Formulação do Modelo Hidráulico de Otimização.....	172
5.11.2 – Técnica de Solução do Modelo Hidráulico de Otimização.....	176
5.12 – Simulação da Política Ótima de Operação.....	188
5.12.1 – Resultados das Verificações.....	189
5.12.1.1 – Implementação para RNA.....	189
5.12.1.2 – Implementação para MM.....	193
6 – Conclusões e Recomendações.....	194
REFERÊNCIAS BIBLIOGRÁFICAS.....	199
ANEXO A – Listagem de Programas.....	210
ANEXO B – Listagem de Programas.....	213
ANEXO C – Listagem de Programas.....	222
ANEXO D – Modelo Auto-Regressivo.....	227

RESUMO

Este trabalho investiga a utilização do modelo de redes neurais artificiais, foco principal da pesquisa, e dos modelos baseados em séries temporais (médias móveis e auto-regressivo) na previsão univariada e multivariada da demanda de água em sistemas urbanos de abastecimento de água. Medidas estatísticas foram calculadas sobre os dados de saída dos modelos para permitir a avaliação dos resultados de previsão, em forma comparativa para os diversos modelos. A área de estudo de caso está localizada na região metropolitana de São Paulo, denominada Alça Leste. Uma das grandes dificuldades na previsão das vazões de consumo de água é a presença da sazonalidade, com nítidas diferenças entre o período chuvoso e seco do ano, característica marcante nesta região. Por este motivo, neste estudo optou-se por dividir a série de dados de entrada para melhor caracterizar esses períodos. Também foi estudado o impacto da previsão da demanda no desempenho operacional de um sistema de abastecimento, com os resultados de previsão obtidos por médias móveis e redes neurais servindo como entrada para o software de otimização (GAMS) que forneceu as políticas ótimas de operação do sistema para as duas situações. Tais políticas ótimas foram simuladas em uma rede hipotética de distribuição sob ação da curva de demanda real, pelo simulador hidráulico EPANET, com a finalidade de verificar se tais políticas poderiam ser implementadas.

ABSTRACT

This work investigates the use of an artificial neural network model, which is the main focus of this research, and also the use of time series models for univariate and multivariate water supply demand forecasting. Statistical measures are calculated on the model output data to allow the evaluation of the forecast results, aiming at providing a comparative analysis from the several models. The case study area is located in a branch of the metropolitan area of São Paulo, which is named Alça Leste. One of the great difficulties in the forecast of water supply demand is the presence of seasonal effects throughout the year, what is very strong in this area. For this reason, the observed series of input data are divided in four seasons for allowing a best characterization of these different periods. The impact of the demand forecasting on the daily operation of the water supply system was also evaluated, using the forecast results obtained by movable averages and artificial network models as input to an optimization software package (GAMS). Aiming at providing an evaluation test, the optimal operational results were simulated on a hypothetical water supply network under the action of a real demand curve, using the EPANET hydraulic simulator software.

LISTA DE FIGURAS

FIGURA 3.1 – Exemplos de Formação da Demanda.....	09
FIGURA 3.2 – Métodos de Previsão.....	11
FIGURA 3.3 – Métodos Quantitativos de Previsão.....	12
FIGURA 3.4 – Demandas Doméstica, Comercial, Industrial e Pública e Demanda Máxima Diária Total.....	29
FIGURA 3.5 – Estrutura Geral do Neurônio Genérico.....	38
FIGURA 3.6 – Elementos de Conexão de RNA's.....	39
FIGURA 3.7 – Arquitetura de um Neurônio Artificial com Múltiplas Entradas Não Lineares.....	40
FIGURA 3.8 – Representação Funcional de um Neurônio – Perceptron de McCulloch e Pitts.....	44
FIGURA 3.9 – Arquitetura de Rede Neural Multicamadas.....	45
FIGURA 3.10 – Tipos de Funções de Ativação.....	47
FIGURA 3.11 – Taxonomia do Processo de Aprendizagem.....	50
FIGURA 3.12 – Treinamento Supervisionado de um RNA.....	51
FIGURA 3.13 – Direção de Propagação do Sinal Funcional e do Erro.....	52
FIGURA 3.14 – Superfície do Erro.....	53
FIGURA 3.15 – Estágios de Pré e Pós-processamento de Rede Neural.....	60
FIGURA 3.16 – Superfície de Erro – Mínimo Local.....	62
FIGURA 3.17 – Superfície de Erro – Mínimo Global.....	62
FIGURA 4.1 – Rede Neural Multicamadas.....	76
FIGURA 4.2 – Uso de Pré-processamento e Pós-processamento dos Dados em Conjunto com o mapeamento das RNA's.....	80
FIGURA 4.3 – Fluxograma de Utilização dos Programas.....	85
FIGURA 4.4 – Série de Vazões Médias Diárias para o Reservatório de Penha	88
FIGURA 5.1 – Topologia da Alça Leste.....	103
FIGURA 5.2 – Perfis de Consumo Associados aos 7 Reservatórios em Estudo.....	105
FIGURA 5.3 – Perfis dos Reservatórios Admensionalizados.....	105
FIGURA 5.4 – Correlação para os Meses Chuvosos.....	108
FIGURA 5.5 – Correlação para os Meses Secos.....	108
FIGURA 5.6 – Demandas Horárias para 4 Sábados do Mês de Julho (Reservatório Penha).....	111
FIGURA 5.7 – Demandas Horárias para 5 Sábados do Mês de Janeiro (Reservatório Penha).....	111
FIGURA 5.8 – Valores de Demanda Média para o Reservatório Penha (Treinamento e Teste).....	114
FIGURA 5.9 – Valores de Demanda Horária para os Dias 28/09/98 e 28/10/98 (Meses Secos).....	114
FIGURA 5.10 – Valores de Demanda Horária para o Dia 28/11/98 (Meses Secos).....	115

FIGURA 5.11 – Valores de Demanda Média para o Reservatório Penha (Treinamento e Teste).....	116
FIGURA 5.12 – Valores de Demanda Horária para os Dias 22/03/99 e 22/04/99 (Meses Chuvosos)...	116
FIGURA 5.13 – Valores de Demanda Horária para o Dia 22/05/99 (Meses Chuvosos).....	117
FIGURA 5.14 – Valores de Demanda Média para o Reservatório Penha Inverno (Treinamento e Teste).....	122
FIGURA 5.15 – Valores de Demanda Horária para o Dia 28/08/98 (Inverno).....	122
FIGURA 5.16 – Valores de Demanda Média para o Reservatório Penha Primavera (Treinamento e Teste).....	123
FIGURA 5.17 – Valores de Demanda Horária para o Dia 28/11/98 (Primavera).....	123
FIGURA 5.18 – Valores de Demanda Média para o Reservatório Penha Verão (Treinamento e Teste).....	124
FIGURA 5.19 – Valores de Demandas Horária para o Dia 20/03/99 (Verão).....	124
FIGURA 5.20 – Valores de Demanda Média para o Reservatório Penha Outubro (Treinamento e Teste).....	125
FIGURA 5.21 – Valores de Demanda Horária para o Dia 22/05/99 (Outubro).....	125
FIGURA 5.22 – Resultados do Treinamento e Teste para Estação de Primavera (RNA 2.1.1).....	131
FIGURA 5.23 – Resultado do Treinamento e Teste para Estação de Verão (RNA 2.1.1).....	131
FIGURA 5.24 – Resultado do Treinamento e Teste para Estação de Primavera (RNA 2.1.2).....	132
FIGURA 5.25 – Resultado do Treinamento e Teste para Estação de Verão (RNA 2.1.2).....	132
FIGURA 5.26 – Resultado do Treinamento e Teste para Estação de Verão (RNA 2.1.3).....	133
FIGURA 5.27 – Resultado do Treinamento e Teste para Estação de Outono (RNA 2.1.3).....	133
FIGURA 5.28 – Resultado do Treinamento e Teste para Estação de Verão (RNA 2.2.1).....	136
FIGURA 5.29 – Resultados do Treinamento e Teste Estação de Outono (RNA 2.2.1).....	136
FIGURA 5.30 – Valores Observados x Valores Previstos por Médias Móveis para Três períodos de Referência.....	137
FIGURA 5.31 – Séries de Demandas Horárias para o Reservatório Penha (Estação Inverno).....	139
FIGURA 5.32 – Média e Desvio Padrão Horário para a Série de Demanda do Reservatório Penha (Estação Inverno).....	141
FIGURA 5.33 – Série Padronizada para os Dados de Demanda do Reservatório Penha (Estação Inverno).....	141
FIGURA 5.34 – Função de Autocorrelação para a Série de Demanda para o Reservatório Penha (Estação Inverno).....	142
FIGURA 5.35 – Esquema de Previsão Univariada.....	144
FIGURA 5.36 – Esquema de Previsão Multivariada.....	144

FIGURA 5.37 – Visualização dos EQM, EAM, EPM e EPmax para RNA's , MM e AR Reservatório Penha.....	161
FIGURA 5.38 – Visualização dos EQM, EAM, EPM e EPmax para as variações de RNA Reservatório Penha.....	164
FIGURA 5.39 – EQM e Coeficientes de Variação para o Reservatório Penha (RNA 3.1, RNA 3.2, RNA 3.3 e RNA 1.2).....	168
FIGURA 5.40 – EQM e Coeficientes de Variação para o Reservatório Jaçanã (RNA 3.1, RNA 3.2, RNA 3.3 e RNA 1.2).....	169
FIGURA 5.41 – Rede Hipotética.....	171
FIGURA 5.42 – Estrutura de Solução Apresentada pelo Software GAMS.....	177
FIGURA 5.43 – Curvas de Modulação da Demanda.....	178
FIGURA 5.44 – Potência da Bomba.....	178
FIGURA 5.45 – Operação da Válvula 1.....	179
FIGURA 5.46 – Operação da Válvula 2.....	179
FIGURA 5.47 – Níveis de Operação para o Reservatório 1.....	180
FIGURA 5.48 – Níveis de Operação para o Reservatório 2.....	180
FIGURA 5.49 – Vazões QA1 de Entrada.....	181
FIGURA 5.50 – Vazões QA2 de Entrada.....	181
FIGURA 5.51 – Regime de Operação da ETA (Vazão QA ₁).....	182
FIGURA 5.52 – Regime de Operação da ETA (Vazão QA ₂).....	183
FIGURA 5.53 – Abertura da Válvula 1.....	183
FIGURA 5.54 – Abertura da Válvula 2.....	184
FIGURA 5.55 – Regime de Operação da Bomba de <i>Booster</i> 1 (Rotação).....	184
FIGURA 5.56 – Volumes Úteis do Reservatório 1.....	185
FIGURA 5.57 – Volumes Úteis do Reservatório 2.....	185
FIGURA 5.58 – Volumes Úteis do Reservatório 1 (Comparação).....	192
FIGURA 5.59 – Volumes Úteis do Reservatório 2 (Comparação).....	192
FIGURA D.1 – Função de Autocorrelação para a Série de Demanda para o Reservatório Penha (Estação Verão).....	228
FIGURA D.2 – Função de Autocorrelação para a Série de Demanda para o Reservatório Penha (Estação Outono).....	230
FIGURA D.3 – Função de Autocorrelação para a Série de Demanda para o Reservatório Penha (Estação Primavera).....	232

FIGURA D.4 – Função de Autocorrelação para a Série de Demanda para o Reservatório Edu Chaves (Estação Verão).....	234
FIGURA D.5 – Função de Autocorrelação para a Série de Demanda para o Reservatório Edu Chaves (Estação Outono).....	236
FIGURA D.6 – Função de Autocorrelação para a Série de Demanda para o Reservatório Edu Chaves (Estação Inverno).....	238
FIGURA D.7 – Função de Autocorrelação para a Série de Demanda para o Reservatório Edu Chaves (Estação Primavera).....	240
FIGURA D.8 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Ermelino Matarazzo (Estação Verão).....	242
FIGURA D.9 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Ermelino Matarazzo (Estação Outono).....	244
FIGURA D.10 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Ermelino Matarazzo (Estação Inverno).....	246
FIGURA D.11 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Ermelino Matarazzo (Estação Primavera).....	248
FIGURA D.12 – Função de Autocorrelação para a Série de Demanda para o Reservatório Cangaíba (Estação Verão).....	250
FIGURA D.13 – Função de Autocorrelação para a Série de Demanda para o Reservatório Cangaíba (Estação Outono).....	252
FIGURA D.14 – Função de Autocorrelação para a Série de Demanda para o Reservatório Cangaíba (Estação Inverno).....	254
FIGURA D.15 – Função de Autocorrelação para a Série de Demanda para o Reservatório Cangaíba (Estação Primavera).....	256
FIGURA D.16 – Função de Autocorrelação para a Série de Demanda para o Reservatório Gopoúva (Estação Verão).....	258
FIGURA D.17 – Função de Autocorrelação para a Série de Demanda para o Reservatório Gopoúva (Estação Outono).....	260
FIGURA D.18 – Função de Autocorrelação para a Série de Demanda para o Reservatório Gopoúva (Estação Inverno).....	262
FIGURA D.19 – Função de Autocorrelação para a Série de Demanda para o Reservatório Gopoúva (Estação Primavera).....	264
FIGURA D.20 – Função de Autocorrelação para a Série de Demanda para o Reservatório Jaçanã (Estação Verão).....	266

FIGURA D.21 – Função de Autocorrelação para a Série de Demanda para o Reservatório Jaçanã (Estação Outono).....	268
FIGURA D.22 – Função de Autocorrelação para a Série de Demanda para o Reservatório Jaçanã (Estação Inverno).....	270
FIGURA D.23 – Função de Autocorrelação para a Série de Demanda para o Reservatório Jaçanã (Estação Primavera).....	272
FIGURA D.24 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Jardim Popular (Estação Verão).....	274
FIGURA D.25 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Jardim Popular (Estação Outono).....	276
FIGURA D.26 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Jardim Popular (Estação Inverno).....	278
FIGURA D.27 – Função de Autocorrelação para a Série de Demanda para o Reservatório de Jardim Popular (Estação Primavera).....	280

LISTA DE TABELAS

TABELA 3.1 – Índice de Crescimento Populacional.....	26
TABELA 3.2 – População Total Projetada (habitantes).....	26
TABELA 3.3 – Evolução dos Índices de Atendimento.....	28
TABELA 3.4 – Evolução da Quota Per Capita (l/hab.dia).....	28
TABELA 4.1 – Estatística da Demanda Associada a Cada Reservatório.....	82
TABELA 4.2 – Variações do Modelo de RNA, Modelo de Médias Móveis (MM) e Auto-Regressivo	101
TABELA 5.1 – Características dos Reservatórios da Alça Leste do Sistema Adutor de São Paulo.....	102
TABELA 5.2 – Nós e Cotas da Alça Leste.....	103
TABELA 5.3 – Trechos da Alça Leste.....	104
TABELA 5.4 – Coeficientes de Correlação Para Meses Chuvosos e Secos.....	108
TABELA 5.5 - Consumos Para os Sábados do Mês de Janeiro no Reservatório Penha.....	109
TABELA 5.6 – Consumos Para os Sábados do Mês de Julho no Reservatório Penha.....	110
TABELA 5.7 – Correlações Entre os Consumos dos Sábados do Mês de Julho (Reservatório Penha)..	110
TABELA 5.8 – Correlações Entre os Consumos dos Sábados do Mês de Janeiro(Reservatório Penha)	111
TABELA 5.9 – Testes Realizados com Algumas Topologias no Período Seco.....	113
TABELA 5.10 – Testes Realizados com Algumas Topologias no Período Chuvoso.....	115
TABELA 5.11 – Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Inverno).....	119
TABELA 5.12 – Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Primavera).....	120
TABELA 5.13 – Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Verão).....	120
TABELA 5.14 – Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Outono).....	121
TABELA 5.15 – Resultados da Etapa de Treinamento e Teste para o Reservatório Penha (10 neurônios na camada intermediária e 1500 iterações).....	121
TABELA 5.16 – Resultados da Etapa de Treinamento e Teste para o Reservatório Jardim Popular (10 neurônios na camada intermediária e 1500 iterações).....	126
TABELA 5.17 – Resultados da Etapa de Treinamento e Teste para o Reservatório Edu Chaves (10 neurônios na camada intermediária e 1500 iterações).....	126
TABELA 5.18 – Resultados da Etapa de Treinamento e Teste para o Reservatório Ermelino Matarazzo (10 neurônios na camada intermediária e 1500 iterações).....	126
TABELA 5.19 – Resultados da Etapa de Treinamento e Teste para o Reservatório Jaçanã (10 neurônios na camada intermediária e 1500 iterações).....	126

TABELA 5.20 – Resultados da Etapa de Treinamento e Teste para o Reservatório Gopoúva (10 neurônios na camada intermediária e 1500 iterações).....	127
TABELA 5.21 – Resultados da Etapa de Treinamento e Teste para o Reservatório Cangaíba (10 neurônios na camada intermediária e 1500 iterações).....	127
TABELA 5.22 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.1.1.....	129
TABELA 5.23 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.1.2.....	129
TABELA 5.24 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.1.3.....	129
TABELA 5.25 – Valores de Média e Variância para os Dados de Treino e Teste (RNA 2.1.1).....	130
TABELA 5.26 – Valores de Média e Variância para os Dados de Treino e Teste (RNA 2.1.2).....	130
TABELA 5.27 – Valores de Média e Variância para os Dados de Treino e Teste (RNA 2.1.3).....	130
TABELA 5.28 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.2.1.....	135
TABELA 5.29 – Erro Absoluto Médio para os Períodos de Recorrência (Reservatório Penha-Inverno).....	138
TABELA 5.30 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Inverno).....	140
TABELA 5.31 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório de Penha (Estação Inverno).....	142
TABELA 5.32 – Variância dos Resíduos para Diferentes Modelos AR.....	143
TABELA 5.33 – Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Edu Chaves e Gopoúva.....	148
TABELA 5.34 – Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Cangaíba e Jardim Popular.....	149
TABELA 5.35 – Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Penha e Jaçanã.....	150
TABELA 5.36 – Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Penha e Edu Chaves.....	151
TABELA 5.37 – Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Gopoúva e Cangaíba.....	152
TABELA 5.38 – Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Jardim Popular e Jaçanã.....	153
TABELA 5.39 – Erro Quadrático Médio de Treinamento e Teste para os sete Reservatórios da Rede	154
TABELA 5.40 – Erro para o Reservatório Penha para o Período Chuvoso.....	155
TABELA 5.41 – Erro para o Reservatório Penha para o Período Seco.....	155
TABELA 5.42 – Estatística para os Modelos de Previsão para o Reservatório Penha.....	156
TABELA 5.43 – Estatística para os Modelos de Previsão para o Reservatório Edu Chaves.....	157
TABELA 5.44 – Estatística para os Modelos de Previsão para o Reservatório Ermelino Matarazzo....	157

TABELA 5.45 – Estatística para os Modelos de Previsão para o Reservatório Cangaíba.....	158
TABELA 5.46 – Estatística para os Modelos de Previsão para o Reservatório Gopoúva.....	158
TABELA 5.47 – Estatística para os Modelos de Previsão para o Reservatório Jaçanã.....	159
TABELA 5.48 – Estatística para os Modelos de Previsão para o Reservatório Jardim Popular.....	159
TABELA 5.49 – Coeficiente de Variação dos Consumos.....	160
TABELA 5.50 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.1.1).....	162
TABELA 5.51 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.1.2).....	162
TABELA 5.52 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.1.3).....	162
TABELA 5.53 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.2.1).....	163
TABELA 5.54 – Estatística para os Modelos de Previsão para os Reservatórios Edu Chaves e Gopoúva.....	165
TABELA 5.55 – Estatística para os Modelos de Previsão para os Reservatórios Cangaíba e Jardim Popular.....	165
TABELA 5.56 – Estatística para os Modelos de Previsão para os Reservatórios Penha e Jaçanã.....	165
TABELA 5.57 – Coeficientes de Variação.....	165
TABELA 5.58 – Estatística para os Modelos de Previsão para os Reservatórios Penha e Edu Chaves.....	166
TABELA 5.59 – Estatística para os Modelos de Previsão para os Reservatórios Gopoúva e Cangaíba.....	166
TABELA 5.60 – Estatística para os Modelos de Previsão para os Reservatórios Jardim Popular e Jaçanã.....	166
TABELA 5.61 – Coeficientes de Variação.....	166
TABELA 5.62 – Estatística para os Modelos de Previsão para os sete Reservatórios da Rede.....	167
TABELA 5.63 – Coeficientes de Variação.....	167
TABELA 5.64 – Pontos de Operação da Bomba de <i>Booster 1</i>	186
TABELA 5.65 – Potência Hidráulica Consumida em 24 horas pela Bomba de <i>Booster 1</i>	187
TABELA 5.66 – Regime de Operação das Válvulas.....	188
TABELA 5.67 – Pressões Abaixo do Limite de 5 m. c. a. para as Políticas Operacionais Obtidas a partir da Curva de Demanda Prevista para RNA.....	190
TABELA 5.68 – Potência Hidráulica Consumida pela Bomba do Booster 1 para as Políticas Operacionais Obtidas a partir da Curva de Demanda Prevista por RNA.....	191
TABELA D.1 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Verão).....	227

TABELA D.2 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Penha (Estação Verão).....	227
TABELA D.3 – Variância dos Resíduos para Diferentes modelos AR.....	228
TABELA D.4 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Outono).....	229
TABELA D.5 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Penha (Estação Outono).....	229
TABELA D.6 – Variância dos Resíduos para Diferentes modelos AR.....	230
TABELA D.7 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Primavera).....	231
TABELA D.8 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Penha (Estação Primavera).....	231
TABELA D.9 – Variância dos Resíduos para Diferentes modelos AR.....	232
TABELA D.10 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Verão).....	233
TABELA D.11 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Verão).....	233
TABELA D.12 – Variância dos Resíduos para Diferentes modelos AR.....	234
TABELA D.13 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Outono).....	235
TABELA D.14 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Outono).....	235
TABELA D.15 – Variância dos Resíduos para Diferentes modelos AR.....	236
TABELA D.16 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Inverno).....	237
TABELA D.17 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Inverno).....	237
TABELA D.18 – Variância dos Resíduos para Diferentes modelos AR.....	238
TABELA D.19 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Primavera).....	239
TABELA D.20 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Primavera).....	239
TABELA D.21 – Variância dos Resíduos para Diferentes modelos AR.....	240
TABELA D.22 – Média e Desvio Padrão para a Série de Consumos do Reservatório de Ermelino Matarazzo (Estação Verão).....	241

TABELA D.23 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Verão).....	241
TABELA D.24 – Variância dos Resíduos para Diferentes modelos AR.....	242
TABELA D.25 – Média e Desvio Padrão para a Série de Consumos do Reservatório de Ermelino Matarazzo (Estação Outono).....	243
TABELA D.26 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Outono).....	243
TABELA D.27 – Variância dos Resíduos para Diferentes modelos AR.....	244
TABELA D.28 – Média e Desvio Padrão para a Série de Consumos do Reservatório de Ermelino Matarazzo (Estação Inverno).....	245
TABELA D.29 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Inverno).....	245
TABELA D.30 – Variância dos Resíduos para Diferentes modelos AR.....	246
TABELA D.31 – Média e Desvio Padrão para a Série de Consumos do Reservatório de Ermelino Matarazzo (Estação Primavera).....	247
TABELA D.32 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Primavera).....	247
TABELA D.33 – Variância dos Resíduos para Diferentes modelos AR.....	248
TABELA D.34 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Verão).....	249
TABELA D.35 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Verão).....	249
TABELA D.36 – Variância dos Resíduos para Diferentes modelos AR.....	250
TABELA D.37 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Outono).....	251
TABELA D.38 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Outono).....	251
TABELA D.39 – Variância dos Resíduos para Diferentes modelos AR.....	252
TABELA D.40 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Inverno).....	253
TABELA D.41 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Inverno).....	253
TABELA D.42 – Variância dos Resíduos para Diferentes modelos AR.....	254
TABELA D.43 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Primavera).....	255

TABELA D.44 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Primavera).....	255
TABELA D.45 – Variância dos Resíduos para Diferentes modelos AR.....	256
TABELA D.46 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopoúva (Estação Verão).....	257
TABELA D.47 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopoúva (Estação Verão).....	257
TABELA D.48 – Variância dos Resíduos para Diferentes modelos AR.....	258
TABELA D.49 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopoúva (Estação Outono).....	259
TABELA D.50 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopoúva (Estação Outono).....	259
TABELA D.51 – Variância dos Resíduos para Diferentes modelos AR.....	260
TABELA D.52 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopoúva (Estação Inverno).....	261
TABELA D.53 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopoúva (Estação Inverno).....	261
TABELA D.54 – Variância dos Resíduos para Diferentes modelos AR.....	262
TABELA D.55 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopoúva (Estação Primavera).....	263
TABELA D.56 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopoúva (Estação Primavera).....	263
TABELA D.57 – Variância dos Resíduos para Diferentes modelos AR.....	264
TABELA D.58 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Verão).....	265
TABELA D.59 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Verão).....	265
TABELA D.60 – Variância dos Resíduos para Diferentes modelos AR.....	266
TABELA D.61 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Outono).....	267
TABELA D.62 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Outono).....	267
TABELA D.63 – Variância dos Resíduos para Diferentes modelos AR.....	268
TABELA D.64 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Inverno).....	269

TABELA D.65 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Inverno).....	269
TABELA D.66 – Variância dos Resíduos para Diferentes modelos AR.....	270
TABELA D.67 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Primavera).....	271
TABELA D.68 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Primavera).....	271
TABELA D.69 – Variância dos Resíduos para Diferentes modelos AR.....	272
TABELA D.70 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Verão).....	273
TABELA D.71 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Verão).....	273
TABELA D.72 – Variância dos Resíduos para Diferentes modelos AR.....	274
TABELA D.73 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Outono).....	275
TABELA D.74 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Outono).....	275
TABELA D.75 – Variância dos Resíduos para Diferentes modelos AR.....	276
TABELA D.76 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Inverno).....	277
TABELA D.77 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Inverno).....	277
TABELA D.78 – Variância dos Resíduos para Diferentes modelos AR.....	278
TABELA D.79 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Primavera).....	279
TABELA D.80 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Primavera).....	279
TABELA D.81 – Variância dos Resíduos para Diferentes modelos AR.....	280

1 – INTRODUÇÃO

Os sistemas municipais de abastecimentos de água são projetados e operados de maneira a atingir vários propósitos, distinguindo-se dois grandes grupos. Um primeiro grupo visa atingir os objetivos técnicos, normalmente ligados ao desempenho hidráulico, tais como: garantia de pressões mínimas e máximas, garantia de água suficiente para a proteção contra incêndio, confiabilidade operacional, e outros. Outro grupo visa os objetivos econômicos, que normalmente se traduzem pela minimização de custos operacionais.

A busca por maior eficiência no gerenciamento dos recursos hídricos constitui, sem dúvida um dos temas atuais de importância estratégica no cenário mundial. Hoje tomamos consciência da escassez da água e da necessidade de preservar e bem gerir este elemento vital e finito.

Cada vez mais, os grandes centros urbanos das regiões Sul e Sudeste do Brasil, localizados em áreas originalmente com disponibilidade de recursos hídricos para abastecimento em qualidade e quantidade, estão sendo obrigados a fazer a captação de água em fontes cada vez mais distantes em decorrência do crescimento da demanda de água ou da má qualidade no manancial. Assim em decorrência do contínuo processo de crescimento da população e urbanização, há uma necessidade cada vez maior de investimento em pesquisa visando o melhor gerenciamento dos recursos hídricos.

Como fornecedores de água para quase 50 % da população mundial, as companhias de água municipais exercem um papel vital no gerenciamento deste recurso. Com a continuidade da migração para as cidades, as companhias de água municipais têm a complexa tarefa de fornecer água com custo otimizado para manter as cidades funcionando. Os recursos limitados de energia,

o suprimento ineficiente de água e as crescentes preocupações ambientais tornam a tarefa de distribuição de água ainda mais desafiadora.

Atualmente mais de 40 % da população mundial mora em áreas com recursos limitados de água e provavelmente este percentual crescerá para 50 % até o ano 2025, já que a demanda de água também cresce. Alguns municípios em particular têm visto um aumento na demanda de água devido, principalmente, ao crescimento da população, à migração da área rural para a área urbana, e à industrialização. Muitos municípios estão tendo dificuldades crescentes para assegurar fontes adequadas de água que atendam a essa crescente demanda.

Como muitas municipalidades em todo o mundo enfrentam carências de água e também têm a necessidade de minimização dos custos, que potencialmente podem ser transferidos como benefício ao consumidor na forma de tarifas menores, a análise e a previsão de demandas são de fundamental importância no planejamento da operação de sistemas urbanos de abastecimento, com o objetivo de assegurar a disponibilidade de água.

O consumo de água de uma população varia de região para região, de cidade para cidade e dentro de uma mesma cidade pode variar muito de um setor de distribuição para outro. Os principais fatores associados à definição do consumo são o nível sócio econômico dos consumidores, os tipos de residências, o tipo de uso do solo, as características das instalações hidráulicas individuais, o método de medida de consumo, o preço da água e as condições climáticas.

A consideração desses fatores motivou a proposição da presente pesquisa, enfocando um aspecto em especial, de enorme importância na modelagem da operação dos sistemas, a previsão da demanda horária. Em um sentido mais amplo (MAYS e TANG, 1992) uma previsão é uma estimativa de um parâmetro ou estado futuro o qual apresenta quatro dimensões: quantidade; qualidade; tempo e espaço. Na escala de discretização horária, com horizonte de 24 horas, um modelo de previsão permite: (a) gerenciar adequadamente os recursos de controle, reservação e bom andamento da rede e do sistema como um todo, permitindo inclusive a redução dos custos devido à operação integrada, espacial e temporalmente, do sistema; (b) garantir maiores chances de efetivo atendimento da demanda, diminuindo os riscos de déficit em pontos de consumo

específicos, ou riscos de extravasamento nos reservatórios; (c) identificar as melhores formas de implementar manobras especiais, durante condições de emergência ou manutenção.

Uma das grandes dificuldades na previsão da demanda é a presença da sazonalidade devido a períodos distintos de chuva e seca no ano. Em um primeiro teste optou-se em estratificar os dados em dois períodos, seco e chuvoso. Após tais testes decidiu-se estratificar os dados em quatro períodos, referentes às quatro estações do ano, com parâmetros diferenciados em cada modelo (denominada estratificação sazonal dos dados).

A previsão de demanda é um tema sempre presente quando se pretende criar ou expandir um sistema. Existem vários métodos de previsão de demanda de água, porém, métodos que utilizam RNA's (redes neurais artificiais) são escassos na literatura. A potencial vantagem do uso de RNA's para a solução de tal problema e a necessidade de desenvolvimento de algoritmos de previsão de demanda de água em sistemas urbanos de abastecimento, como novas metodologias específicas para problema de previsão no Brasil, constituem as principais motivações para estudar a performance do uso de RNA's nesta tese.

O trabalho visa fazer uma previsão da demanda de água em sistemas urbanos de abastecimento, usando a técnica de redes neurais artificiais. A modelagem inclui versão univariada e multivariada, utilizando-se o ambiente de programação com o software MATLAB versão 6.0. Também foram realizadas previsões usando os modelos de médias móveis e auto-regressivo para fins comparativos.

1.1 – MOTIVAÇÃO PARA A UTILIZAÇÃO DE REDES NEURAIIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA's) funcionam conceitualmente de forma similar ao cérebro humano, tentando reconhecer regularidades e padrões de dados. São capazes de aprender com a experiência e proceder à generalização baseadas no conhecimento prévio sobre o fenômeno ou processo em estudo. As RNA's encontraram aplicações em muitas áreas diferentes, sendo nesse trabalho enfocada a aplicação na área do cálculo da previsão de demanda.

Algumas características importantes presentes nas RNA's são:

- capacidade de processamento paralelo;
- representação distribuída de conhecimento;
- tolerância à falhas;
- possibilidade de incorporar redundâncias;
- grande capacidade de adaptação;
- flexibilidade no atendimento a critérios de generalização;
- possibilidade, de incorporação de poderosas ferramentas algébricas facilitando a análise e interpretação dos resultados.

A eficácia das ferramentas de engenharia, baseadas nos conceitos e algoritmos mais avançados de redes neurais artificiais, se manifesta na forma de dois aspectos básicos: redução drástica da participação do usuário (geralmente não especializado) em seu desenvolvimento e capacidade de tratamento a problemas de elevada complexidade.

1.2 – JUSTIFICATIVA

A complexidade inerente aos processos de previsão apresenta um desafio ao engenheiro quando este se depara com o dimensionamento e operação de sistemas de abastecimento. Este fato deve-se ao número de condicionantes físicos que estão envolvidos, como o número de variáveis independentes que afetam o consumo. A grande vantagem do uso de RNA's para a solução de tal problema e a necessidade de desenvolvimento de algoritmos de previsão de demanda de água em sistemas urbanos de abastecimento, com novas metodologias específicas para problemas de previsão no Brasil, foram as principais motivações para estudar a performance do uso de RNA's para a solução da previsão de demanda horária de água.

Com base no conjunto de potenciais benefícios e considerando a eficiência da técnica de previsão por redes neurais artificiais, amplamente reportadas na literatura, é que se formulou a presente proposta de pesquisa.

1.3 – DESCRIÇÃO DO TRABALHO

O trabalho está dividido em seis capítulos. No Capítulo I apresenta-se a introdução ao trabalho. O Capítulo II apresenta os objetivos. O Capítulo III traz uma revisão bibliográfica, destacando ao leitor a importância da previsão em todos os setores, e também apresenta alguns trabalhos relevantes ao estudo. No Capítulo IV encontra-se a metodologia utilizada. No Capítulo V é realizado o estudo de caso, sendo apresentados os resultados obtidos. No Capítulo VI estão as conclusões finais, as referências bibliográficas e os anexos.

O estudo sobre previsão multivariada da demanda de água e RNA's compreendeu um resumo dos principais conceitos nas duas áreas. Além de buscar um embasamento teórico necessário ao desenvolvimento de um modelo de previsão de água, procurou-se a identificação de considerações práticas visando aplicá-las na modelagem de RNA's para a previsão da demanda horária de água, para implementação no estudo de caso.

2 – OBJETIVO DO TRABALHO

O objetivo principal do trabalho é estudar o uso de redes neurais artificiais (RNA) na previsão univariada e multivariada da demanda de água em sistemas urbanos de abastecimentos, considerando a escala de discretização horária e diária. O trabalho de pesquisa envolve estudos na área de RNA e a análise das variáveis que influenciam a demanda e séries temporais.

Pretendeu-se com este estudo verificar a capacidade das redes neurais artificiais para prover prognósticos confiáveis de valores futuros de demanda de água. Para alcançar este objetivo a metodologia foi testada em um estudo de caso utilizando como entrada um conjunto de dados observados de consumo de água obtidos da SABESP (Sistema de Abastecimento de São Paulo), para a região metropolitana de São Paulo.

3 – REVISÃO BIBLIOGRÁFICA

Este capítulo tem o objetivo de fortalecer a importância da previsão de demanda, em setores diferenciados e principalmente no setor de abastecimento urbano de água. Para tanto apresenta alguns trabalhos que são relevantes a pesquisa, mostrando com isso, o que esta sendo feito em âmbito de previsão horária e diária, tanto de carga elétrica, quanto de água. Mostrando também alguns trabalhos direcionados a região metropolitana de São Paulo, na qual a pesquisa se desenvolve.

3.1 – A IMPORTÂNCIA DA PREVISÃO DE DEMANDA NA INDÚSTRIA EM GERAL

Os últimos anos foram marcados por grandes transformações nos conceitos gerenciais, especialmente no que toca à função de operação. O movimento da qualidade total e o conceito de produção enxuta trouxeram consigo um conjunto de técnicas e procedimentos, que contribuíram para um grande avanço da qualidade, produtividade e redução dos custos.

Um conceito que despontou no início dos anos 90, foi o *Supply Chain Management* (SCM) ou o Gerenciamento da Cadeia de Suprimentos (CS). Os extraordinários resultados obtidos pelas empresas que já conseguiram implementá-lo com sucesso são uma garantia de que este não é apenas um modismo gerencial, mas algo que vem crescentemente despertando a atenção da alta cúpula gerencial nas grandes e mais modernas empresas internacionais. Pesquisas preliminares sobre os ganhos que podem ser obtidos pela utilização correta do conceito, indicam que as empresas tem obtido reduções substanciais nos custos operacionais da cadeia de suprimentos.

Em síntese, o gerenciamento da cadeia de suprimentos representa o esforço de integração dos diversos participantes do canal de distribuição através da administração compartilhada de processos-chave de negócios que interligam as diversas unidades organizacionais e membros do canal, desde o consumidor final até o fornecedor inicial de matérias-primas.

A administração da demanda é parte fundamental do gerenciamento da cadeia de suprimentos, captando, compilando e atualizando continuamente dados de demanda, com o objetivo de equilibrar a oferta com a demanda. Nas indústrias em geral, a previsão da demanda vem ganhando uma importância cada vez maior, e os efeitos de uma má previsão podem ser sentidos ao longo de toda a organização. No entanto, as empresas de saneamento não parecem ainda ter reconhecido o papel fundamental da previsão e administração da demanda como fonte de aprimoramento operacional.

3.2 – ASPECTOS DE PREVISÃO DE DEMANDA

A demanda denota uma necessidade a ser atendida, onde pode ocorrer uma relação direta entre mercado e empresa ou via um mediador que será o centro de distribuição (Figura 3.1).

Demandas podem incluir as necessidades do mercado (clientes finais), as necessidades de distribuição, as necessidades de reabastecimento (armazéns na indústria em geral; reservatórios em um sistema de abastecimento de água) e a necessidade entre processos (plantas industriais ou ETA's em sistemas de saneamento). As necessidades da empresa envolvem as demandas por produtos acabados, pedidos nos postos de abastecimento e as demandas a serem previstas, fazendo assim uma antecipação.




Figura 3.1 – Exemplos de Formação da Demanda

Na indústria em geral a previsão de demanda é um grande desafio. Muitas vezes o cliente não sabe dizer exatamente o que e quanto quer comprar, com antecedência. Daí segue-se à dificuldade da previsão

3.3 – PREVISÃO SEGUNDO O TIPO DE PRODUÇÃO

As previsões enfocam alguns tipos de processos, como o da produção para estoque, que requer a previsão do produto final, ou a montagem por encomenda, que requer a previsão dos componentes que formarão o produto final e por fim o processo de produção sob encomenda, que requer visibilidade da capacidade de produção disponível.

3.4 – A PREVISÃO MOVE A CADEIA DE SUPRIMENTOS

A previsão da demanda é o “gatilho” que movimenta a cadeia de suprimentos, ela é o agente essencial em diversas áreas da gestão da cadeia, como na área financeira, a qual possibilita o planejamento da necessidade de recursos, na área de recursos humanos, possibilitando o planejamento de modificação no nível de mão de obra, na área de vendas agendando as promoções, na área de planejamento, facilitando a geração de planos estratégicos e táticos e na área operacional, no gerenciamento de estoques.

3.5 – O QUE É PREVISÃO

Prever é o processo de estimar um evento futuro baseado em dados passados (histórico). Estes dados são combinados sistematicamente de uma forma predeterminada até se obter uma estimativa futura (ADAM & EBERT, citado por SILVA, O. S., 2002).

Prever demanda por produtos e serviços é uma das mais importantes tarefas no gerenciamento de empresas. A previsão de demanda significa apoiar a gerência a decidir, onde, quando e quanto produzir ou realizar serviços. Toda a hierarquia de decisão da cadeia de suprimentos é afetada pela previsão da demanda, incluindo etapas tais como:

- Planejamento de capacidade;
- Planos mestre da produção;
- Planejamento de estoque;
- Sequenciamento, alocação de recursos.

A previsão combina dados via um modelo matemático para estimar eventos futuros, já a predição estima eventos futuros com base em considerações subjetivas, sem combinações predeterminadas. (BEASLEY, citado por SILVA, O. S., 2002).

3.6 – MÉTODOS DE PREVISÃO DE DEMANDA

Existem dois métodos de estimativa futura, os métodos quantitativos (previstos) e os métodos qualitativos (preditos). Os métodos qualitativos são métodos não analíticos baseados em julgamento, intuição, entrevista, e usados para criar cenários futuros. Os métodos quantitativos que baseiam-se em um modelo matemático (Figura 3.2).




Figura 3.2 – Métodos de Previsão

Os modelos quantitativos são os mais usados em ferramentas de apoio a decisão, usam informações provenientes de histórico e contemplam padrões de comportamento do fenômeno, como:

- Tendências;
- Sazonalidade;
- Variações Aleatórias;
- Variações Cíclicas.

Três condições devem ser observadas quanto aos dados, são elas:

- A existência de informações históricas;
- As informações históricas podem ser transformadas em dados numéricos;
- Padrões passados podem ser repetidos no futuro.

A Figura 3.3 mostra os modelos quantitativos de previsão mais conhecidos.




Figura 3.3 – Métodos Quantitativos de Previsão

3.7 – PREVISÃO DE DEMANDA DE ÁGUA EM SISTEMAS URBANOS DE ABASTECIMENTO

3.7.1 – INTRODUÇÃO

A previsão de demanda de consumo de água é de grande importância em vários setores das empresas, tais como: o setor de projeto, o de controle de perdas e o de controle operacional.

No setor de projeto, quando a empresa vai projetar um sistema hidráulico, são definidos: a capacidade dos reservatórios, cotas geométricas dos pontos, diâmetros e comprimentos das tubulações, localização dos acessórios, como válvulas, “boosters” e outros. Para tanto o conhecimento da demanda é de fundamental importância

Qualquer ação a ser tomada em um sistema de abastecimento de água é planejada. Quando os profissionais da área planejam, eles determinam no presente quais cursos de ação serão tomados no futuro. O primeiro passo no planejamento é, portanto, prever, ou estimar a demanda de água futura.

Os procedimentos de previsão utilizados na prática variam muito, podendo ser simples e intuitivos ou mais quantitativos e complexos. No primeiro caso, pouca ou nenhuma análise de

dados é envolvida, enquanto, no segundo caso esta análise pode ser considerável (MORETTIN e TOLOI, 1985). É imperativo que as empresas de abastecimento tenham abordagens eficazes para prever, e que a previsão seja parte integrante do planejamento, pois a previsão é um meio de fornecer informações para uma conseqüente tomada de decisões, visando determinados objetivos.

Os projetistas necessitam de previsões de longo prazo para elaborar os projetos de ampliação ou até mesmo a construção de uma rede de abastecimento. O setor operacional, precisa de uma previsão a curto prazo para ajudar a tomar decisões a respeito de questões mais imediatas, como por exemplo, desviar a água de um reservatório para outro de modo a evitar a demanda reprimida em um dos reservatórios do sistema, ou ainda evitar grande produção de água na ETA sem que haja necessidade, evitando assim a reservação. No projeto, quando prevemos esta situação evitamos a construção de reservatórios de grande porte, que evidentemente oneram o custo da obra.

As demandas reprimidas podem ser corrigidas de diversas maneiras, buscando o equilíbrio da distribuição com o número de consumidores. Para tanto devemos adotar alguns procedimentos que devem seguir uma programação com soluções lógicas, baseando-se no conhecimento operacional característico do sistema, como por exemplo: instalação de estruturas de controle nos centros de reservação e distribuição de água tratada, conhecimento das curvas de demanda e capacidade de abastecimento do sistema entre outros.

Hoje a automação, isto é, o controle total do sistema de abastecimento à distância é uma realidade. A automação vem tornando-se uma ferramenta prática para a economia de recursos financeiros e operação de um sistema de abastecimento público de água. A previsão de demanda é um dos parâmetros que promove uma hegemonia de controle, otimizando o período de utilização de equipamento elétrico e mecânico, o volume produzido e variações do volume de reservação; evitando assim manobras inesperadas que possam prejudicar o sistema ou até mesmo causar um acidente hidráulico.

As empresas ainda não consideram a previsão um fator importante para o sistema operacional. As decisões na operação são tomadas de imediato sem um prévio conhecimento das demandas futuras. Em algumas empresas, decisões como: a maior ou menor produção de água

nas ETA's são tomadas de forma intuitiva com base na avaliação do operador do sistema naquele instante. Outras possuem uma produção de água constante, não interessando, naquele momento, se a água produzida será consumida ou reservada, podendo ocorrer problemas como o de extravasamento no reservatório, fazendo com que aumentem as perdas no sistema.

O sistema de abastecimento é dinâmico. A maioria das empresas não possuem os SIGs (Sistemas de Informações Georeferenciadas). Com o passar do tempo as redes adutoras certamente passarão por manutenções, que geralmente são ações de caráter emergencial. Infelizmente devido à falta de pessoal ou de uma política de prevenção nas empresas, não existem ações preventivas no sistema. Segundo FRANCATO (2002), o pessoal do departamento de manutenção toma medidas que solucionam o problema no sistema de maneira rápida e econômica, quase sempre sem consultar o departamento de projeto e por consequência não alterando o setor de cadastramento. Assim, em muitos casos, os reservatórios têm seus níveis operacionais alterados, novas ligações são anexadas às redes, mudando até mesmo a topologia do sistema, sem as devidas alterações cadastrais.

Sendo assim cada alteração realizada no sistema, provoca alterações na demanda de consumo, isto é, cada metro de tubulação, incluída no sistema, há variação da demanda. Como a previsão por RNA's trabalha com dados observados reais de consumo e calibra o modelo usando estes dados, podemos fazer uma previsão a curto prazo, hora a hora, dia a dia, conforme a necessidade da empresa, absorvendo as modificações feitas no sistema e analisando o novo perfil de consumo.

Já no setor de perdas, as empresas possuem vários programas de redução de perdas, que dependem de pessoal especializado e de recursos financeiros disponíveis para a sua execução.

Algumas empresas apostam na implantação maciça de macromedição e substituição da micromedição, outras em programas ostensivos de localização de vazamentos e algumas na capacitação dos funcionários. Para as empresas a previsão da demanda não é um fator relevante, porém a melhor solução será alcançada quando houver a aplicação de todos esses processos em conjunto.

Com a previsão de demanda não poupamos apenas água, mas os produtos químicos, a energia elétrica, rotinas de manutenção preventiva, desperdício de mão de obra, obras de ampliação do sistema e o maior ganho, preservamos o meio ambiente.

3.7.2 – ESTUDOS SOBRE PREVISÃO DE DEMANDA

Quando se pretende criar ou expandir um sistema, a previsão de demanda é fundamental. De uma forma geral, a previsão é uma afirmação sobre o futuro. Entretanto, ao contrário da “predição” a previsão é condicional sobre o que é esperado para acontecer, caso uma série de hipóteses admitidas venham a se tornar válidas. Portanto, a previsão pode ser entendida como uma projeção ou extrapolação das tendências do passado (BOLAND, 1985).

A previsão de demanda pode ser classificada de várias formas, de acordo com diversos critérios. Quanto à variável prevista, a previsão pode ser classificada como previsão hidrológica, previsão de carga elétrica, previsão de consumos de água e outros. Dependendo da variável prevista, as técnicas utilizadas podem sofrer variações em função das características de cada processo. Quanto ao horizonte de previsão, pode-se classificar a previsão como de longo prazo ou curto prazo. A previsão do longo prazo está associada à definição de parâmetros para planejamento ou projetos de novos sistemas. A previsão de curto prazo está associada aos estudos de efeitos de medidas de racionamento ou a operação em tempo real.

No caso de previsão de longo prazo, necessária para fins de projeto, procura-se geralmente, prever três valores básicos, a demanda média de um dia de consumo médio, a demanda média de um dia de consumo máximo e o pico de consumo de um dia de consumo máximo. Na previsão de curto prazo, procura-se definir o padrão de consumo, isto é, a distribuição dos consumos ao longo do tempo.

A previsão de consumos pode estar ligada a um consumo agregado, como o de uma região, ou de uma cidade ou de um setor abastecido por uma fonte definida ou a consumos individuais, onde se analisam os perfis associados a ligações domésticas, comerciais, industriais, etc.

Os principais fatores associados à definição do consumo são o nível sócio econômico dos consumidores, os tipos de residências, o tipo de usos do solo, as características das instalações hidráulicas individuais, o método de medida de consumo, o preço da água e as condições climáticas, especialmente a temperatura.

A operação em tempo real de um sistema de abastecimento de água requer informações atualizadas em diversos pontos da rede de distribuição, visando à decisão sobre as manobras a serem mantidas (ex. *boosters*). O planejamento da operação destes elementos tem como referência a necessidade de atendimento a custo mínimo e com garantia de um padrão mínimo de confiabilidade. Tipicamente, o plano de operação é preparado para um período de 24 horas adiante. Existem diversas razões para a escolha deste horizonte, que são: as demandas apresentarem um pronunciado ciclo diário; a tarifa de energia elétrica, determinante direto dos custos de operação, também apresenta diferenciação horária em muitos sistemas (hora-sazonal); existe sempre uma certa hora do dia em que o estado do sistema (ex. nível dos reservatórios) pode ser estabelecido como meta desejável (ex. reservatório cheio às 6:00 horas), facilitando o planejamento da operação uma vez que tal nível funciona como uma condição de contorno na modelagem.

Embora o horizonte de planejamento usual seja o de 24 horas, pode ser necessário em alguns casos considerar o ciclo semanal diante do maior volume dos reservatórios, com capacidade de regularização semanal.

Os modelos de previsão de demanda de curto prazo tem sido utilizados basicamente para estudos de racionamento em períodos críticos de atendimento e para a operação em tempo real de sistemas de abastecimento de água, gás e eletricidade.

A previsão de demanda de curto prazo foi inicialmente utilizada na área de eletricidade. DRYAR (1944) e SCHILLER (1945) estudaram a influência das condições meteorológicas e da iluminação do dia sobre a carga dos sistemas elétricos.

DAVIES (1945) fez um trabalho muito interessante, buscando a correlação entre a carga elétrica demandada por um sistema e as condições climáticas. Dos fatores meteorológicos,

Davies enfoca cinco como sendo os mais importantes: temperatura e velocidade do vento, como elementos controladores da demanda de calor e nebulosidade, visibilidade e precipitação como determinantes da demanda de iluminação. Inicialmente, Davies tomou os dados de um ano de observações e efetuou uma regressão linear múltipla com três fatores meteorológicos, definidos como temperatura efetiva, poder de resfriamento do vento e índice de iluminação diária. Para eliminar as tendências sazonais e de longo prazo, bem como o efeito do dia da semana, foi ajustado aos dados de consumos, um polinômio de 6º grau e uma correlação do dia da semana. As diferenças entre os consumos reais e os valores ajustados por polinômio foram correlacionados com os fatores meteorológicos já descritos. Para um refinamento da análise, Davies efetuou correlações gráficas não lineares entre os consumos de energia e os fatores meteorológicos, para avaliar os desvios em relação à hipótese de linearidade admitida.

PERRY (1981) desenvolveu dois modelos alternativos de previsão para serem utilizados em associação a um modelo otimizador da operação de elevatórias da empresa East Worcesershire Waterworks (Inglaterra).

O uso da previsão de demanda de consumo de água em curto prazo tem merecido atenção freqüente, face à necessidade de economizar energia, através de uma operação otimizada das elevatórias do sistema.

Os consumos são tratados, no primeiro, como uma série temporal composta por uma componente periódica e uma componente residual.

Considerando a componente periódica com um período de 24 horas, pode ser modelada como uma série de Fourier, onde no instante k , seu valor é dado por:

$$yp(k) = a_0^p + \sum_{i=1}^{np} (a_i^p \cdot \sin i\omega_0 k + b_i^p \cdot \cos i\omega_0 k) \quad (3.1)$$

onde:

np, a_i^p, b_i^p são números a determinar.

w_0 = frequência natural

A componente residual pode ser escrita como um modelo ARMA (auto-regressive-moving-average), na forma:

$$yr(k) = \sum_{i=1}^n a_i^r . yr(k-i) + \sum_{j=0}^m b_j^r . u(k-j) + \sum_{l=1}^p d_l . w(k-l) \quad (3.2)$$

onde:

u é um parâmetro meteorológico,

w é um ruído branco,

n, m, p, a_i^r, b_j^r e d_l são constantes a determinar.

A segunda alternativa consiste em considerar a demanda total como uma série temporal não estacionária e expandi-la da forma como fizeram FARMER e POTTON (1968) que desenvolveram um modelo em que só utilizavam os dados disponíveis no computador no centro de controle, prevendo a carga unicamente a partir de seus valores atual e anteriores. Argumentavam que para estimar a carga, analisando sua dependência com parâmetros meteorológicos, tornaria a tarefa duplamente difícil, pois haveria a necessidade de se desenvolver outro modelo de previsão meteorológica.

Para o propósito de previsão, a demanda pode ser considerada como uma combinação de duas componentes: a primeira, tendência de longo tempo, inclui o crescimento econômico, as variações sazonais e as periodicidade e a segunda, que inclui as componentes de variações diárias e horárias oriundas das flutuações das condições climáticas. O método utilizado para analisar essas componentes foi à decomposição espectral.

Segundo Perry, a segunda alternativa oferece melhor precisão para previsões até 4 horas, em relação à primeira. Entretanto, como a primeira é de mais fácil execução, sugere que seja a utilizada em tempo real, e é a que foi implementada com sucesso no sistema de Worcestershire.

BOLAND (1985) propõem formas diversas de classificação de métodos de previsão de longo prazo. Uma síntese das duas idéias permite propor a seguinte estrutura de classificação:

- Métodos consensuais, são aqueles que visam uma explicação explícita do processo e se concentram em pura predição, causando pouca confiabilidade nos resultados;
- Métodos de extrapolação temporal, que procuram explicar as alterações do consumo como função do tempo. Este é um processo útil para previsões de curto prazo, mas pouco eficaz para previsões de períodos de alguns anos;
- Métodos de coeficientes únicos, que incluem a tradicional aproximação de consumo per capita ou consumo por ligação;
- Métodos de coeficientes múltiplos, que relacionam o consumo com variáveis importantes, e os modelos econométricos de demanda;
- Métodos probabilísticos, que proporcionam um meio de considerar a incerteza da previsão.

Qualquer um dos métodos acima pode ser utilizado, atribuindo-se probabilidades subjetivas aos vários cenários possíveis do futuro, dependentes das várias fontes de incerteza relacionadas aos níveis de consumo futuro da água.

YOUNG et al. (1985) relatam suas experiências no desenvolvimento de um modelo previsional para a região metropolitana de Denver (Colorado, USA). O modelo é composto de duas partes, em que na primeira aproximação os fatores de uso são aplicados a variáveis demográficas (população, número de residência). A partir de uma regressão do consumo com diversas variáveis econômicas (tamanho do lote, preço), as previsões iniciais são então refinadas.

Como fatores de uso foram considerados: número de residências unidomiciliares com medição (*SFM*), número de residências unidomiciliares sem medição (*SFF*), número de

residências multi-domiciliares (**MF**), número de empregados na indústria e comércio (**E**), população (**P**) e fator de consumo por residência unidomiciliar (**F**).

A demanda de um setor **D** é expressa por:

$$D = F \times SFM + 630 \times SFF + 217 \times MF + 45 \times E + 14 \times P \quad (3.3)$$

O refinamento da consideração dos fatores econômicos está associada à definição do consumo diário **f**, dado por:

$$f = f_0 + 350 \times a_1 \times (A - A_m) - 118,7 \times a_2 \times (d_p - d_{pm}) + 3,59 \times a_3 \times (I - I_m) + 31,2 \times a_4 \times (HH - HH_m) \quad (3.4)$$

onde:

f₀ = é o valor base médio do consumo **SFM** (2.500 l/residência/dia),

A_m = tamanho médio do lote (**A**= 0,24 acres),

d_p = preço marginal da água,

I_m = renda média por residência,

HH = número de ocupantes por residência,

a_i = coeficiente de ajuste.

A apresentação das expressões deste método visa mostrar o uso conjunto de um modelo com coeficiente único associado a outro de múltiplos coeficientes.

NVULE (1985) desenvolveu dois modelos de previsão de demandas, para prever a data de início de racionamento, durante uma estiagem ocorrida na região de Austin, Texas (EUA), em 1984. Com os modelos, avaliou também o efeito das medidas de racionamento sobre o consumo do período. Em ambos os modelos, o consumo é relacionado com a temperatura (número de dias com temperatura máxima superior a 29,4^o C) e com o número de dias chuvosos.

A opção por modelos de previsão com base em séries temporais parece ter sido a forma mais frequentemente adotada por diversos autores. STERLING e BAGRELIA (1985) utilizaram um modelo auto-regressivo a dois estágios, onde num primeiro estágio é prevista a tendência média diária para um horizonte semanal e no segundo estágio um outro modelo ARIMA faz a previsão horária com horizonte de 24 horas. HARTLEY e POWELL (1991) deram continuidade a este trabalho combinado a técnica de previsão por séries temporais com um procedimento heurístico. As previsões do modelo de série temporal são ajustadas pelo conhecimento prévio contido em uma base de dados contendo informações sobre eventos não usuais que poderiam influenciar o consumo de água. JOWITT e XU (1992) analisaram a influência de dados meteorológicos na demanda de água e concluíram não haver uma correlação específica. Diante desta constatação, tais autores optaram pela modelagem tradicional via séries temporais.

WILLIAMS e COULBECK (1987) descrevem sucintamente um modelo utilizado na cidade de Wolverhampton (Inglaterra), em que os consumos são ajustados por uma série de Fourier com seis harmônicos, considerando-se alguns perfis de consumo típicos para determinados dias da semana.

Em todos os modelos de curto prazo pesquisados, nota-se a preocupação em destacar a qualidade do modelo em função da previsão dos valores previstos quando comparados com os reais. Esta forma é bastante simples de calcular e indica resultados na forma de desvios ou de coeficientes de correlação que são facilmente entendidos pelos órgãos de operação.

Embora haja um grande número e variedade de técnicas para previsão de demanda de água em horizonte anual com intervalo mensal (ex. DZIEGIELEVUSKI e BORLAND, 1989), o mesmo não se pode dizer em relação aos modelos de previsão em escala horária. Conforme citado por SHVARTSER et al. (1993), a análise de séries temporais foi utilizada por MOSS (1978) e GRAY (1978) para a previsão de demanda horária em modelos de planejamento diário. Para descrever a influência da temperatura e das precipitações no consumo diário de água, MAIDMENT e PANZER (1984) e MAIDMENT et al. (1985) desenvolveram estudos com base em funções de transferência, os quais exigiram grande extensão dos dados observados para calibração dos modelos, chegando a 20 anos de série histórica.

HU (1988) efetua um estudo de previsão de demanda para Hong Kong (China), a partir de estatísticas históricas de consumo, fazendo a projeção incluir a projeção do consumo total baseada nas tendências de crescimento histórico, a projeção baseada no crescimento da população e do consumo per capita, a projeção baseada nas tendências de crescimento das principais categorias de consumidores (doméstico, comercial e industrial) e a projeção baseada nos planos e programas de desenvolvimento do uso do solo. Todas essas projeções diferem, naturalmente, entre si, com graus variáveis, representando vários cenários possíveis de crescimento de consumos, cada uma tendo seus méritos e restrições em função dos critérios e hipóteses admitidos. Desta forma, é inevitável um enfoque probabilístico dos resultados das projeções, criando um conceito de banda de confiança, onde se definem limites superior e inferior de demandas futuras, para garantir um planejamento mais prudente.

Quando os modelos de longo prazo procuram definir as vazões de pico de consumo, há uma tendência em correlacioná-lo com grandezas climáticas e principalmente com a temperatura.

Um trabalho efetuado por DARR (1988) descreve um modelo de correlação entre o consumo médio mensal e a média mensal das temperaturas máximas diárias, aplicado à cidade de Jerusalém (Israel). Utilizando dados do período de 1980 a 1985, obteve uma correlação linear, com coeficiente de correlação igual a 0,945. Darr sugere que esta técnica poderia ser utilizada para intervalos de tempo menores.

Entretanto, MERLO (1988) compara as vazões de pico diárias com a temperatura e observa que, como regra geral, o consumo tende a aumentar quando a temperatura excede 30° C (na cidade de Turim, Itália) por várias horas durante o dia. O acréscimo do consumo devido à temperatura poderá chegar a ser da ordem de 15 a 20%. Transportar essa relação para uma fórmula seria muito difícil, pois como afirma o autor, deveria ser admitido que uma série de outros fatores permanecessem constantes, enquanto se sabe que variam continuamente e de forma aleatória. Por exemplo, se ocorressem as mesmas variações de temperatura nos meses de julho ou agosto, as curvas de consumo seriam totalmente diferentes. Se o dia com a temperatura de pico máxima for uma segunda-feira, o pico de consumo seria maior. Existe, pois uma inter-relação entre a temperatura e os demais fatores, que dificultam a explicação do consumo como função da temperatura.

Merlo, define as curvas de consumo agregadas (para a cidade de Turim), a partir dos perfis de consumo por tipo de uso (doméstico, Industrial, etc...), procurando definir as relações entre o consumo de um dia de pico e um dia médio.

Uma abordagem alternativa é empregada por SHVARTSER et al. (1993). Neste trabalho a previsão de demanda horária é obtida por um modelo baseado em uma combinação das técnicas de análise de séries temporais com a técnica de reconhecimento de padrões. Três segmentos do ciclo diário de demanda são definidos, a fase ascendente, a fase oscilante (intermediária) e a fase descendente. Estas fases são denominados “estados” da curva de demanda, os quais são definidos como estados sucessivos de um processo Markoviano. As previsões, atualizadas em tempo real, foram testadas em um sistema de abastecimento de Israel, com resultados satisfatórios.

BUCHBERB e WELLS (1996) estudaram as demandas residenciais de água de quatro famílias, que foram monitoradas pelo período de um ano.

O serviço público municipal esforça-se para atender à demanda solicitada com pressões adequadas para o consumo através de recursos disponíveis. A demanda residencial é o maior componente do uso da água municipal (FLACK, 1982), muitas vezes excedendo 75% do total do sistema de consumo. Os estudos de previsão de demanda são motivados pela necessidade de se obter um sistema de abastecimento de qualidade, e valiosos no melhoramento de projetos e na diminuição de custos de sistemas de distribuição de água (LINAWEAVER, et al., 1966).

O consumo de água residencial depende primordialmente do número de ocupantes da residência, da renda familiar, do tamanho do lote, do custo da água e do clima (LINAWEAVER et al., 1966). Devido as diferentes características da demanda, os usos da água residenciais são usualmente separados em doméstico (*indoor*) e para irrigação (*outdoor*). Dois terços do total da água residencial é de uso doméstico, onde a maior parte ocorre no banheiro (FLACK, 1982).

As demandas per capitas das quatro famílias foram analisadas e convertidas em pulsos retangulares equivalentes, cada pulso foi classificado por tipo, determinístico ou randômico, por situação, uso doméstico (*indoor*) ou irrigação (*outdoor*) e por dia, dia de semana ou final de semana. Fundamentalmente a exploração e a análise dos dados foram realizadas por técnicas

descritivas de dados, distribuições cumulativas e ocorrências horárias de intensidade, duração e volumes de pulsos retangulares de acordo com o tipo de situação e dia. Da hipótese que a demanda de água residencial ocorre como uma distribuição não homogênea de Poisson, o processo de pulsos retangulares foi examinado. Os resultados mostraram que um pulso retangular fornece uma razoável aproximação da demanda de água doméstica.

BILLINGS e AGTHE (1998) compararam os modelos espaço temporal e regressão múltipla, através de médias mensais para a previsão a curto prazo da demanda de água urbana. Foram analisados sete séries de 24 previsões mensais de demanda, cada série está baseada em um período histórico de sete anos, usando um total de quinze anos de dados mensais. Baseado nas medidas de erro, o modelo espaço temporal apresentou menos propensão ao erro do que outros modelos, os erros de previsão mostraram variabilidade considerável nos modelos espaço temporal e regressão múltipla. O erro absoluto variou de 7.4 a 14.8 % para a regressão múltipla, e de 3.6 a 13.1% para o modelo espaço temporal. Para estes dados amostrais o modelo de previsão regressão múltipla foi o menos preciso e apresentou maiores problemas em relação aos outros modelos.

Em todos os modelos de curto prazo pesquisados, nota-se a preocupação em destacar a qualidade do modelo em função da previsão dos valores previstos quando comparados com os reais. Esta forma é bastante simples de calcular e indica resultados na forma de desvios ou de coeficientes de correlação que são facilmente entendidos pelos órgãos de operação.

O problema de previsão da demanda do consumo de água em tempo real tem muita similaridade com o problema de determinação da carga elétrica em uma rede de distribuição de energia elétrica. A exemplo da previsão da carga elétrica, muitos métodos baseiam-se em correlações com parâmetros climáticos ou em análises dos dados do histórico recente de consumo como elementos de uma série temporal. Conforme citado por ZADEH FILHO (1990) a empresa Lyonnaise des Eaux utilizava um modelo para previsão em tempo real que considera as correlações dos consumos com a temperatura, precipitação, temperatura, umidade relativa e visibilidade do próximo dia. Uma abordagem alternativa foi adotada pela SABESP, conforme ZADEH FILHO (1990), quando se definiu uma curva de consumo médio para cada setor de abastecimento, denominada curva neutra. A obtenção da curva de consumo num dia específico da

semana é conseguida pela multiplicação dos consumos horários por fatores de correção previamente obtidos em função de dados históricos. A seguir, nova correção é efetuada para considerar o efeito da temperatura, a saber, a temperatura máxima, a média ou a mínima do dia, dependendo de qual dessas temperaturas mais influenciar o consumo.

3.7.3 – A PREVISÃO DE DEMANDA DE ÁGUA EM SÃO PAULO-SP E CAMPINAS-SP

Este item tem a finalidade de mostrar ao leitor o que foi feito sobre previsão nas cidades de São Paulo e Campinas.

Na reportagem publicada pela FOLHA CAMPINAS do dia 15 de outubro de 2002, pelo menos 11 cidades da região de Campinas, que totalizam 803,9 mil habitantes, tiveram problemas de falta d'água devido ao aumento de consumo provocado por uma onda de calor. Campinas registrou no dia 11 de outubro (sábado) a maior temperatura dos últimos 41 anos, 37,4 graus Celsius. De acordo com a SABESP (Companhia de Saneamento Básico do Estado de São Paulo), o consumo médio normal por pessoas em 10 das 11 cidades afetadas é de 120 litros por dia. No período da onda de calor, cada pessoa consumiu a média diária de 180 litros de água. Entre os municípios com deficiência no abastecimento, Sumaré, Hortolândia e Várzea Paulista apresentaram as situações mais críticas.

Analisando a situação descrita acima, há indicações de que a temperatura é um fator importante para o aumento do consumo, e que previsões de temperatura e previsões de demanda água, são de importância para que situações como essa possam ser evitadas ou pelo menos amenizadas, auxiliando as empresas de abastecimento na tomada de decisões e no gerenciamento dos sistemas operacionais. Assim a influência da temperatura foi investigada neste trabalho de pesquisa

O Plano Diretor de Águas de Campinas de julho de 1992 da SANASA apresenta um estudo de demanda, baseado em dados de população estabelecida a partir dos resultados dos estudos e das análises das informações obtidas na Diretoria Comercial da SANASA – Divisão de Atendimento ao Consumidor. As informações disponíveis foram selecionadas de forma adequada

para permitir a definição do perfil setorial de consumo doméstico, comercial e industrial, face às características da população abastecível atual e projetada.

A projeção de expansão da população do Município de Campinas baseou-se na adoção dos índices de crescimento resultantes do Censo de 1991 (846.084 habitantes).

Os índices sugeridos são apresentados abaixo na Tabela 3.1.

Tabela 3.1 – Índice de Crescimento Populacional

Período	Taxa de Crescimento (% a.a.)
1991/1995	3.00
1996/2000	3.00
2001/2005	2.42
2006/2010	2.42

Fonte: Plano Diretor de Campinas

Com base nestes índices foi calculada a população total projetada, Tabela 3.2.

Tabela 3.2 – População Total Projetada (habitantes)

Ano	População Total Projetada (hab.)
1995	1.001.051
2000	1.200.658
2005	1.443.756
2010	1.849.181

Fonte: Relatório Técnico 1 – SANASA

Logo a seguir foi necessária a subdivisão da área do município em setores de abastecimento ou de demanda de água, com a finalidade de definir unidades espaciais com usos e costumes específicos, para os quais, foram avaliadas as projeções de demanda de água.

Na definição dos setores foram considerados três critérios básicos:

- Compatibilização da divisão setorial com as redes de distribuição de água existentes;

- Utilização sempre que possível, de bloqueios naturais topográficos e outros (ferrovias e grandes rodovias) como limites entre setores;
- Compatibilização entre a divisão em setores de demanda de água e as divisões institucionais para as quais são disponíveis informações de natureza sócio-econômicas que caracterizam os bairros e as regiões administrativas usos e costumes.

A área Metropolitana do Município de Campinas engloba um total de 43 setores de abastecimento que somam, aproximadamente 20.510 ha. Essa área representa cerca de 26% da superfície total do município (78.100 ha.).

O abastecimento de água é vinculado ao Sistema Adutor Principal, para o qual, a SANASA estabeleceu um Modelo Matemático chamado MOMA para as análises hidráulicas. Cada setor é representado no MOMA através de um nó com demanda (NOD) que recebe numeração específica. Portanto, para cada setor de abastecimento foi associado um NOD.

A distribuição da população por setores de abastecimento baseou-se na análise do número de ligações, número de residências e consumo por setores de leitura, associados a cada setor de abastecimento.

Em função do Planejamento Urbano Estratégico e na ênfase social, a SANASA considerou o crescimento localizado em alguns setores de abastecimento.

A população total projetada foi calculada a partir da população abastecida existente, adotada a taxa de crescimento ao longo dos anos (Tabela 3.1) e agregando o crescimento localizado em alguns setores.

A projeção da demanda doméstica, por setores de abastecimento foi baseada na evolução das seguintes variáveis:

- População total projetada;
- Evolução dos índices de atendimento;
- População abastecida projetada e

- Evolução das quotas “per capita”.

Com base nos índices de atendimento, foi considerado que os mesmos evoluíssem ao longo do horizonte de projeto, de 95 a 100%, de acordo com as metas sociais da administração municipal obedecendo ao esquema da Tabela 3.3.

Tabela 3.3 – Evolução dos Índices de Atendimento

Ano	Índice de Atendimento (%)
1991	95
1995	95
2000	100
2005	100
2010	100

Fonte: Relatório Técnico 1 - SANASA

Analisado os valores das quotas “per capita”, foi verificado que os setores de abastecimento apresentam valores próximos, em função da similaridade das características socio-econômicas do município. As diferenças resultam de outros fatores, tais como: (a) a idade da rede de distribuição; (b) e a existência ou não da demanda reprimida. A Tabela 3.4 mostra a evolução da quota “per capita”.

Tabela 3.4 – Evolução da Quota Per Capita (l/hab. dia)

Ano	Cota Per Capita Líquida	Cota Per Capita Bruta	Índices de Perdas
1991	160	267	40.0%
1995	170	262	35.0%
2000	180	257	30.0%
2005	190	253	25.0%
2010	200	250	20.0%

Fonte: Relatório Técnico 1 –SANASA

A demanda doméstica abastecível foi calculada multiplicando as populações abastecíveis pelas respectivas quotas “per capita”.

As demandas referentes ao consumo público, comercial e industrial, por setor de abastecimento, foram consideradas a partir das leituras de consumo comercial e industrial que

indica um valor médio estatístico do Município de Campinas. A separação do consumo comercial e do consumo industrial é baseada no Plano Diretor de Campinas, o qual fornece os seguintes parâmetros.

- Demanda de comércio:

Parcela de Consumo: 60% do consumo do setor de ligações comerciais e industriais.

Dias de trabalho efetivo: 25 dias/mês.

Horas de trabalho por dia: 10 horas.

- Demanda de indústria:

Parcela de consumo: 40% do consumo do setor de ligações comerciais e industriais.

Dias de trabalho efetivo: 25 dias/mês.

Horas de trabalho por dia: 24 horas.

Obtidas as demandas domésticas e as demandas comerciais e industriais para cada setor de abastecimento foi obtida a demanda total máxima diária, somando estas demandas e aplicando o coeficiente $K = 1,2$ (dias de maior consumo) apenas sobre a demanda doméstica. O gráfico a seguir mostra os resultados obtidos pela SANASA.




Figura 3.4 – Demandas Doméstica, Comercial, Industrial e Pública e Demanda Máxima Diária Total.

Fonte: Relatório Técnico 1 – SANASA

Segundo Relatório Síntese de junho de 1999 da SABESP, o sistema adutor de São Paulo (SAM) conta com aproximadamente 150 reservatórios setoriais, responsáveis pelo abastecimento de cerca de 16 milhões de habitantes da grande São Paulo e municípios adjacentes.

Em razão da crescente evolução populacional observada na Região Metropolitana de São Paulo, tornou-se necessária à elaboração de estudos de expansão do sistema de abastecimento de água e, nesse sentido, foi de fundamental importância o conhecimento das curvas de consumo dos setores e a determinação dos coeficientes de variação de consumo, K_1 e K_2 , que identificam, respectivamente, o dia e a hora críticos de consumo e do coeficiente K_3 , que identifica a hora de menor consumo, permitindo que se faça as previsões de demanda de longo e curto prazo.

Para as previsões de longo prazo, procurou-se, geralmente, prever três valores básicos: (a) a demanda média de um dia de consumo médio; (b) a demanda média de um dia de consumo máximo e (c) o pico de consumo de um dia crítico.

Através da utilização de uma série histórica de cerca de 3,5 anos de dados de consumos horários de cerca de 120 setores pertencentes ao SAM de São Paulo, o trabalho foi conduzido de maneira a caracterizar as curvas de consumo horário e os perfis adimensionais de demanda e determinar os coeficientes de variação de consumo K_1 , K_2 e K_3 (coeficiente do dia de maior consumo, da hora de maior consumo e da hora de menor consumo, respectivamente) desses setores.

Baseado nesses dados de consumo, a SABESP fez uma análise preliminar da existência ou não de alguma correlação entre os perfis de consumo e o tipo de ocupação dos setores (comercial, residencial, industrial ou público).

A base para a elaboração do trabalho foi à série histórica de dados de consumo, disponibilizada pelo Centro de Controle de Abastecimento (CCO) desde dezembro de 1994. Esses dados foram obtidos telemetricamente das estações remotas e armazenados em arquivos textos, posteriormente convertidos para arquivos de bancos de dados.

De posse da curva de consumo verificada em cada dia do período analisado, foram definidas as curvas média, mínima e máxima de cada setor, baseadas no seguinte critério:

- Curva média – para cada hora, foi obtida a média dos valores horários da série histórica. A curva obtida quando se plotam esses valores fornece a curva de consumo horário média do setor;
- Curva mínima – para cada hora, definiu-se como sendo o valor mínimo aquele obtido pela relação: $(\text{valor médio} - 2*s)$ onde s representa o desvio padrão amostral horário da série histórica.

A curva obtida quando se plotam os valores mínimos horários assim definidos é a curva de consumo horário mínima do setor.

- Curva máxima – para cada hora definiu-se como sendo o valor máximo aquele obtido pela soma: $(\text{valor médio} + 2*s)$.

A curva obtida quando se plotam os valores máximos horários assim definidos é a curva de consumo horário máximo do setor.

A definição do critério utilizado para determinação das curvas mínima e máxima de consumo foi baseada na verificação de que, para os setores analisados durante a fase de investigação de dados, praticamente a totalidade das curvas se apresenta dentro da envoltória $(\text{valor médio} - 2*s)$ e $(\text{valor médio} + 2*s)$.

Dentro da análise de consumos, foi definido o “valor neutro” de consumo da hora h pela média dos valores horários da curva média de consumo do setor. Dessa forma, a curva neutra é dada pelos 24 “valores neutros” assim obtidos.

No trabalho foram caracterizadas as curvas de consumos médios, mínimos e máximos da série histórica e as curvas neutras dos setores para cada dia da semana, com o objetivo de verificar a existência de um comportamento típico para cada setor ou grupo de setores.

O consumo médio de cada setor foi considerado como sendo a média dos consumos dos últimos 12 meses. Esse valor foi atualizado mensalmente na definição dos coeficientes K_1 obtidos para cada dia da série histórica. Em diversos casos, foram verificadas falhas nos dados da série histórica de consumos diários. Os dados referentes há esses dias foram completados com o consumo médio dos 30 dias anteriores. Quando havia uma sequência de dias falhos, a substituição era feita a partir do primeiro dia falho, e o valor calculado para esse dia foi incorporado à série histórica e utilizado no cálculo da média dos 30 dias, de modo que se pudesse completar o dia posterior. No caso de não existência de uma série contínua com 30 dias de dados válidos, não era feito o cálculo da média mensal. Para o cálculo de K_1 , somente foram considerados os dias em que havia os consumos mensais dos 12 meses anteriores.

O coeficiente K_2 é a relação entre a vazão máxima de consumo horário e a vazão média de um dia, procurando avaliar as maiores oscilações de consumo de um dia.

Para melhor caracterizar a forma da curva de consumo, foi definido o coeficiente K_3 , como sendo a relação entre a vazão mínima horária de consumo médio do dia. A análise deste coeficiente permitiu, por exemplo, a detecção de setores com alto índice de vazamentos, o que permite adotar medidas para o controle de perdas do SAM.

Os coeficientes K_1 , K_2 e K_3 obtidos da série histórica de consumos de cada setor foram ajustados à curva de frequência de excedência, o que permite a adoção de diferentes valores em função do risco admitido, permitindo ainda conhecer os valores mínimos e máximos que podem ser atingidos ou ultrapassados com determinada frequência. A análise da frequência de excedência dos valores obtidos procurou obter parâmetros para comparação desses valores com aqueles usualmente utilizados procurando estimar os riscos envolvidos na utilização desses valores.

Para cada setor foram extraídos os valores dos coeficientes K_1 , K_2 , K_3 associados a frequências de excedência 1%, 2,5%, 5%, 10%, 15% e 20%. Para cada um desses níveis de frequência “global” para os setores de SAM, obtida pela análise conjunta de todos os setores do SAM.

Foram definidos ainda, a frequência e o número de vezes em que determinados valores de K_1 , K_2 e K_3 (divididos em faixas de valores) ocorreram dentro da série analisada de cada setor.

Com base nas análises efetuadas, foi possível obter uma caracterização das curvas média, mínima e máxima de consumo dos setores pertencentes ao SAM.

Para a maioria dos setores, verificou-se que essas curvas de consumo apresentam um perfil típico, que pode ser associado em sua forma à de uma senóide bem definida.

Analisando as curvas médias obtidas para cada dia da semana, observou-se que, em geral os setores predominantemente residenciais não apresentaram mudanças significativas nas forma das curvas de consumo, tão pouco na magnitude das vazões médias e extremas. Alguns desses setores apresentaram um pequeno acréscimo de consumo no sábado, o que explica a SABESP é devido à realização de tarefas como lavagem de carros, roupas e outros. Nos setores com parcela de uso comercial significativo, houve uma redução nas vazões máximas horárias da ordem de 15% nos finais de semana.

3.8 – REDES NEURAIIS ARTIFICIAIS

3.8.1 – FUNDAMENTOS DE REDES NEURAIIS ARTIFICIAIS

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento; já o cérebro de um mamífero pode ter muitos bilhões de neurônios. Cada elemento opera somente sob uma informação local (NIGRINI, 1993). ZURADA (1992) simplifica a conceituação afirmando que o sistema neural ou RNA's são sistemas celulares físicos os quais podem adquirir, armazenar e utilizar conhecimentos experimentais. Em outras palavras, RNA's são unidades de processamento numérico, cuja arquitetura em camada produz um fluxo de informações com ou sem realimentação, possuindo uma estrutura de processamento de sinais com grande poder de adaptação e capacidade de representação de processos não lineares.

São representadas por unidades interconectadas através de processamentos não lineares estáticos, onde a(s) entrada(s) na rede são vetores e sua respectiva(s) saída(s) são escalares, chamadas de neurônios artificiais. Apresentam grande competitividade com os métodos lineares, quando estes não apresentam bom desempenho nos processos que, particularmente, envolvem aproximação de funções multivariáveis, identificação e controle de sistema dinâmicos. As redes além de calcular qualquer função computável, estão habilitadas a resolverem problemas de classificação e mapeamento e aproximação de funções.

Várias são as aplicações de redes neurais divulgadas na literatura. Na área aeroespacial está sendo usada em simulação do trajeto de vôos e sistemas de controle de aeronaves; na engenharia automotiva em sistemas de direção automática de automóveis; no sistema bancário em avaliação de aplicações, e se estendendo ao sistema financeiro em previsão do preço corrente. Na eletrônica é bastante utilizada em controle de processos, máquinas de visão, síntese de vozes e modelagem não linear; na área de robótica existem estudos em controle de trajetória e controladores manipulador; na medicina em análise de eletroencefalograma e eletrocardiograma, modelos de próteses e otimização de tempo de transplantes; nas ciências sociais em previsão do custo da violência no trânsito e violência provocada pelos conflitos agrários (NEURAL NETWORK TOOLBOX, 1998).

Na agricultura, por exemplo, DECK et al. (1995) comparam RNA's com uma máquina tradicional classificadora por inspeção visual e , TAO et al. (1995) aplicaram RNA's na inspeção visual das cores de tomates e batatas para um processo seletivo. Nas ciências econômicas (TRIPP e TURDAN, 1993) e indústria (TAWEL, MARKO e FELDKAMP, 1998) diversos são os investimentos em busca de novas tecnologias aplicadas.

Particularmente, na hidrologia e recursos hídricos tem sido uma ferramenta muito útil em modelos de previsão de vazão destinados à operação de reservatórios em tempo real; como ferramenta alternativa, na construção de programas especialistas destinados a apoiar as decisões no gerenciamento de recurso hídricos, na previsão de eventos extremos como secas e cheias e, também na previsão de níveis em canais de fuga. O campo de aplicação de redes neurais se estende além das áreas da ciência, para utilização em serviços públicos (segurança, educação, saúde), entretenimento, exploração de óleo e gás e transportes.

3.8.2 – BREVE HISTÓRICO

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

A origem da teoria de redes neurais remonta aos modelos matemáticos e aos modelos de engenharia, de neurônios biológicos. A célula nervosa, ou neurônio foi identificado anatomicamente e descrito com notável detalhe, pelo neurologista espanhol Ramón y Cajal no século XIX (CAJAL, 1894 citado por KOVÁCS, 1897).

Pode-se dizer que o interesse por redes neurais é bastante remoto e vem desde a época em que alguns filósofos como John Locke, George Berkeley e David Hume especulavam sobre o relacionamento entre espírito, memória e comportamento humano. Porém com o desenvolvimento das Neurociências é que o interesse pelo estudo de redes neurais e seus paradigmas computacionais se desenvolveu e chegou ao estágio avançado dos dias atuais. O primeiro passo significativo nesse sentido foi feito por McCulloch e Pitt em 1943, com a publicação do primeiro artigo sobre propriedades matemáticas de redes neurais. Este artigo foi inspirado nas propriedades eletrofisiológicas dos neurônios nas teorias que indicavam ser booleanas a natureza essencial da inteligência. Eles procuraram reproduzir o comportamento fisiológico do neurônio através de um modelo computacional simples (FREEMAN, 1991 e HAYKIN, 1994). Posteriormente, Rosenblatt em 1959 introduziu o Perceptron, baseando-se no trabalho de McCulloch, e com ele um modelo computacional capaz de classificar padrões linearmente separáveis, através de um algoritmo de correção do erro (*“error-correction algorithm”*) que permite o ajuste dos parâmetros do Perceptron utilizando o teorema da convergência.

Paralelamente a esses resultados, Kolmogorov em 1957 provou um teorema importante para a teoria de funções e que bem mais tarde seria utilizado de uma forma modificada para provar a capacidade de redes neurais em representar funções. Contudo, não se tem notícia de que

o teorema de Kolmogorov e a teoria de redes neurais apresentassem alguma relação na época em que o mesmo foi elaborado.

Foi somente com o trabalho de Widrow-Hoff em 1960 (HAYKIN, 1994 e WIDROW, 1990) e sua regra delta que se elaborou um algoritmo para ajuste dos parâmetros do Perceptron.

Widrow utilizou o tal algoritmo para elaborar o ADALINE (elemento linear adaptativo), que consistia em uma máquina para classificação de padrões lineares. Na realidade, o ADALINE são calculados de forma a minimizar o erro de saída do elemento linear no sentido dos mínimos quadrados, enquanto o objetivo do perceptron e seu algoritmo de convergência é o de adaptar os parâmetros até que os padrões apresentados aos neurônios estejam separados. Mais tarde, Widrow estendeu o seu trabalho para uma rede ADALINES chamada MADALINE. Esses estudos lançaram as bases para o uso da Rede de Múltiplas Camadas. Outros trabalhos seguiram-se aos de Widrow, porém um grande problema ainda persistia, como adaptar os parâmetros dos neurônios da rede, pois até então não existia uma regra geral para isso (KOVÁCS, 1996). Foi graças a Rumelhart (RUMELHART, 1986), com a publicação do livro *Parallel Distributed Processing* editado por J.L. McClelland & Rumelhart (1986a-1986b) e seu algoritmo de retro-propagação (*Backpropagation*), que havia sido também desenvolvido independentemente por Werbos em 1974, que se tornou possível calcular os parâmetros de uma rede de neurônios (*Perceptrons*) abrindo caminho para que as redes neurais ganhassem grande popularidade. O desenvolvimento deste método para ajuste de parâmetros de redes não recorrentes de múltiplas camadas fez com que efetivamente a área de redes neurais fossem uma das prioritárias na obtenção de recursos, fazendo com que pesquisadores das mais diferentes áreas passassem a visualizar interessantes aplicações para redes neurais artificiais.

Esta descoberta, em conjunto com uma variação do teorema de Kolmogorov, permitiu aplicar redes neurais em uma série de problemas em diversos campos da ciência e em particular ao problema da previsão de séries temporais. Cabe notar que, enquanto as redes de Perceptron eram estudadas outros tipos de redes neurais foram também desenvolvidos como as redes de Kohonem e Hopfield. J. Hopfield em seu trabalho *Neural Networkan Physical Systems With Emergent Collective Computational Abilities*, publicado em 1982, desenvolveu a idéia de uma função energia para formular novo percurso visando melhorar a performance computacional de

redes recorrentes com concepção sináptica simétrica, o que originou as Redes de Hopfield. Outro importante trabalho, apresentado em 1982, foi o de T. Kohonen sobre mapas de auto-organização usando estruturas treliçadas uni ou bidimensionais (HAYKIN, 1994).

J. HOPFIELD (1982), juntamente com D. Tank, um pesquisador da AT&T, desenvolveram grande parte de modelos de redes neurais baseadas em pesos finos e ativações adaptativas. Estas redes podem servir como memórias autoassociativas e serem usadas para resolver problemas de otimização restrita como o caso do “caixeiro viajante” (URL1). A rede de Hopfield pode ser considerada como um sistema dinâmico com número finito de estados de equilíbrio, de forma que o sistema invariavelmente irá evoluir para um destes estados ou para uma sequência periódica, de estados a partir de uma condição inicial. É também natural que a localização destes estados de equilíbrio possa ser controlada pela intensidade das conexões (pesos) da rede neural.

A conclusão interessante adotada por Hopfield foi que tais estados de equilíbrio podem ser utilizados como dispositivos de memória. De forma distinta daquela utilizada pelos computadores convencionais, em que o acesso à informação armazenada se dá por meio de um endereço, o acesso ao conteúdo da memória de uma rede de Hopfield se dá permitindo que a rede evolua com o tempo para um de seus estados de equilíbrio. Tais modelos de memória são denominados memórias endereçáveis por conteúdo.

O trabalho de Hopfield com este tipo de rede simétrica recorrente atraiu, principalmente, matemáticos e engenheiros para a pesquisa nesta área, e as redes de Hopfield foram, estudadas como ferramentas na solução de problemas de otimização restrita.

3.8.3 – NEURÔNIO ARTIFICIAL

Um neurônio é uma unidade de processamento de informação a qual é fundamental na operação de redes neurais (HAYKIN, 1994). Os neurônios biológicos (Figura 3.5) recebem sinais e produzem a resposta, e este processo é realizado através das interconexões que existem na estrutura do sistema nervoso.

Como qualquer célula biológica, o neurônio é delimitado por uma fina membrana celular que além da sua função biológica normal, possui determinadas propriedades (KOVÁCS, 1996), essenciais para o funcionamento elétrico da célula nervosa. Na rede neural biológica as informações são armazenadas e os pontos de contato entre os diferentes neurônios são chamados de sinapses, que nada mais são do que regiões eletroquimicamente ativas. Dentro do sistema nervoso, encontram-se neurônios de diferentes tipos e funções. Sua estrutura mínima é compreendida das sinapses; do corpo da célula, também, chamado de soma, é onde ocorre o centro dos processos metabólicos da célula nervosa, e a partir dele várias extensões de filamentos são enraizadas dando origem aos dendritos, que são canais transmissores de chegada das informações. O axônio (também referido como fibra nervosa ou linha de transmissão. Cada célula possui apenas um), serve para conectar a célula nervosa a outras do sistema e, nas extremidades dos dendritos encontram-se os terminais sinápticos.




Figura 3.5 - Estrutura Geral do Neurônio Genérico

Fonte: <http://www.icmc.sc.usp.br/~prico/neural1.html#intro> – 24/05/2000

As entradas no neurônio biológico são feitas através das conexões sinápticas que conectam todos os dendritos ou a árvore dendrital aos axônios de outras células nervosas. As sinapses estão compreendidas entre suas membranas: a pré-sináptica, onde chegam os estímulos

vindo de outra célula e, a pós-sináptica que é a do dentrito. Os sinais emitidos pelo corpo celular que chegam e percorrem os axônios são impulsos elétricos (substância neurotransmissora produzida) chamados de impulsos nervosos ou potenciais de ação. Estes sinais nada mais são do que as informações que o neurônio irá processar, através de alguma forma, para em seguida produzir como saída, um outro impulso nervoso no seu axônio. O neurotransmissor poderá diminuir ou aumentar a polaridade da membrana pós-sináptica, através da inibição ou da excitação dos pulsos no outro neurônio conectado.

Comparando sua estrutura ao do neurônio biológico, ela é constituída de canais de entrada, corpo da célula e canais de saída, as sinapses irão ser simuladas através dos contatos entre os pontos do corpo da célula e as conexões de entrada e saída e, os pesos estarão associados a esses pontos.

3.8.4 – TOPOLOGIA DAS REDES NEURAIS ARTIFICIAIS

As redes neurais são constituídas de elementos simples operando em paralelo, que armazenam conhecimentos através de experiências, sendo estes elementos inspirados no sistema nervoso biológico. As redes neurais artificiais são uma tentativa de modelar a capacidade de processamento das informações do sistema nervoso (HAYKIN, 1994), ver Figura 3.7.



Figura 3.6 – Elementos de Conexão de RNA's

As RNA's constituem-se de uma técnica computacional cuja representação do respectivo modelo matemático está baseada na estrutura neural de organismos inteligentes, nos quais a aquisição do conhecimento está vinculada a experiência adquirida. Comparando a estrutura de uma RNA com a do neurônio biológico, percebeu-se que ela é constituída de canais de entrada, corpo da célula e canais de saída, as sinapses irão ser simuladas através dos contatos

entre os pontos do corpo da célula e as conexões de entrada e saída e, os pesos estarão associados a esses pontos.

A Figura 3.7 mostra o modelo de um neurônio artificial e seus elementos básicos. Sua estrutura é constituída de um conjunto de entradas (x_R) que multiplicadas por um peso sináptico correspondente (w_{iR}), produz entradas ponderadas. Na sequência é realizada uma soma ponderada destes sinais, resultando em um valor n_k o qual comparado com um valor limite (**limiar** θ_k), para então ativar do neurônio resultando em $a_k = \varphi(n_k)$. Se o valor exceder o valor do limiar do neurônio, ocorrerá a ativação, caso contrário, não.




Figura 3.7 – Arquitetura de um Neurônio Artificial com Múltiplas Entradas Não Lineares

Onde:

x_R – são os dados de entrada da rede (*inputs*);

w_{iR} – são os pesos sinápticos escalares, relativos à camada de neurônio referentes a cada elemento de entrada x . Indicam a conexão entre os neurônios r e i , e caso seu valor seja positivo indica uma sinapse excitatória e caso contrário uma sinapse inibitória;

Σ - é o somatório dos produtos entre os vetores linha dos pesos ($\mathbf{w}$) e os vetores coluna ($\mathbf{x}$) de entrada da rede ($\mathbf{w} * \mathbf{x}$), mais a influência do limiar, expressa por:

$$n_k = \sum_{r=1}^R w_{ij} \cdot x_r - \theta_i \quad (3.5)$$

θ_k - é um *Threshold* e *bias* (limiar) que representam entradas adicionais de polarização ($x_0 = 1$ ou $x_0 = -1$) é um parâmetro aplicado externamente a um neurônio k e possui um efeito de rebaixamento da rede de entrada de uma função de ativação, por outro lado, estas entradas podem ser aumentadas pelo emprego do termo *bia* - uma *bia* é um negativo de um *threshold*. Os limiares adicionados ao somatório dos produtos ($\mathbf{w} * \mathbf{x}$) formarão a entrada escalar $\mathbf{n}$. Esta soma é o argumento da função de transferência $\varphi(\cdot)$;

$\varphi(\cdot)$ - é função de transferência ou de ativação e produz o vetor de saída $\mathbf{a}_i$. Esta função é um limitador de amplitude de um neurônio de saída e geralmente fechada em um intervalo de $[0,1]$ ou alternativamente $[-1,1]$.

O valor de $\mathbf{n}_k$ passa a ser argumento de uma função de ativação, $\mathbf{a}_k = \varphi(\mathbf{n}_k)$, ocorrendo a propagação desses valores para os próximos neurônios.

Para WASSERMAN (1989) as redes neurais se assemelham ao cérebro por dois aspectos: o conhecimento é adquirido pela rede através de um processo de aprendizagem, e a intensidade das conexões, conhecidas como pesos sinápticos, são usadas para armazenar aprendizagem.

A estrutura da rede, composta de interconexões de neurônios, é chamada de arquitetura da rede neural, podendo variar quanto ao número de camadas, neurônios em cada camada, função de transferência de um neurônio para o outro e número de saídas. A Rede Multicamadas (RMC) está associada ao algoritmo de treinamento *Back-Propagation* (BP). As arquiteturas de redes estão divididas em quatro diferentes classes:

- a) Redes Feedforward de Camada Única

São formadas por uma camada de entrada de nós origem ligada à camada de saída do neurônio. Uma de suas vantagens é que possui memória associativa, ou seja, ela associa um padrão de saída (vetor) com padrão de entrada (vetor).

b) Redes Feedforward Multicamadas

As redes neurais artificiais com perceptron de multicamadas (MLP, do inglês *Multilayer Perceptron*) possuem uma ou mais camadas escondidas, enquanto que os cálculos nos nós correspondentes são chamados de neurônios escondidos ou unidades escondidas. São geralmente usadas para determinar um mapeamento entre dois conjuntos de dados.

c) Redes Recorrentes

As RNA's recorrentes, também chamadas de RNA's com memória por possuírem realimentação, respondem a estímulos dinamicamente, isto é, após aplicar uma nova entrada, a saída é calculada e então realimentada para modificar a entrada. Para redes estáveis, este processo é repetido várias vezes, produzindo pequenas mudanças nas saídas, até ficarem constantes. Todavia, as RNA's recorrentes nem sempre são estáveis, mesmo com entradas constantes. As redes mais comuns são as redes Elman e as Redes Hopfield (BISHOP, 1997).

d) Estrutura treliçada

A treliça consiste em duas ou mais dimensões de ordem de neurônios com um correspondente conjunto de nós origem que fornecem sinais de entrada para uma ordem. É uma rede com neurônios de saída combinados em linhas e colunas. (HAYKIN, 1994).

O fato de não se conseguir prever quais redes seriam estáveis foi um problema que preocupou os pesquisadores até o início da década de 80 quando Cohen e Grossberg provaram um poderoso teorema para definir quando as RNA's eram estáveis (WASSERMAN, 1989). Este teorema determina que para as RNA's recorrentes alcançarem um estado estável é necessário que possuam conexões simétricas.

Contribuições importantes também foram dadas por John Hopfield (HOPFIELD, 1984), tanto para a teoria como para a prática, sendo que algumas configurações passaram a ser chamadas de redes de Hopfield em sua homenagem.

HINTON et al. (1986), também tiveram seus méritos, introduzindo regras gerais de treinamento para rede, denominada por eles de máquina de Boltzmann devido ao cálculo das saídas dos neurônios artificiais ser efetuado através de probabilidade com distribuição de Boltzmann.

A arquitetura da rede é muito importante para as capacidades de convergência e generalização das RNA's. Existem várias técnicas que tentam encontrar a arquitetura ideal através da diminuição de neurônios redundantes e do compartilhamento de pesos (HERTZ, 1991), ou através de um algoritmo genético, porém, nenhuma apresenta resultados convincentes para todas as aplicações. Na verdade, a arquitetura ideal das RNA's continua sendo determinada principalmente pela experimentação e pela experiência do projetista (ABELÉM et al. 1995).

3.8.5 – REDES DO TIPO PERCEPTRON DE MÚLTIPLAS CAMADAS (MLP)

O pesquisador Frank Rosenblatt, na década de 50 deu continuidade à teoria de McCULLOCH e PITTS (1943), que ficou conhecida como o neurônio de McCulloch e Pitts, era um dispositivo binário, ou seja, a saída poderia ser pulso ou não pulso e os seus inúmeros sinais de entrada possuíam um ganho arbitrário e poderiam ser excitatórios ou inibitórios (Figura 3.19). Rosenblatt criou uma rede de múltiplos neurônios do tipo discriminadores lineares e deu o nome a esta rede de Perceptron (KOVÁCS, 1996).

As arquiteturas do tipo perceptron de múltiplas camadas (MLP) constituem os modelos neurais artificiais mais utilizados e conhecidos.

Tipicamente, esta arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída.

As redes do tipo MLP tem sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. Seu treinamento é do tipo supervisionado e utiliza um algoritmo muito popular chamado retro-propagação do erro (*error backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (HAYKIN, 1994).




Figura 3.8 – Representação Funcional de um Neurônio – Perceptron de McCullock e Pitts

Fonte: <http://www.icmc.sc.usp.br/~prico/neural1.html#intro> – 24/05/2000

A estrutura de rede a ser aplicada neste trabalho é do tipo MLP as outras classes podem ser conferidas em HAYKIN (1994), ROJAS (1996). A rede RNA é definida como sendo um “...sistema de interconexões de unidades (chamadas neurônios), baseada no sistema nervoso, que atua após um estímulo externo” (BALLINI, 1996). A MLP’s (Figura 3.9) apresentam um modelo estacionário, ou seja, aquele que possui como característica a existência de equações que não possuem memória. Isto significa que a saída é função da entrada corrente e não de valores passados.

Existem várias notações para designar as camadas de neurônio. As classificações, de acordo com a sua posição, são:

1) Camada de entrada, é aquela cujos neurônios (unidades de entrada) propagam as informações de entrada para a camada seguinte, sem que ocorram modificações;

2) Camada(s) intermediária(s) ou escondidas(s), transmitem as informações, por meio das interconexões, entre as unidades de entrada e saída, os neurônios desta camada são denominados de unidades intermediárias ou escondidas;

3) Camada de saída, cujos neurônios são denominados de unidades de saída, propagam a resposta da RNA à entrada aplicada na camada de entrada.




Figura 3.9 – Arquitetura de Rede Neural Multicamadas

Neste trabalho serão adotadas as denominações seguintes, tendo como o exemplo à Figura 3.9. A camada com os dados será denominada camada de entrada, a camada que produz a saída da rede é a camada de saída (camada 2) e as demais intermediárias serão as camadas escondidas (camada 1). Outra notação para a rede é feita quanto ao número de nós e neurônios existentes. Por exemplo, uma rede com notação 5-3-1 ou [5,3,1], terá cinco nós de entrada (camada de entrada), três neurônios escondidos (camada escondida) e 1 neurônio de saída (camada de saída).

Seja uma rede neural artificial multicamada representada pela notação da Figura 3.9. O subscrito i refere-se á camada de saída da rede, j á camada escondida e k à camada de entrada.

As saídas de cada unidade são denotadas por $A_i = a_i^p$ para a camada de saída; A_j para a camada escondida e, em se tratando da camada de entrada $A_k = x_k^p$. As conexões entre a camada de entrada e a camada escondida de neurônio são representadas por w_{ij} . Os números de neurônios correspondentes a cada camada de entrada, escondida e de saída, são representados por K, J e I , respectivamente.

São designados diferentes pares padrões pelo superescrito p , em que P representa o número de padrões do conjunto de treinamento $P(x_k, d_k)$, x_k é o *input* e d_k o valor desejado. Cada valor x_k^p de entrada pode ser binário ou contínuo.

3.8.6 – FUNÇÃO DE ATIVAÇÃO

O modelo de cada unidade da rede pode incluir uma não-linearidade na sua saída. É importante enfatizar que a não-linearidade deve ser suave, ou seja, diferenciável, diferentemente da função sinal utilizada pelo perceptron original.

A função de ativação representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade. Quando propriedades dinâmicas estão envolvidas na definição do estado de ativação, equações diferenciais (caso contínuo) ou as diferenças (caso discreto) são empregadas. Tendo em vista a simplicidade desejada para as unidades processadora, geralmente define-se seu estado de ativação como uma função algébrica da entrada interna atual, independente de valores passados do estado de ativação ou mesmo da entrada interna. Geralmente, esta função é monotonicamente não-decrescente e apresenta um tipo de não-linearidade associada ao efeito da saturação (KOSKO, 1992; HAYKIN, 1994). Existem vários tipos de funções, mas as comumente usadas na modelagem de neurônios são as funções *Sigmoid*, *Threshold Logic* e *Hard Limiter* (Figura 3.10).




Figura 3.10 – Tipos de Funções de Ativação

Fonte: <http://www.icmc.sc.usp.br/~prico/neural1.html#intro> – 24/05/2000

3.8.7 – PROCESSO DE APRENDIZAGEM E GENERALIZAÇÃO

A capacidade de “aprender” associada a uma rede neural é uma das mais importantes qualidades destas estruturas. Trata-se da habilidade de adaptar-se, de acordo com regras pré-existent, ao seu ambiente, alterando seu desempenho ao longo do tempo. O treinamento é feito através de um processo iterativo de ajustes aplicado a seus pesos e *bias*, e isto consiste basicamente na rede ser estimulada externamente, sofrer mudanças resultantes por meio desses estímulos e, finalmente, responder face às mudanças ocorridas na sua estrutura interna.

A capacidade de uma rede aprender está intrinsecamente ligada à forma de conexões entre seus neurônios, à topologia da rede, em que ambiente a rede é utilizada e no paradigma de treinamento.

Entende-se por aprendizado da rede neural, um processo em que, os parâmetros livres existentes na estrutura da rede sofrem alterações devido a uma estimulação contínua proveniente do ambiente no qual a rede está envolvida. Assim, o aprendizado se concretiza, à medida que um modelo implícito é obtido na representação de um sistema a ser simulado ou de uma tarefa a ser executada ou implementada. Isso se realiza por meio de ajustes dos respectivos parâmetros da rede (BARP, 1999).

Da Figura 3.9, considere $w(t)$ um peso sináptico de um neurônio, no instante de tempo t , o ajuste $\Delta w(k)$ a ser somado ao peso $w(t)$ produzirá um novo valor corrigido $w(t+1)$ segundo a equação:

$$w(t+1) = w(t) + \Delta w(t) \quad (3.6)$$

A obtenção de $\Delta w(k)$ pode ser realizada por várias técnicas, a partir delas é definido o tipo e aprendizado para o ajuste dos pesos sinápticos, que são os parâmetros da rede neural. Um conjunto de regras bem definidas para resolver o problema de aprendizagem das redes neurais é chamado de algoritmo de aprendizagem. Estes algoritmos diferem uns dos outros na formulação do ajustamento dos pesos sinápticos, alguns exemplos de algoritmos são: lei de Hebb, algoritmos de *backpropagation*, estratégias de competição, máquina de Boltzmann.

A forma particular influenciada pelo ambiente à rede durante o período de aprendizagem é denominada de paradigma de aprendizagem (BARP, 1999). Alguns exemplos de paradigma de aprendizagem são: aprendizado supervisionado, aprendizado por reforço e aprendizado não-supervisionado ou auto-organizado.

No aprendizado supervisionado, existe um “professor”, o qual, considerando o processo de treinamento, “diz” a rede qual é a melhor performance ou o que deve ser corrigido no comportamento da rede. Existem diversos métodos de aprendizado para qualquer topologia de rede. Destacam-se: *Brain State in a Box* (BSB), *Fuzzy Cognitive Map* (FCM), *Boltzmann Machine* (BM), *Mean Field Annealing* (MFA), *backpropagation* (BP), *Extended Kalman Filter* (EKF), *Adaptive Logic Network* (ALN), e outros.

No aprendizado não supervisionado a rede é autônoma, ela não necessita de um “professor”. O processo é direcionado por correlações existentes nos dados de entrada: *Temporal Associative Memory* (TAM), *kohonene Self-Organization/Topoly Preserving Map* (SOM/TPM), *discrete Hopfield* (DH), *Learning Matrix* (LM), *Optimal Linear Association Memory* (OLAM), *Couterpropagation* (CP), e outros.

O processo de aprendizagem é composto por cinco regras básicas e três classes básicas de paradigma de aprendizagem (Figura 3.11).

Considerando qualquer algoritmo ou o paradigma utilizado, ao alcançarmos o objetivo, obtemos uma representação de conhecimento que obedece as seguintes regras de procedimentos (VON ZUBEM, 1999):

Regra 1 – entradas similares provenientes de classes similares de fenômenos ou eventos tendem a produzir representações similares dentro da rede, o que pode levar a classificá-las como pertencentes à mesma categoria.

Regra 2 – itens que devem ser classificados ou processados distintamente devem provocar, de alguma forma, representações distintas dentro da rede.

Regra 3 – se uma característica é importante, então devem ser alocados recursos da rede neural (por exemplo, neurônios e conexões) para representá-la devidamente. Quando mais complexa a representação, mais recursos devem ser alocados.

Regra 4 – a etapa de aprendizado pode ser simplificada caso as informações conhecidas a priori e invariâncias sejam embutidas diretamente no projeto da rede neural.




Figura 3.11 – Taxonomia do Processo de Aprendizagem

Fonte: HAYKIN, 1994

Neste trabalho será aplicado a rede neural um algoritmo de aprendizagem de correção do erro e paradigma supervisionado.

3.8.7.1 – APRENDIZADO SUPERVISIONADO

A RNA possui a habilidade de aprender, ou seja, por meio de treinamento a rede tem a possibilidade de computar, sem que haja a necessidade de se especificar todos os detalhes desta computação. Neste modelo é empregado um aprendizado supervisionado, no qual as entradas e suas respectivas saídas (conjunto de treinamento) são apresentadas simultaneamente à rede, em cada interação do processo de treinamento. A rede calcula o erro entre o padrão de saída desejado e o obtido naquela interação, o erro gerado é propagado através da rede. Os pesos das sinapses são atualizados através da aplicação de um determinado algoritmo que consequentemente minimize este erro. Este procedimento é refeito até que o valor do erro encontrado para o vetor de

treinamento seja o menor possível. Este é o tipo de treinamento usado no algoritmo de retro-propagação (*Backforward*) (BARP, 1999) (Figura 3.12).




Figura 3.12 – Treinamento Supervisionado de uma RNA

3.8.7.2 – REGRA DE APRENDIZAGEM DE CORREÇÃO DO ERRO

O primeiro processo de treinamento para rede neural linear – ADALINE (*Adaptive Liner Element*), conhecido como Regra Delta ou Método do Gradiente, foi criado por B. Widrow. Tinha como proposta, calcular o ponto de mínimo por meio de um processo de iteração local, utilizando um exemplo do conjunto de treinamento por vez (KOVÁCS, 1996).

No treinamento da rede multicamadas, um dos algoritmos de 1ª ordem mais utilizados é o *Backpropagation* (BP), ou algoritmo de retro-propagação do sinal do erro (Figura 3.13), que foi inventado independentemente por vários pesquisadores, Brysib e Ho (BRUSON e HO, 1969), Werbos (WERBOS, 1974), Parker (PARKER, 1985) e Rumelhart (RUMELHART et al. 1986). Uma abordagem aproximada foi proposta por Le Cun (LE CUN, 1986). O algoritmo fornece uma forma de alteração dos pesos w_{ij} em qualquer rede diretamente alimentada para aprender a relação entre pares entrada-saída (x^p, a^p) de um conjunto de treinamento. O algoritmo baseia-se no método de gradiente descendente, o qual tenta minimizar uma função de custo $E(w)$ que é uma medida dos erros da saída.

O algoritmo *Backpropagation* possui como forma de atualização (ajustamento) dos pesos a Regra Delta Generalizada (RDG), criada por D.E.Rummelhart, G.E. Hinton e R.J. Williams, que implementam o método do gradiente simples. Esta regra teve como origem a Regra Delta de Widrow ou Regra de Aprendizagem de Correção do Erro (*Error-Correction Learning*) e a diferença está na inclusão de um parâmetro constante denominado de *momentum* (α), que geralmente é número positivo. A RDG consiste em ajustar os pesos sinápticos para um intervalo de tempo.




Figura 3.13 – Direções de Propagações do Sinal Funcional e do Erro

Fonte: <http://www.icmc.sc.usp.br/~prico/neural2.html> – 24/05/2000

A adição do *momentum* na regra de aprendizagem resulta em uma rede com menor sensibilidade às características locais da superfície de erro e maior sensibilidade às grandes tendências. Tal rede pode “escapar” de superfícies de mínimos locais.

A plotagem da função custo (nesse exemplo, Soma do Erro Quadrático – *Sum Squared Error*) versus os pesos sinápticos e *bias*, caracterizando desta forma uma rede neural, consiste em uma superfície multidimensional denominada superfície da performance do erro ou, simplesmente, superfície de erro (*Error Surface*) (Figura 3.14).




Figura 3.14 – Superfície de Erro

Fonte: <http://www.icmc.sc.usp.br/~prico/neural2.html> –24/05/2000

Considerando que a rede neural consiste em unidade de processamento não linear, a superfície de erro consistirá de um mínimo global ou, até mesmo vários mínimos locais.

O processo matemático de treinamento da rede é realizado da seguinte maneira: para cada padrão apresentado à rede ($\mathbf{x}^p_k$), a camada escondida calcula a soma ponderada das unidades da camada de entrada conectada a ela:

$$n_j^p = \left(\sum_{k=1}^k w_{ij} \cdot x_k^p \right) - \theta_j \quad (3.7)$$

que será o argumento da função de ativação, $\varphi(\cdot)$, resultando a saída

$$A_j^p = \varphi(n_j^p) \quad (3.8)$$

Cada neurônio de saída i receberá os sinais A_j^p de cada unidade escondida e calculará:

$$n_i^p = \left(\sum_{j=1}^j w_{ij} \cdot A_j^p \right) - \theta_i \quad (3.9)$$

onde a partir desse resultado será calculada a saída da rede por:

$$a_i^p = A_i^p = \varphi(n_i^p) \quad (3.10)$$

sendo que $\varphi(\cdot)$ é função de ativação para cada unidade da rede e θ são os respectivos limiares.

Seja $d_i(t)$ representado pelo valor desejado ou resposta meta para um neurônio i em um tempo t de uma rede neural multicamada e o valor calculado por ela representado por $a_i(t)$, correspondente ao estímulo aplicado pelo vetor *input* $x_r(t)$.

Como o valor da resposta calculada é diferente do valor desejado, então é embutido um erro entre as diferenças desses valores. O sinal do erro na saída do neurônio i após a t -ésima iteração, é definido como:

$$\varepsilon_i(t) = d_i(t) - a_i(t) \quad (3.11)$$

O valor instantâneo da soma dos erros médios quadráticos sobre todos os neurônios da camada de saída, por definição é dado pela expressão:

$$E(t) = \frac{1}{2} \sum_{i \in C} \varepsilon_i^2(t) \quad (3.12)$$

onde C corresponde ao conjunto de todos os neurônios na camada de saída da rede. O Erro Médio Quadrático (*Mean Squared Error – MSE*), é obtido pelo somatório de $E(t)$ e então normalizado com relação ao conjunto de tamanho N (número de padrões apresentados), dado pela expressão

$$E(W) = \frac{1}{N} \sum_{t=1}^N E(t) \quad (3.13)$$

O objetivo da aprendizagem por correção do erro é minimizar a função custo ou função aproximada $E(W)$ com relação aos pesos sinápticos da rede, que é uma medida sobre o erro $\varepsilon_k(t)$, de maneira que o valor de $a_i(t)$ se aproxime o máximo possível do valor de $d_i(t)$. A função custo comumente usada é a do MSE, do tipo contínua e diferenciável para qualquer peso sendo representada pela Equação (3.13). Pode ser considerada outro tipo de função, por exemplo, a do Desvio Médio Absoluto (*Mean Absolute Deviation – MAD*), ou ainda, a Soma dos Erros Quadráticos (*Sum Squared Error – SSE*). Esta minimização da função MSE com relação aos

parâmetros da rede conduz ao método do gradiente descendente, que consiste em dada uma medida de erro ou função custo representado por $E(W)$, buscar o melhor conjunto de pesos W_{ji} deslizando no sentido descendente da superfície definida no espaço W , ou seja, tenta minimizar a função (ABELÉM, 1994).

Um dos problemas de aproximação paramétrica incide em uma questão bem natural: como escolher a função de aproximação que melhor ajuste, ou seja, que tipo de restrição paramétrica deve ser imposta ao modelo de aproximação (VON ZUBEN, 1996).

O ajustamento ou correção dos peso é feito a partir do valor do erro calculado para cada padrão de treinamento apresentado à rede. O nível de atividade interna da rede $n_i(t)$ produz uma entrada de não linearidade associada com o neurônio i e tem a seguinte expressão:

$$n_i(t) = \sum_{j=0}^P w_{ij}(t) - a_i(t) \quad (3.14)$$

no qual P o número total de entradas (exceto os limiares) aplicada ao neurônio i . Logo o valor calculado na saída do neurônio i é:

$$a_i(t) = \varphi_i(n_i(t)) \quad (3.15)$$

no qual $\varphi(.)$ é Função de Ativação.

A Função de Ativação (FA), representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade. O emprego da FA nas camadas intermediárias de uma rede neural se faz pela necessidade de se introduzir a não linearidade (capacidade de representar função não linear), isto é, sem a não linearidade, as camadas escondidas não se tornariam mais poderosas que os *perceptron*. Estes, por sua vez, não possuem camadas escondidas, apenas constituem-se de camadas de entrada e saída. A não linearidade é uma das grandes características potenciais da RMC. (funções do tipo *sigmoid* são recomendáveis) (BARP, 1999).

Com relação à camada de saída, a escolha da FA deverá habilitar uma distribuição dos valores meta ou desejados. As funções do tipo *sigmoid*, são comumente usadas quando a série meta não é limitada. Quando estes valores não são limitados, é necessário o uso de uma FA não limitada (função identidade) (JORDAN, 1995).

Uma das características requerida para uma FA é que ela satisfaça a propriedade da existência da derivada, devido à necessidade do cálculo do gradiente local de cada neurônio de uma RMC requerer o conhecimento da derivada da FA. Quando as propriedades dinâmicas estão envolvidas na definição do estado de ativação, são então empregadas alguns tipos de função como características monotonicamente não decrescente, que defina o estado e ativação. Um exemplo de FA não linear diferenciável continuamente, mais aplicada em redes do tipo RMC é *sigmoidal* não linear. Uma forma particular definida para um neurônio i é pela função logística (*logistic function*),

$$\varphi_i(n_i(t)) = \frac{1}{1 + \exp(-n_i(t))}, \quad -\infty < n_i(t) < \infty \quad (3.16)$$

na qual $n_i(t)$ é o nível atividade interna do neurônio i . De acordo com a linearidade, a amplitude de saída permanece no intervalo de $0 \leq n_i \leq 1$.

Outro tipo de não linearidade *sigmoidal* é a função tangente hiperbólica, a qual assume a forma assimétrica com relação à origem e para qual a amplitude da saída permanece no intervalo de $-1 \leq n_i \leq 1$, representada pela equação (HAYKIN, 1994):

$$\varphi(n_i(t)) = a \tanh(bn) \quad (3.17)$$

onde a e b são constantes.

No caso particular do algoritmo BP aplica a correção $\Delta w_{ij}(t)$ para o peso sináptico $w_{ij}(t)$, que é proporcional ao gradiente $\frac{\partial E(t)}{\partial w_{ij}(t)}$. De acordo com a Regra da Cadeia, o gradiente é expresso por:

$$\frac{\partial E(t)}{\partial w_{ij}(t)} = -\varepsilon_i(t) \cdot \varphi_i(n_i(t)) \cdot a_i(t) \quad (3.18)$$

A correção $\Delta w_{ij}(t)$ aplicada ao peso $w_{ij}(t)$ é definida pela Regra Delta

$$\Delta w_{ij}(t) = -\eta \cdot \left(\frac{\partial E(t)}{\partial w_{ij}(t)} \right) \quad (3.19)$$

em que η é um parâmetro constante chamado de taxa de aprendizagem do algoritmo BP, o subscrito i é o neurônio i da camada posterior e o subscrito j é o neurônio j da camada anterior. O algoritmo de retro-propagação do erro (método de obtenção das derivadas parciais) é conhecido por *Backpropation Padrão*. Nele a regra da cadeia irá propagar a função $E(W)$ definida na saída da rede, via caminho inverso, seguindo até a entrada da rede.

Outra forma de se representar a correção do peso é dada pela fórmula:

$$\Delta w_{ij}(t) = \eta \delta_i(t) a_i(t) \quad (3.20)$$

sendo $\delta_i(t)$ o gradiente local para o neurônio de saída i e definido como o produto do erro correspondente ($\varepsilon_i(t)$) pela derivada $\varphi_i'(n_i(t))$ da função de ativação associada.

Dependendo de onde o neurônio i está localizado, pode-se definir dois casos para o cálculo da correção do erro, segundo o valor do gradiente local $\delta_i(t)$:

- Caso 1: Neurônio i está na camada de saída. Neste caso existe um valor meta a ser comparado e, calculado o erro $\varepsilon_i(t)$, a expressão que determina o gradiente local $\delta_i(t)$ é dada por:

$$\delta_i(t) = \varepsilon_i(t) (\varphi_i'(t)) \quad (3.21)$$

- Caso 2: O neurônio i está na camada intermediária. Neste caso não existe um valor meta para comparações e a expressões do gradiente local é redefinida por:

$$\delta_i(t) = (\varphi_i(t)) \sum_k \delta_k(t) \cdot w_{ki}(t) \quad (3.22)$$

Resumindo, a Regra Delta é definida pela correção $\Delta w_{ij}(t)$ aplicada aos pesos sinápticos conectando o neurônio j ao neurônio i ,

$$\begin{bmatrix} \text{Correção do} \\ \text{Peso } \Delta w_{ij}(t) \end{bmatrix} = \begin{bmatrix} \text{Parâmetro Taxa} \\ \text{de Aprendizagem} \\ \eta \end{bmatrix} \times \begin{bmatrix} \text{Gradiente} \\ \text{Local} \\ \delta_i(t) \end{bmatrix} \times \begin{bmatrix} \text{Entrada no} \\ \text{Neurônio i} \\ a_i(t) \end{bmatrix}$$

Ao ser atribuído um dado valor à taxa de aprendizagem η observa-se que se este valor é muito pequeno a velocidade de aprendizagem da rede torna-se lenta, pois são bem menores as mudanças em w_{ij} . No caso de η ser grande, implica em velocidades de aprendizagens rápidas e, as mudanças dos pesos sinápticos serão grandes. Um dos mecanismos bastante utilizado para corrigir estas distorções (instabilidade na rede, ou seja, movimentos oscilatórios) é o método modificado da Regra Delta Generalizada (RDG). A correção do peso é então dada por:

$$\Delta w_{ij}(t) = \alpha \Delta w_{ij}(t-1) + \eta \delta_i(t) a_i(t) \quad (3.23)$$

sendo α a constante *momentum*, geralmente um número positivo ($0 \leq |\alpha| < 1$) que controla o *loop* de realimentação em torno de $\Delta w_{ij}(t)$. Quando α é igual a um, o algoritmo BP opera sem a constante *momentum*.

A inclusão da constante α no BP tende a implementar uma aceleração descendente sob direção do valor estacionário. Possui, também, um efeito estabilizador nas direções que oscilam.

Muitos são os algoritmos usados nos treinamentos de RNA's, e alguns são baseados no algoritmo proposto por D.O.Hebb em 1961. Já os mais eficientes são baseados em trabalhos publicados por Widrow em 1959, Widrow e Hoff no ano de 1960 e Rosenblatt em 1962.

Indiscutivelmente, o mais utilizado em redes multicamadas e difundido na literatura é o algoritmo de retro-propagação do erro ou *backpropagation*.

3.8.7.3 – MODOS DE TREINAMENTO DE RMC

Em aplicações práticas de algoritmo de retro-propagação, o aprendizado é resultado de apresentações repetidas de todas as amostras do conjunto de treinamento ao RMC. Cada apresentação de todo conjunto de treinamento durante o processo de aprendizagem é chamado de época. O processo de aprendizagem é conduzido época-por-época até que os pesos sinápticos e os níveis de limiares (*Threshold ou bias*) da rede encontrem a estabilização, simultaneamente convergindo a um valor mínimo do erro considerando aquele conjunto de treinamento selecionado.

Através de um processo iterativo, existem dois tipos possíveis de métodos de treinamento para se calcular a atualização dos pesos em algoritmos de aprendizagem de RMC, a partir de um conjunto de dados para treinamento da rede (SILVA, 1998). Estes métodos são:

- Método de atualização local (*on-line ou padrão a padrão*): neste método, a atualização dos pesos é feita imediatamente após a apresentação de cada amostra de treinamento. Especificamente considere, uma época consistindo de N padrões de treinamento arbitrariamente ordenados $\{(x_1, s_1), \dots, (x_n, s_n)\}$. A primeira amostra (x_1, s_1) da época é apresentada à rede, e são efetuados o passo positivo e a retro-propagação do erro, resultando em um ajuste dos pesos das conexões. Em seguida, a próxima amostra (x_2, s_2) é apresentada a rede e o passo positivo e a retro-propagação do erro são efetuados, resultando em mais um ajuste do conjunto de pesos. Este processo é repetido até que a última amostra seja apresentada à rede. Este método também é conhecido como método de atualização *on-line* ou padrão a padrão.

- Método de atualização em lote (Batelada ou *Batch* ou *off-line*): no método em lote, a atualização dos pesos só é feita após a apresentação de todas as amostras de treinamento que constituem uma época. O ajuste relativo a cada apresentação de um par de entradas é acumulado. Este método também é conhecido como método de atualização *off-line*, *batch* ou batelada.

Do ponto de vista operacional, o método padrão a padrão de treinamento é preferível, pois requer um menor armazenamento local e para cada conexão sináptica (PARMA, MENEZES e BRAGA, 1997).

Numa análise final, entretanto, a eficiência dos dois métodos depende do problema a ser tratado (HAYKIN, 1994).

3.8.7.4 – NORMALIZAÇÃO DOS DADOS DE ENTRADA

A influência dos dados de entrada no treinamento de uma RNA pode ser vista da seguinte maneira: se duas entradas, conectadas à mesma unidade, possuem intervalos de variação muito diferentes, os pesos ligados a estas unidades devem ser atualizados de maneira equalizada. Este processo de adaptação dinâmica dos intervalos pode ser muito demorado do ponto de vista computacional quando há uma variação grande nos intervalos de valores das diferentes entradas (JOOST & SCHIFFMAN, 1993).

O termo normalização é usado para representar um processo onde um vetor freqüentemente é dividido pela norma de um vetor. Outra definição da literatura refere-se ao rescalonamento através de um mínimo ou média de um vetor, para produzir dados ou elementos que permaneçam entre o intervalo, por exemplo, de [0,1] ou [1, -1]. Este procedimento faz parte de um estágio denominado pré-processamento do conjunto de variáveis de entrada, neste caso, o valor da variável original e dado por x_k e após o estágio passará a valer $\tilde{x}_k$. O conjunto de dados de saída da rede, $\tilde{a}_k$, também são submetidos ao estágio de pós-processamento para convertê-los à forma numérica requerida, a_k (Figura 3.15).




Figura 3.15 – Estágios de Pré e Pós-processamento de Rede Neural

Nas aplicações práticas a escolha do estágio de pré-processamento tem um efeito significativo sobre a performance da generalização e também pode oferecer, geralmente, grandes melhoramentos no desempenho do sistema de reconhecimento padrão (BISHOP, 1995).

A solução desse problema é aplicar a normalização, que consiste basicamente, em transformar linearmente os pares padrões. Após o treinamento, os resultados calculados pela rede passam por um processo de reversão da normalização para os valores reais.

Dentre os vários procedimentos de normalização requeridos pelas funções de ativação não lineares, como exemplos, aplicando a Equação (3.24) os valores normalizados estarão no intervalo de [0,1] ou [1-1].

$$\tilde{x} = \frac{(x - x_{min,exp})(x'_{max} - x'_{min})}{x_{max,exp} - x_{min,exp}} + x'_{min} \quad (3.24)$$

onde

x = é o valor da variável;

$\tilde{x}$ = é o valor da variável normalizado;

$x_{max,exp}$ = é o valor máximo da variável;

$x_{min,exp}$ = é o valor mínimo da variável;

x'_{max} = é o valor máximo da variável normalizada e

x'_{min} = é o valor mínimo da variável normalizada.

É importante lembrar que a normalização imposta aos dados é um processo reversível.

3.8.7.5 – INICIALIZAÇÃO DOS PESOS

A inicialização dos pesos de uma rede neural é um dos fatores relevantes com vista ao melhor ajuste dos pesos sinápticos e limiares decorrentes do treinamento por retro-propagação do erro. Uma escolha inicial errada dos parâmetros livres pode levar a rede a um fenômeno conhecido como saturação prematura (*premature saturation*) (LEE et al. 1991). Este fenômeno refere-se a um determinado procedimento que ocorre durante o treinamento à rede, em que o erro

médio quadrático permanece quase constante por alguns períodos de tempo durante o processo de aprendizagem da rede, com isso, mascarando a existência do erro mínimo. Neste caso, o processo de aprendizagem pode ser interrompido impedindo a busca do provável erro mínimo da função fazendo com que a convergência ocorra prematuramente. (Figuras 3.16 e 3.17).




Figura 3.16 – Superfície de Erro – Mínimo Local




Figura 3.17 – Superfície de Erro – Mínimo Global

Melhoramentos nos algoritmos de treinamento e topologia ótima da rede, apesar de serem uma boa estratégia de acertos voltada a inicialização dos pesos, não garantem boa convergência da rede se os pesos forem mal inicializados. Um dos procedimento de obtenção de resultados mais rápidos e precisos pode ser realizado quando o ponto de partida do processo de otimização estiver o mais próximo da solução ótima.

Uma regra muito utilizada baseia-se em inicializar uma rede com pesos aleatórios numericamente pequenos. A motivação para este procedimento é que valores absolutos muito grandes de pesos originam nós escondidos a serem altamente ativos ou inativos para toda a amostra de treinamento e, então, indiferentes para o processo de treinamento. Outro processo recomendado de inicialização não-aleatória é linearizar a rede, e então calcular os pesos iniciais por meio de regressão linear. Esta estratégia torna-se vantajosa se o problema for mais ou menos linear, então, a maior parte do treinamento é feita antes do ajustamento iterativo dos pesos a ser iniciado (LEONDES, 1998).

3.8.7.6 – CRITÉRIOS DE PARADA

O processo de minimização da função custo, em geral, não tem convergência garantida e não possui um critério de parada bem definido. Um critério de parada não recomendável, por não levar em conta o estado do processo iterativo de treinamento, é interromper o treinamento após um número fixo (definido previamente) de iterações (NUNES, 1998).

Um dos critérios de parada geralmente atribuídos à convergência da rede, é o de interromper o processo iterativo do treinamento, limitado por uma quantidade ou número de iterações pré-definidos. HAYKIN (1994), observou outros critérios:

- É considerado que o algoritmo de retro-propagação convergiu quando a norma Euclidiana da estimativa do vetor gradiente atingiu um valor suficientemente pequeno;

- É considerado que o algoritmo de retro-propagação convergiu quando a variação de erro quadrático de uma época (ou passo) para outra, atingiu um valor suficientemente pequeno;
- É considerado que o algoritmo de retro-propagação convergiu quando o erro quadrático médio atingir um valor consideravelmente pequeno, ou seja, $E_{med}(x) \leq \varepsilon$, em que ε é um valor suficientemente pequeno.

É importante observar que se for considerado como critério de parada, o valor mínimo para a função custo, torna-se difícil garantir a convergência do algoritmo ao valor desejado, ou seja, uma hipótese é que o valor ε desejado pode ser menor que o valor mínimo da função.

Atualmente existe uma grande quantidade de pesquisadores procurando funções de erro (custo) alternativas, com o objetivo de melhorar as características de convergência dos perceptrons de múltiplas camadas. Uma abordagem possível é adotar um funcional de erro que aumente a capacidade da rede escapar de mínimos locais.

3.8.8 – VALIDAÇÃO CRUZADA

Quando treinamos uma RNA, geralmente desejamos obter uma rede com a melhor capacidade de generalização possível, ou seja, a maior capacidade de responder corretamente a dados que não foram utilizados no processo de treinamento. As arquiteturas convencionais, totalmente interconectadas, como o MLP, estão sujeitas a sofrerem um sobre-treinamento (*overtraining*): quando a rede parece estar representando o problema cada vez melhor, ou seja, o erro do conjunto de treinamento continua diminuindo, em algum ponto deste processo a capacidade de responder a um novo conjunto de dados piora (PRECHELT, 1997).

A validação cruzada ou *cross validation* é uma técnica usada para auxiliar a determinação dos valores ótimos de alguns parâmetros livres, que não possuem regras para determiná-lo e que são usados em RMC e no algoritmo BP. Esses procedimentos indicam a ocorrência do treinamento executado de forma excessiva, como também, a interrupção do treinamento antes de encontrar o valor mínimo do erro (BARP, 1999).

3.8.9 – GENERALIZAÇÃO

A capacidade de generalização se refere à habilidade da rede neural fornecer um valor de saída que seja aceitável, segundo algum critério, quando um conjunto de dados não utilizados durante o treinamento lhe for apresentado. Esse fato está relacionado com os fatos anteriores, pois a capacidade de generalização depende da estimativa dos parâmetros da rede (pesos) e do número de neurônios utilizados (SJÖBERG, 1995). Para um número de neurônios ótimo, o nível de generalização também é ótimo. Contudo, se a rede é subdimensionada para o problema, então ela não generalizará bem e se a rede é superdimensionada, a capacidade de generalização será também afetada por haver um excesso de parâmetros na rede. Todavia, é possível melhorar a generalização parando o processo de minimização antes que o mínimo seja atingido (no caso de uma rede com número de neurônios fixos). Buscar o mínimo, nesse caso corresponde também a aumentar a variância do modelo. O número de amostras utilizadas para treinamento também influencia a capacidade de generalização. Em geral, um número maior de amostras tende a aumentar essa capacidade, desde que o problema abordado seja estático.

SJÖBERG (1995), comenta que o uso excessivo dessa técnica pode levar a uma conclusão viciada sobre a capacidade de generalização da rede, uma vez que o uso repetido do conjunto de dados para teste da rede equivaleria a incorporá-lo no conjunto de treinamento.

Redes do tipo MLP são conhecidas por representarem um modelo estacionário, o qual é caracterizado por equações que não possuem memória, significando que a sua saída é função apenas da entrada corrente e não de valores passados. Contudo, o problema de séries temporais requer o uso de valores passados da série. Para isso, é necessário utilizar um modelo dinâmico de rede.

3.9 – REDES NEURAIS ARTIFICIAIS APLICADAS À PREVISÃO

As aplicações da técnica de redes neurais artificiais (RNA's) para previsão têm sido campo de intensa pesquisa na última década. As comparações dos resultados das previsões dos modelos de RNA's e por técnicas tradicionais baseadas em modelos de séries temporais do tipo Box e Jenkins também têm sido objeto de investigação (TANG et al., 1991 e HILL et al., 1996).

Nesses trabalhos justifica-se a aplicação das RNA's a partir do reconhecimento de algumas limitações das técnicas estatísticas de modelagem de séries temporais por não incorporarem relações não-lineares entre as variáveis, o que deteriora a qualidade dos resultados da previsão na presença de processos não-lineares, tão comuns em Recursos Hídricos. Um segundo aspecto refere-se à presença de *outliers*, os quais podem originar estimadores viciados dos parâmetros dos modelos. Um terceiro aspecto refere-se à etapa da própria definição do modelo e ainda a estimação dos seus parâmetros, nas quais a interação humana e a avaliação estarão sujeitas a uma certa parcela de subjetividade. Uma boa parte dessas limitações não são encontradas nos modelos de RNA's.

As conclusões dos estudos comparativos revelam superioridade da técnica de previsão por RNA's devido às observações seguintes (HILL et al, 1996):

- a) O modelo de RNA's apresenta melhores resultados que os modelos de séries temporais na previsão de variáveis presentes em processos com forte não-linearidade e descontinuidade;
- b) O modelo de RNA's consegue melhores previsões do que os modelos de séries temporais em séries de menor extensão de dados observados;
- c) A variância dos erros de previsão do modelo de RNA's foi sistematicamente menor que aquela dos modelos de séries temporais.

Diversos autores têm mostrado a viabilidade de utilizar RNA's para previsão de séries temporais (CHAKRABORTY et al., 1992; TANG et al., 1991). SHARDA e PATIL (1990) mostram que a performance das redes neurais é comparável à obtida com o método de Box & Jenkins.

O desempenho das redes neurais é afetado por vários fatores, tais como a topologia das redes, os parâmetros de treinamento e a natureza das séries temporais. TANG e FISHWICK (1991), demonstram que existe uma arquitetura de unidades escondidas ótima para cada diferente

tipo de série temporal. Concluí-se neste trabalho que o modelo de RNA sem padronização das séries produz previsões de menor erro que os modelos do tipo SARIMA.

ZHANG et al. (1994) desenvolveram um modelo de redes neurais artificiais para a previsão de demanda de água. Neste trabalho uma aproximação baseada no modelo de RNA's é proposta para a previsão de demanda diária de água. A aproximação por RNA's é comparada com alguns modelos convencionais e os resultados mostraram que esta técnica é mais confiável e mais eficiente.

Em essência a maioria dos modelos de previsão de demanda a curto prazo publicados tem tratado demandas diárias de água com séries temporais estocásticas e descrevem a relação entre a demanda diária e as variáveis de entrada do modelo através do uso de expressões lineares. Porém muitas pesquisas mostraram que as relações são geralmente não lineares, sendo assim esses modelos já não são adequados.

As entradas do modelo de redes neurais para o problema de previsão de demanda, são variáveis que causam flutuação na demanda diária de água. De acordo com ZHANG et al.(1992) e YAMADA et al. (1992) as principais variáveis são: último dia de abastecimento, temperatura diária, tempo, precipitação e características do dia. As variáveis tempo e precipitação foram tratadas como variáveis discretas, isto é, tempo foi classificado como ensolarado, nublado e chuvoso, e a precipitação foi classificada em três intervalos, [0mm/dia, 1mm/dia), [1mm/dia, 5mm/dia) e [5mm/dia, ∞). A variável característica do dia foi dividida em dia útil e Domingo (inclusive feriado nacional). A função de ativação usada foi a sigmoideal.

Com o estudo do modelo de redes neurais, as demandas diárias de água de abril de 1990 a março de 1991 foram previstas e comparadas com os registros. O erro relativo foi menor que 5% durante 339 dias do ano, maior que 10% para cinco dias, que são um feriado especial, o dia de ano novo e três dias de tufões. Em geral, as previsões feitas pelo modelo de redes neurais estão em excelente aderência com os registros.

ABELÉM et al. (1995) apresentam um estudo do processo de modelagem das RNA's para a previsão de séries temporais, em função de três fatores determinantes de desempenho,

convergência, generalização e escalabilidade, e concluí que a modelagem das RNA's mostra-se como um fator crucial para o sucesso nas aplicações. A falta de um maior conhecimento das complexas inter-relações entre os diversos parâmetros que influenciam o desempenho da rede, faz com que este sucesso seja muito dependente da experimentação prática e da experiência do projetista.

No que concerne a modelagem de séries hidrológicas, as aplicações mais recentes estão relacionadas com a previsão de demanda de regras da lógica Fuzzy (MUSTER et al., 1994), modelagem estocástica de precipitações (BARDOSSY, et al., 1993), operação otimizada de reservatórios (WEIJUN e JING, 1994) e modelagem da condutividade hidráulica em aquíferos (RANJITHAN et al., 1993).

FERNANDES (1995), realizou um estudo aplicando a técnica de redes neurais artificiais, mais especificamente o modelo perceptron multicamadas com aprendizado por retro-propagação de erros, à previsão de valores futuros de séries temporais.

O estudo foi executado através de previsões a partir de uma determinada arquitetura da rede neural, a qual foi construída com base na análise estatística da série, para três séries reais. Os resultados obtidos com as RNA's foram comparados aos prognósticos realizados pelo método econométrico que apresenta os melhores resultados para o problema da previsão de séries temporais.

Este trabalho comprovou com segurança que as RNA's são ferramentas poderosas para a realização de previsão de séries temporais, capazes de realizar prognósticos com o mesmo nível de precisão ou até maior que um dos métodos estatísticos mais respeitados, embora não possam oferecer considerações estatísticas sobre a série devido à sua natureza.

JAIN e ORMSBEE (1995) separaram os modelos de previsão de demanda que são desenvolvidos usando métodos estatísticos e a tecnologia de redes neurais. Em cada caso os resultados dos modelos são desenvolvidos usando cinco anos de dados diários (1982-1986) de Lexington, Kentucky e então testados usando séries de demandas anuais e diárias.

Historicamente, a maioria dos trabalhos de previsão de demanda tem focalizado o desenvolvimento de previsão a longo prazo. Com a reorientação e ênfase nos programas de controle para sistemas de distribuição de água, houve a necessidade da previsão de demanda a curto prazo. A maioria das tentativas de modelos de demanda a curto prazo tem se concentrado no uso de métodos estatísticos, isto é, análise de regressão ou análise de séries temporais. Enquanto geralmente esses métodos produzem performance adequada na modelagem cíclica das variáveis observadas em uma série típica de demanda de água, eles requerem a seleção à priori da estrutura do modelo subjacente e não são geralmente adaptáveis as mudanças nas realizações das demandas futuras. Em estudos recentes a tecnologia de redes neurais tem sido proposta como uma metodologia alternativa para o uso na previsão da demanda, as quais evitam estas deficiências (JAIN e ORMSBEE, 1995).

As RNA's têm tido grande destaque na previsão de séries temporais por sua habilidade de aprendizado e capacidade de generalização, associação e busca paralela. Estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries, tais como sazonalidade, periodicidade, tendências, entre outras, na maioria das vezes camufladas por ruídos, sem necessitar do laborioso passo da formulação teórica, imprescindível para os procedimentos estatísticos (REFENES, 1992; KINGDON, 1993; ZUBULUM(a), 1995 e ZUBULUM(b), 1995).

SARMENTO (1996) Fez inicialmente uma sucinta classificação das redes de neurônios artificiais no âmbito da teoria geral dos sistemas. Em seguida foi apresentada a formulação matemática básica da categoria denominadas redes cibernéticas, sob a ótica da otimização dos parâmetros. Algoritmos de otimização local e global e sua eficiência para a finalidade considerada são também comentados bem como aspectos relacionados com a definição da arquitetura das redes em função da natureza do problema a ser modelado.

Uma das aplicações realizada consiste na reprodução através de uma RNA da relação chuva-vazão para uma bacia localizada na região semi-árida do Nordeste brasileiro onde a modelagem desse fenômeno de transformação se torna bastante complexa entre outras razões em função do caráter convectivo dominante nas precipitações da região.

Na seguinte aplicação é investigada a habilidade das redes de perceptrons para a previsão de vazões médias diárias na bacia do rio Leine, localizada na região central da Alemanha.

Sarmiento concluiu que em ambas as aplicações o algoritmo de propagação regressiva dos erros utilizado apresentou resultados satisfatórios, confirmando a superioridade do modelo RNA's.

As aplicações da técnica de RNA's no setor de recursos hídricos têm sido feita através de diversos trabalhos para a previsão de vazões fluviais. Uma comparação entre as previsões por RNA e por modelos de séries temporais para postos de vazões médias mensais afluentes a diversos reservatórios do sistema hidroelétrico brasileiro é encontrada em BALLINI et al. (1997); onde as séries de vazões utilizadas tem sazonalidade definida. Neste caso existem basicamente duas formas de abordar o problema de previsão usando modelos de Box & Jenkins. Na primeira a sazonalidade é assumida determinística e a série original é transformada em uma série padronizada removendo-se a média e o desvio-padrão sazonal; só então se ajusta um modelo ARMA (p,q) à série padronizada. Na Segunda supõe-se que a sazonalidade é estocástica e um modelo do tipo SARIMA (p,q) (P,D,Q)s é ajustado diretamente aos modelos originais.

BARP (1999) investigou a utilização de modelos determinístico de simulação hidrológica do tipo chuva-vazão. Foram testados dois modelos determinístico do tipo chuva-vazão, ambos com processo de otimização dos parâmetros na forma irrestrita e não-linear: SMAP (*Soil Moisture Accoreting Procedure*) – com aplicação de um método de otimização de primeira ordem; e outro modelo utilizando a técnica de Redes Neurais Artificiais, com método de otimização de segunda ordem.

Assim como diversos autores em âmbito internacionais (ex: HSU et al. 1995) ou nacional como BARP e BARBOSA (1999) e o já citado SARMENTO (1996), BARP (1999) concluiu pela superioridade dos resultados de previsão do modelo de RNA's.

HIPPERT et al. (2001) trazem à comunidade científica um estudo que tem como objetivo. examinar criticamente, artigos publicados entre 1991 e 1999 que utilizam RNA's na previsão de carga elétrica a curto prazo.

A previsão de carga elétrica é uma tarefa difícil, primeiro porque a série dados é complexa e exibe vários níveis de sazonalidade: a estimativa da carga em uma dada hora não depende somente da carga da hora anterior, mas da carga da mesma hora de dias anteriores. Por isso as variáveis dependentes são consideradas importantes, especialmente as variáveis relacionadas ao tempo. É relativamente fácil adquirir uma previsão com aproximadamente 10 % de erro absoluto, porém os custos do erro são tão altos, que as pesquisas poderiam ajudar reduzindo isto a alguns pontos percentuais. Uma estimativa freqüentemente citada em BUNN e FARMER (1985), sugere que um aumento de 1% no erro previsto implica em 10 milhões de dólares de aumento nos custos operacionais por ano.

A maioria dos modelos de previsão e métodos tem sido usados com relativo grau de sucesso na previsão de carga elétrica. Eles podem ser classificados como modelos de séries temporais (univariados), nos quais a carga é modelada em função de valores observados no passado e modelos causais, nos quais a carga é modelada como função de alguns fatores dependentes, especialmente do tempo e variáveis sociais.

Nos últimos tempos, muitas pesquisas tem sido realizadas na aplicação de técnicas de inteligência artificial em problemas de previsão de carga. Sistemas especialistas têm sido experimentados e comparados com métodos tradicionais. Lógica Fuzzy e modelos Fuzzy-neural também tem sido experimentados. Porém, os modelos que recebem a maior parte a atenção são indubitavelmente as redes neurais artificiais.

Os primeiros relatórios sobre problemas de previsão de carga foram publicados no final da década 80 e no ano de 1990 (CZERNICHOW et al., 1996 citado por HIPPERT et al. , 2001). Desde então o número de publicações tem aumentado.

A maioria dos trabalhos propõe perceptron de multicamadas, que podem ser classificados em dois grupos, de acordo com o número de neurônios de saída. No primeiro grupo

estão os que tem somente uma saída, usados para prever carga da próxima hora, carga de pico do próximo dia ou carga total do próximo dia. No segundo grupo são os que tem sucessivos neurônios de saída para a previsão de carga de hora em hora. Tipicamente eles tem 24 neurônios para previsão de carga para as 24 horas do dia, sendo essa série horária chamada de perfil de carga.

Apesar de vários relatórios sobre a performance das RNA's para a previsão, alguns pesquisadores desta área apresentam algum ceticismo quanto às redes neurais. A revisão bibliográfica feita por HIPPERT et al. (2001) contribuiu para esclarecer as razões para esta incredibilidade. Este trabalho apresentou dois fatores, os quais podem estar entre as razões deste ceticismo, sendo elas:

a) A maioria dos modelos propostos, especialmente os projetados para prever perfis de carga, parecem ter um excesso de parametrização. Muitos estavam baseados em um único modelo de previsão multivariada, isto é eles consideram os perfis com vetores de 24 componentes que deveriam ser previstos simultaneamente por uma única rede com 24 neurônios de saída. Esta aproximação conduziu ao uso de uma RNA muito grande, a qual teria centenas de parâmetros a serem calculados e poucos dados.

b) Os resultados da performance dos teste nessas RNA's, tem sido aparentemente bons, mas nem sempre convincentes, todos esses modelos foram testados com dados reais. Todavia em muitos casos esses testes não foram levados em consideração, porque os modelos não foram comparados com padrões de referência e as análises dos erros não fizeram o uso de avaliação gráfica e ferramentas estatísticas.

Em resumo, a maioria dos trabalhos publicados para a previsão de cargas apresentou modelos aparentemente incompletos (HIPPERT et al., 2001).

A necessidade da modernização do setor de saneamento, da redução das perdas no sistema, da otimização do uso da energia elétrica, de manter as pressões na rede entre valores máximos e mínimos, nos leva a investigação de modelos que possam produzir bons prognósticos para a previsão de demanda de água, a partir de uma série de dados, que muitas vezes apresentam

falhas ou mesmo são de pequena extensão, dificuldades que podem ser superadas com o uso de redes neurais artificiais.

Evidencia-se a necessidade de pesquisas adicionais sobre o desempenho das RNA's antes de definir conclusões. É sabido também, que deveriam ser adotados padrões mais rigorosos nas experiências e na análise dos resultados, de forma que a comunidade científica possa ter resultados mais sólidos.

Neste trabalho realizam-se previsões univariada de demanda de água com discretização horária e diária e previsão multivariada de água com discretização horária. A previsão multivariada nos sistemas de abastecimentos urbanos, podem ser de extrema importância, quando há falta de dados em alguns dos reservatórios do sistema. A correlação dos reservatórios, na previsão multivariada pode ajudar a suprimir a falta desse dados.

Obtidos as previsões, foram calculados com os dados de saída medidas estatísticas, como o erro quadrático médio, o erro percentual médio, o erro absoluto médio e o erro percentual máximo.

Os resultados obtidos com a técnica de RNA's reforçam a pertinência da linha de pesquisa e a oportunidade da investigação que se propõe.

4 – METODOLOGIA

Neste trabalho três tipos de modelos foram estudados: o modelo de médias móveis e o modelo auto-regressivo, que são baseados em séries temporais; e o modelo de redes neurais artificiais que foi foco principal da pesquisa. Este último sofreu algumas variações nos seus dados de entrada e saída. Os resultados das previsões de todos os modelos foram comparados usando os resultados das medidas estatísticas.

4.1 – ANÁLISE DOS DADOS COLETADOS

Os dados de entrada dos modelos propostos foram: demanda, referente à Alça Leste, e temperatura, referente ao reservatório Araçá, localizado em outra Alça. O período de dados obtido foi de 08/06/1998 a 13/07/1999, não havendo nesse período limitações no fornecimento de água. Os arquivos possuem valores de temperatura e de demanda para as 24 horas do dia, incluindo valores mínimos, médios e máximos. Os arquivos de entrada e de saída foram gerados no aplicativo *Bloco de Notas for Windows* e salvos com extensão “.dat”. Os dados de entrada dos modelos propostos foram obtidos junto a SABESP.

Com a finalidade de estudar a relação existente entre as variáveis envolvidas na previsão (demanda e temperatura), é que calculamos o coeficiente de correlação que indicou o grau de intensidade da correlação entre as variáveis correlacionadas. Foi usado o coeficiente de correlação de Pearson, que é dado por:

$$r = \frac{n \sum x_i y_i - (\sum x_i)(\sum y_i)}{\sqrt{[n \sum x_i^2 - (\sum x_i)^2][n \sum y_i^2 - (\sum y_i)^2]}} \quad (4.1)$$

onde n é o número de observações.

4.2 – MODELO DE REDES NEURAIIS

Os modelos de redes neurais artificiais vêm sendo extensivamente aplicados aos problemas de previsão de séries temporais devido à sua capacidade de generalização e habilidade de aprendizado, tornando-se assim capazes de identificar e assimilar as características das séries. Em relação às técnicas de séries temporais do tipo Box-Jenkins, as RNA's calibram com período de tempo (observado) menor, alcançando resultados praticamente iguais (TANG, 1991). Outro fator que nos leva a utilização de RNA's é o processo de calibração automática que vem suprir uma deficiência de calibração dos parâmetros de outros modelos.

4.2.1 – ESTRUTURA DE RNA's PARA PREVISÃO DE CONSUMO DE ÁGUA EM SISTEMAS URBANOS DE ABASTECIMENTO

Os neurônios da camada de entrada são chamados de neurônios sensoriais, responsáveis pela recepção dos sinais de entrada e sua propagação, sem qualquer modificação para a camada seguinte da rede neural.

A camada intermediária é composta por n neurônios, e a camada de saída é composta por r neurônios, ambos análogos aos da Figura 4.1, porém a função de ativação nos neurônios da camada de saída é igual à função identidade.

Não existe regra definida para estabelecer o número inicial de neurônios a ser utilizado por camada. Existem algumas indicações que auxiliam como primeira tentativa, dentre elas aplicaremos a que indica para a camada de entrada (variáveis independentes) um número de neurônios igual ao número de variáveis de entrada. O número de neurônios da camada escondida deve ser o menor possível, mas como primeira tentativa, treina-se a rede para um número bem alto de neurônios e verifica-se o comportamento do erro, se ele for muito alto, então se deve diminuir até que o erro não se altere significativamente.

Como os neurônios, o número de camadas não possui regras estabelecidas e este valor fica em aberto, neste estudo o treinamento será feito para 3 camadas fixas. A função de ativação que será utilizada é a tangente hiperbólica do tipo log-sigmoidal.

O modelo de RNA's será simulado através do software MATLAB (*Matrix Laboratory for Windows*, que é um ambiente computacional técnico para visualização e computação numérica de alta performance. O MATLAB integra análise numérica, processamento de sinais e gráficos, em que o problema e as soluções são expressos tal como são formulados matematicamente, sem a programação tradicional (MATHWORKS, 1998).




Figura 4.1 – Rede Neural Multicamadas

Onde:

- n é o número de neurônios da camada de entrada;
- m é o número de neurônios da camada intermediária;
- p é o número de pesos (parâmetros ajustáveis).

4.2.2 – TREINAMENTO SUPERVISIONADO DA REDE NEURAL

Assumimos disponível um conjunto de dados de entrada-saída (estímulo-resposta) devidamente normalizados; tal como expresso na Equação (4.2), uma função objetivo a ser minimizada, e uma função de ativação igual para todos os neurônios e diferenciável ao menos até a segunda ordem, ambas fixas. Quanto à dimensão da rede neural, o número de neurônios na camada intermediária e o número de pesos (parâmetros w_0) a serem ajustados tem que ser fixo, o conjunto inicial de pesos é gerado aleatoriamente, com média 0 e distribuição uniforme em um intervalo de $[-0.1; 0.1]$.

$$(x_l, y_{dl})_{l=1}^N \quad (4.2)$$

Consideramos agora uma rede neural com uma camada intermediária, conforme apresentado na Figura 4.1. Esta possui as seguintes características de processamento:

- Cada camada contém um determinado número de neurônios do tipo perceptron (Figura 4.1), onde todos possuem a entrada adicional de polarização $x_0 = 1$,
- O vetor de entrada de cada camada da rede neural é distribuído a todos os neurônios da mesma camada,
- As saídas de todos os neurônios de uma camada formam o vetor de entrada para a camada seguinte.

Dado um estado inicial w_0 (pesos), deve-se conduzir a rede neural para um estado final w_f , tal que, para um determinado conjunto de dados de entrada-saída $(x_l, y_{dl})_{l=1}^N$, a saída y da rede assumam valores os mais próximos possíveis das saídas desejadas y_{dl} , $l = 1, \dots, N$, quando na entrada da rede são apresentados os correspondentes valores x_l , $l = 1, \dots, N$.

Este problema pode ser reformulado como segue:

Dado um estado inicial w_0 , conduzir a rede para um estado final w_f tal que, para um determinado conjunto de dados de entrada-saída, a função erro quadrático $J(w)$ seja minimizada.

$$J(w) = \sum_{l=1}^N \frac{1}{2} (y_l(w) - y_{dl})^2 = \sum_{l=1}^N \frac{1}{2} (g(u_l(w)) - y_{dl})^2 = \sum_{l=1}^N J_l(w) \quad (4.3)$$

O algoritmo de otimização usado neste trabalho é o gradiente conjugado escalonado, um método de segunda ordem, proposto por MOLLER (1993), o qual é considerado bastante eficiente na aplicação da técnica de redes neurais.

O algoritmo aplicado nesta pesquisa é descrito abaixo (MOLLER, 1993; BISHOP, 1997 e SILVA, 1998):

1. Escolha um vetor de parâmetros inicial θ_0 e escalares $0 < \sigma < 10^{-4}$ e $\lambda_0 = 0$;
2. Faça : o conjunto de $P_0 = r_0 = -\nabla f(x_0)$; $k = 0$; sucesso = 1 $\rightarrow$ verdadeiro;
3. Se sucesso = 1, então calcule a informação da Segunda ordem:

$$\sigma_k = \frac{\sigma}{\|d\|}; \quad s_k = \frac{\nabla f(x_k + \sigma_k d_k) - (\nabla f(x_k))}{\sigma_k} + \dots_k d_k; \quad \delta_k = P_k^T \cdot s_k;$$

4. Se $\delta \leq 0$, então faça a matriz *Hessiana* definida positiva:

$$\lambda_k^N = 2 \left[\lambda_k - \frac{\delta_k}{\|d_k\|} \right]; \quad \delta_k = \delta_k + (\lambda_k^N - \lambda_k) \|d_k\|^2; \quad \lambda_k = \lambda_k^N;$$

5. Calcule o tamanho do passo (taxa de ajuste):

$$\mu_k = P_k^T \cdot r_k; \quad \alpha_k = \frac{\mu_k}{\delta_k};$$

6. Calcule o parâmetro de comparação:

$$\Delta_k = \frac{2\delta_k [f(x_k) - f(x_k + \gamma_k \cdot d_k)]}{\mu_k^2};$$

7. Se $\Delta_k \geq 0$ (o erro pode ser reduzido), então atualize o vetor de pesos:

$$x_{k+1} = x_k + \gamma_k \cdot d_k; \quad r_{k+1} = -\nabla f(x_{k+1});$$

8. Se $(k \bmod P) = 0$, então reinicialize o algoritmo;

$$P_{k+1} = r_{k+1}$$

senão, defina uma nova direção conjugada de busca:

$$\beta_k = \frac{\|r_{k+1}\|^2 - r_{k+1}^T \cdot r_k}{\mu_k}; \quad P_{k+1} = r_{k+1} + \beta_k \cdot P_k;$$

9. Se $\nabla_k \geq 0,75$, então reduza o parâmetro

$$\lambda_k = 0,5\lambda_k;$$

10. Se $\nabla_k \leq 0,25$, então aumente o parâmetro

$$\lambda_k = 4\lambda_k;$$

senão, uma redução no erro não é possível:

sucesso = 0 (falso);

11. Se $r_{k+1} > \varepsilon$, em que $\varepsilon \rightarrow 0$, então faça:

$$k = k + 1; \quad \text{retorne ao passo 3;}$$

senão, o procedimento de ajuste chegou ao fim x_{k+1} é o ponto de mínimo.

Notação: ε = erro pré-estabelecido ou tolerância; γ = é um escalar que indica o comprimento do passo; β = coeficiente *momentum*; x = é um vetor de parâmetros; λ = coeficiente

de escalonamento ou parâmetros de ajuste; P = matriz de dados de entrada; d = é a direção de busca e f = é a superfície de erro de um problema de aproximação.

Em SANTOS e ROMERO (1994), descrevem-se os principais procedimentos de programação existentes para a implementação das RNA's e MOLLER (1993), CASTRO e VON ZUBEM (1998) definem o algoritmo de treinamento otimizado para o caso do modelo neural proposto, Algoritmo do Gradiente Conjugado Escalonado (GCE).

4.2.3 – PROCESSAMENTO DOS DADOS DE ENTRADA

A metodologia de processamento adotada foi primeiramente à normalização (pré-processamento) dos dados de entrada para o treinamento e o teste da RNA, posteriormente os resultados calculados são desnormalizados (pós-processamento).

Os valores de N (número total de padrões ou exemplos, contidos no conjunto de treinamento) são variáveis de acordo com o período de dados disponíveis. As séries de entrada e saída identificadas foram classificadas como atributos com valores reais por se tratarem de variáveis de vazão e temperatura. Nesse caso, os dados foram normalizados de acordo com o operador que os mapearam no intervalo de $[0,1]$ (Figura 4.2).




Figura 4.2 – Uso de Pré-processamento e Pós-processamento dos Dados em Conjunto com o Mapeamento das RNA's.

4.2.4 – FUNÇÃO OBJETIVO

A função objetivo usada em todas as simulações foi a minimização do erro quadrático médio (EQM). O erro quadrático médio, adotado na função objetivo, tem um aspecto importante para a modelagem das previsões de demanda de água. Ele penaliza os desvios entre série

observada e prevista com mesma intensidade (quadrática) em qualquer hora do dia. Neste sentido, os desvios nas horas de pico da demanda não são considerados no modelo como mais importantes do que nas horas fora de pico. Ou seja, o modelo visa garantir proximidade entre volume diário previsto e volume diário observado, para a calibração dos parâmetros. Este aspecto é de fato o mais importante de ser incorporado no modelo, uma vez que os sistemas de abastecimento de água trabalham com reservatórios, os quais podem prover suprimento de água e assim corrigir os pequenos erros de previsão que ocorrem ao longo das horas do dia, porém garantindo proximidade entre volume total diário previsto e observado.

Tal potencial será tanto maior quanto for à capacidade do reservatório relativamente à demanda que ele atende. Ou seja, quanto maior o volume armazenado relativamente à demanda média diária, menos importante é a coincidência entre picos entre a série observada com a série prevista pelo modelo. Não obstante, o volume diário consumido deve coincidir tanto quanto possível na série de valores previstos pelo modelo e na série de valores observados. Assim, o erro quadrático médio, adotado com critério de minimização, entre a série prevista e a série observada no modelo de RNA's será tanto mais adequado quanto maior o valor do parâmetro α , apresentado adiante, o qual representa a percentagem da demanda diária que o volume útil do reservatório consegue atender.

O parâmetro α e o coeficiente de variação são indicadores da flexibilidade operacional do sistema (FRANCATO, 2002).

$$\alpha = \frac{V_{\text{útil}}}{\text{Demanda Média Diária} \times 24 \text{ Horas}} \times 100 \% \quad (4.4)$$

$$\text{Coef. Variação} = \frac{\text{Desv. Padrão}}{\text{Dem. Média}} \times 100 \% \quad (4.5)$$

A Tabela 4.1 mostra o valor de α para os reservatórios da Alça Leste.

Tabela 4.1 – Estatística da Demanda Associada a Cada Reservatório

<i>Reservatórios</i>	<i>Dem. Média</i> (m^3/s)	<i>Desv. Padrão</i> (m^3/s)	<i>Coef. Variação</i>	<i>Volume Útil</i> (m^3)	α
<i>Jaçanã</i>	0.666	0.177	26.54 %	7825	13.60 %
<i>Edu Chaves</i>	0.835	0.101	12.10 %	23103	32.03 %
<i>Gopouva</i>	2.213	0.278	12.55 %	48858	25.55 %
<i>Penha</i>	0.422	0.116	27.61 %	15865	43.51 %
<i>Cangaíba</i>	0.524	0.163	31.15 %	3678	8.12 %
<i>Jd Popular</i>	0.307	0.099	32.22 %	8825	33.27 %
<i>Erm. Matarazzo</i>	0.682	0.136	19.99 %	24580	41.71 %

Fonte: Francato, 2002

4.2.5 – FUNÇÃO DE ATIVAÇÃO

A função de ativação utilizada é a tangente hiperbólica do tipo sigmoidal sendo a mesma para todos os neurônios da camada intermediária, e na camada de saída a função é a identidade. Estas funções foram utilizadas em todas as simulações. A função tangente hiperbólica foi escolhida com base na literatura devido a sua comprovada eficiência.

4.2.6 – ALGORITMO DE OTIMIZAÇÃO

O algoritmo de otimização foi o gradiente conjugado escalonado (GCE). Este é um método de segunda ordem, desenvolvido por Moller (1993). Tal algoritmo foi utilizado por VON ZUBEN (1996) em um programa computacional de treinamento em RNA's na linguagem MATLAB, denominado *moller.m*. Este algoritmo foi modificado, com o objetivo de atender às necessidades do estudo de previsão de demanda. Baseado no trabalho de Barp (1999), criaram-se novas rotinas para composição dos modelos.

Como o treinamento da rede é realizado por um algoritmo de segunda ordem (o algoritmo calcula o gradiente e a matriz hessiana), ela deve ser submetida a uma reinicialização a cada treinamento referente a cada iteração.

4.2.7 – INICIALIZAÇÃO DOS PESOS

A inicialização dos pesos é feita por geração aleatória, com distribuição uniforme entre $[-0.1 ; 0.1]$.

4.2.8 – ESTRATIFICAÇÃO DOS DADOS AMOSTRAIS

A amostra de dados de vazões de consumo (demanda) observadas foram estratificadas em um conjunto de dados para o treinamento e outro conjunto para teste, objetivando uma avaliação sistemática do desempenho das redes. A série de vazões e temperaturas seria pequena para proceder uma divisão em três conjuntos, treinamento , validação e teste. Quanto ao particionamento dos dados para distribuição em cada conjunto, decidiu-se que o conjunto de teste representasse 40 % do conjunto de dados para treinamento.

4.2.9 – CRITÉRIO DE PARADA

Como critério de parada para o treinamento, optou-se por aplicar um limite no número de épocas (iterações). O limite estabelecido foi verificado pelo valor mínimo do erro da função objetivo.

4.3 – PROGRAMAÇÃO

Os passos a seguir indicam a metodologia de processamento adotada.

Passo 1 – Normalização (pré-processamento) dos dados de entrada para treinamento e teste da RNA.

Foi desenvolvida uma metodologia de cálculo para treinamento e teste da RNA, na qual procurou-se inicialmente pré-processar os dados de entrada da rede, o programa que realiza a normalização desses dados chama-se “*normateste1.m*” (anexo B).

Passo 2 – Treinamento da RNA.

O treinamento será realizado através do programa “*moller.m*” (anexo C). Considerando cada caso simulado o programa calcula as vazões, o erro quadrático entre vazões observadas e calculadas, bem como o desempenho da rede. As vazões treinadas encontram-se normalizadas e deverão passar por pós-processamento para retornarem aos seus valores reais.

Passo 3 – Verificação do desempenho da RNA.

A verificação do desempenho da rede é realizada através do programa “*testarn1.m*” (anexo D), que utiliza os pesos obtidos após o treinamento da rede neural. Gera os arquivos de saída desnormalizados.

Passo 4 – Teste da RNA

A verificação do desempenho da rede para os dados de teste é realizada pelo programa “*testarn.m*” (anexo D). Gera arquivos de saída desnormalizados.

Passo 5 – Montagem das tabelas e gráficos com os resultados finais para treinamento e teste da RNA.

Passo 6 – Análise estatística dos resultados, calculo do Erro Quadrático Médio (EQM); Erro Absoluto Médio (EAM); Erro Percentual Médio (EPM) e Erro Percentual Máximo (EPmax), e comparação dos modelos. O calculo do erro é executado pelo programa “*calerro.m*”.

A Figura 4.3 mostra a ordem de utilização dos programas.




Figura 4.3 – Fluxograma de Utilização dos Programas

4.4 – MODELOS DE PREVISÃO BASEADOS EM SÉRIES TEMPORAIS

A previsão de séries temporais, atualmente um campo de pesquisa bem claro e definido dentro da estatística, desenvolveu-se rapidamente a partir da década de 70. Sem dúvida alguma foi a partir dos trabalhos de Box & Jenkins (1976) que despertou o interesse dos estatísticos.

Uma série temporal é um conjunto de dados numéricos espaçados no tempo. São dados observados ou medidos na saída de um sistema, sendo dependentes do tempo (hora, dia, mês, ano, etc.), estes dados fornecem informações para a previsão, parte-se da premissa que pode-se prever o futuro a partir de dados passados.

Os componentes de uma série temporal são as tendências, sazonalidades, atividades cíclicas e variações aleatórias. A tendência ocorre quando a série apresenta um padrão de subida

ou descida que persiste no tempo; as atividades cíclicas são variações alternadas de subida e descida da série no tempo; a sazonalidade é um padrão repetitivo do crescimento ou decrescimento de demanda, em períodos bem definidos e as variações aleatórias são flutuações irregulares que não seguem a nenhum padrão determinístico.

Existe uma grande classe de fenômenos (físicos, econômicos, etc..) cujo processo observacional e a conseqüente quantificação numérica, produz uma seqüência de dados distribuídos no tempo. A esta seqüência de dados ordenados segundo o parâmetro tempo, denominamos série temporal.

A forma mais simples de conceituar uma série temporal, denotada por Z_t , onde $t = 1, 2, \dots, n$, é de interpretar Z_t como sendo um conjunto de observações de uma variável aleatória indexada no tempo, denotada por $\{Z_t, t \in \mathcal{R}_+\}$, onde $\mathcal{R}_+$ representa o conjunto de números reais positivos. Em geral, as observações vizinhas são dependentes entre si e o estudo de uma série temporal consiste em analisar e modelar esta dependência.

4.4.1 – ANÁLISE DE SÉRIES TEMPORAIS

O objetivo da análise de série temporal é sumarizar as propriedades estatísticas e caracterizar seu comportamento, identificando ou sugerindo um modelo adequado. Há basicamente dois enfoques usados nesta análise. No primeiro, a análise é feita no domínio do tempo, isto é, o interesse reside na magnitude de eventos que ocorram em determinado instante e na relação entre as observações em diferentes instantes de tempo. A ferramenta utilizada é a função de autocorrelação e a análise é baseada em um modelo paramétrico.

No segundo, a análise é realizada no domínio da frequência, isto é, o interesse está na frequência com que certos eventos ocorrem em determinado período de tempo. A ferramenta utilizada é o espectro e a análise é baseada em modelos não-paramétricos (PEREIRA et al., citado por BALLINI, 2000).

As duas formas de análise não são alternativas, mas complementares, mostrando cada uma diferentes aspectos da natureza da série temporal. Entretanto, pode-se dizer que a análise no

domínio da frequência é conveniente na procura de características determinísticas da série temporal, enquanto a do domínio do tempo é usada na análise de processos não determinísticos.

As séries temporais se desenvolvem no tempo, sujeitas às variações que podem ser descritas por leis probabilísticas. Esse tipo de sistema é objeto da teoria dos processos estocásticos, ou seja, o mecanismo gerador é uma série temporal, considerado como um processo estocástico.

A análise clássica de séries temporais trata, basicamente, da decomposição da série em quatro componentes: tendência, sazonal, cíclica e aleatória. As séries de vazões apresentam um comportamento periódico, ou seja, são séries sazonais como ilustra a Figura 4.4.

De forma geral, uma série temporal, com não estacionariedade sazonal pode ser representada por dois componentes, um sazonal s_t e outro estacionário $\tilde{z}_t$, ou seja, a vazão x_t pode ser escrita como:

$$x_t = s_t + \tilde{z}_t + a_t \quad (4.6)$$

onde a_t é um componente aleatório, com média zero e variância constante σ^2 , chamado de ruído branco. O componente aleatório é denominado estacionário quando a lei probabilística que gera este componente não se altera com um deslocamento no tempo.




Figura 4.4 – Séries de Vazões Médias Diárias para o Reservatório de Penha

Para tornar a série estacionária, é necessário remover o componente sazonal. Para isso, realiza-se a seguinte transformação nos dados:

$$z_t = \frac{x_t - \mu_m}{\sigma_m} \quad (4.7)$$

onde, μ_m e σ_m são a média e o desvio padrão de cada hora, respectivamente. A série z_t tem aproximadamente, média zero e desvio padrão unitário.

4.4.2 – CONCEITO DE PROCESSOS ESTOCÁSTICOS

Definição – Seja Z_+ um conjunto arbitrário. Um processo estocástico é uma família $\{x_t, t \in Z_+\}$ tal que, para cada $t \in Z_+$, x_t é uma variável aleatória.

Nestas condições, um processo estocástico é uma família de variáveis aleatórias, que suporemos definidas num mesmo espaço de probabilidades. O conjunto Z_+ é normalmente tomado como o conjunto dos inteiros ou o conjunto dos reais (MORETTIN, 1995).

4.4.2.1 – MÉDIA E VARIÂNCIA DE UM PROCESSO ESTACIONÁRIO

A hipótese de estacionaridade implica que a distribuição de probabilidade $p(z_t)$ é a mesma para todo tempo t , podendo ser escrita como $p(z)$. Assim, o processo estocástico tem média constante:

$$\mu = E[z_t] = \int_{-\infty}^{+\infty} zp(x)dz \quad (4.8)$$

que define o nível em torno do qual a série oscila, e uma variância constante:

$$\sigma_z^2 = E[z_t - \mu]^2 = \int_{-\infty}^{+\infty} (z - \mu)^2 p(z)dz \quad (4.9)$$

que mede a amplitude desta oscilação. Como a distribuição de probabilidade $p(z_t)$ é a mesma para todo tempo t , sua forma pode ser inferida através do histograma das observações $z_1, z_2, \dots, z_N$, $t = 1, \dots, N$, sobre a série temporal observada. Assim, a média μ do processo estocástico pode ser estimada por:

$$\bar{z} = \frac{1}{N} \sum_{t=1}^N z_t \quad (4.10)$$

sendo denominada média, e a estimativa da variância σ_z^2 , dada por:

$$Var[z] = \frac{1}{N} \sum_{t=1}^N (z_t - \bar{z})^2 \quad (4.11)$$

é denominada variância amostral.

4.4.2.2 – COEFICIENTES DE AUTOCOVARIÂNCIA E AUTOCORRELAÇÃO

A hipótese de estacionariedade também implica que a função de distribuição conjunta $p(z_t, z_{t+k})$ é a mesma para todo tempo $t, t+k$, a qual é separada por um intervalo k . Assim, segue que a distribuição conjunta pode ser inferida plotando um diagrama de dispersão usando os valores de (z_t, z_{t+k}) , das séries temporais, separadas por um intervalo constante k .

A covariância entre z_t e o valor z_{t+k} , separada por k intervalos de tempo, é chamada de autocovariância de passo k sendo definida como:

$$\gamma_k = cov[z_t, z_{t+k}] = E[(z_t - \mu)(z_{t+k} - \mu)] \quad (4.12)$$

onde μ é a média da série dada pela Equação (4.8).

Similarmente, o coeficiente de autocorrelação ρ_k com passo k é definido como:

$$\rho_k = \frac{E[(z_t - \mu)(z_{t+k} - \mu)]}{\sqrt{E[(z_t - \mu)^2 (z_{t+k} - \mu)^2]}} = \frac{\gamma_k}{\sigma_z^2} \quad (4.13)$$

onde a variância $\sigma_z^2 = \gamma_0$ é a mesma tanto no tempo $t+k$ como no tempo t , o que implica que $\rho_0 = 1$.

A matriz de covariância associada a um processo estacionário, para as observações $(z_1, z_2, \dots, z_N)$ realizadas em N vezes sucessivas, é representada por:

$$\Gamma_N = \begin{bmatrix} \gamma_0 & \gamma_1 & \gamma_2 & \cdots & \gamma_{N-1} \\ \gamma_1 & \gamma_0 & \gamma_1 & \cdots & \gamma_{N-2} \\ \gamma_2 & \gamma_1 & \gamma_0 & \cdots & \gamma_{N-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \gamma_{N-1} & \gamma_{N-2} & \gamma_{N-3} & \cdots & \gamma_0 \end{bmatrix}$$

$$= \sigma_z^2 \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{N-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{N-2} \\ \rho_2 & \rho_1 & 1 & \cdots & \rho_{N-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{N-1} & \rho_{N-2} & \rho_{N-3} & \cdots & 1 \end{bmatrix} = \sigma_z^2 P_N \quad (4.14)$$

Desta forma, a matriz Γ_N é simétrica com elementos constantes nas diagonais sendo chamada de matriz de autocovariância e a correspondente matriz P_N é chamada de matriz de correlação. Ambas as matrizes são definidas positivas para o processo estacionário (BOX & JENKINS, 1976).

A condição da matriz de autocorrelação ser definida positiva implica que o determinante é maior que zero. Em particular, para $N=2$ tem-se:

$$\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix} = 1 - \rho_1^2 > 0 \quad (4.15)$$

e, assim, $-1 < \rho_1 < 1$.

Similarmente, para $N=3$ deve-se ter

$$\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix} > 0 ; \begin{vmatrix} 1 & \rho_2 \\ \rho_2 & 1 \end{vmatrix} > 0 ; \begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix} > 0$$

as quais implicam que

$$-1 < \rho_1 < 1 ; -1 < \rho_2 < 1 ; -1 < \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} < 1$$

e assim por diante. Como P_N deve ser definida positiva para todo N , os coeficientes de autocorrelação de um processo estacionário devem satisfazer um grande número de condições.

4.4.3 –FUNÇÃO DE AUTOCOVARIÂNCIA E AUTOCORRELAÇÃO

O coeficiente de covariância γ_k de passo k , mede a covariância entre dois valores z_t e z_{t+k} . O gráfico de γ_k versus k é chamado de função de autocovariância (γ_k) do processo estocástico. Similarmente, o gráfico do coeficiente de autocorrelação ρ_k como função do intervalo k é chamado de função de autocorrelação (ρ_k) do processo. Note que a função de autocorrelação é não-dimensionável, isto é, independe da escala de medida da série temporal.

Sendo a covariância $cov[z_t, z_{t+k}] = cov[z_{t-k}, z_t]$ então $\gamma_k = \gamma_{-k}$ e, portanto, $\rho_k = \rho_{-k}$, ou seja, a função de autocovariância (γ_k) ou, equivalentemente, por sua média μ e sua função de autocorrelação (ρ_k).

4.4.3.1 – ESTIMATIVA DAS FUNÇÕES DE AUTOCOVARIÂNCIA E AUTOCORRELAÇÃO

Seja uma série temporal estacionária $z_1, z_2, \dots, z_N$ de N observações. A estimativa dos coeficientes de autocorrelação ρ_k é obtida através do método dos momentos (BOX & JENKINS, 1976) da seguinte forma:

$$r_k = \frac{c_k}{c_0} \quad (4.16)$$

onde,

$$c_k = \frac{1}{N-k} \sum_{t=1}^{N-k} (z_t - \bar{z})(z_{t+k} - \bar{z}), \quad k = 0, 1, \dots, K \quad (4.17)$$

é a estimativa do coeficiente de autocovariância γ_k e $\bar{z}$ é a média amostral dada pela Equação (4.10) da série temporal.

Nota-se que r_k é calculado para cada $k = 0, 1, 2, \dots, K$ e o número de observações usadas para estimar c_k depende do valor de k . É recomendado que o valor de K seja menor que $N/4$ quando $N \cong 100$ (BOX & JENKINS, 1976).

4.5 – MODELO AUTO-REGRESSIVO

Considerando uma série temporal estacionária z_t , $t \in \mathbb{Z}_+$, um processo autoregressivo de ordem p , denotado por $AR(p)$, é definido como sendo um modelo onde o valor corrente do processo z_t é expresso como uma combinação linear de p valores passados $z_{t-1}, z_{t-2}, \dots, z_{t-p}$ e de um ruído branco a_t é uma sequência de variáveis aleatórias com distribuição normal de média zero e variância σ_a^2 , ou seja, $N(0, \sigma_a^2)$.

O modelo $AR(p)$ pode ser escrito como:

$$z_t = a_t + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} \quad (4.18)$$

Os parâmetros $\phi_1, \phi_2, \dots, \phi_p$ devem ser ajustados, satisfazendo certas condições para o processo ser estacionário. Considerando o caso mais simples em que a ordem do modelo é $p = 1$, isto é, um modelo $AR(1)$, a Equação (4.18) pode ser escrita como:

$$z_t = a_t + \phi_1 z_{t-1} \quad (4.19)$$

onde o parâmetro ϕ_1 deve satisfazer a condição $|\phi_1| < 1$ para garantir a estacionariedade. Para o processo auto-regressivo de ordem 2, $AR(2)$, devemos calcular ϕ_1 e ϕ_2 , e assim sucessivamente de acordo com a ordem do modelo.

4.5.1 – FUNÇÃO DE AUTOCORRELAÇÃO DE MODELOS AUTO-REGRESSIVOS

Uma importante relação de recorrência para a função de autocorrelação de um processo auto-regressivo estacionário representado pela Equação (4.18), é encontrada multiplicando-se ambos os membros de (4.18) por z_{t-k} , ou seja,

$$z_{t-k} z_t = \phi_1 z_{t-k} z_{t-1} + \phi_2 z_{t-k} z_{t-2} + \dots + \phi_p z_{t-k} z_{t-p} + a_t z_{t-k} \quad (4.20)$$

Tomando os valores esperados em (4.20), e como z_{t-k} somente ruídos até a_{t-k} , não correlacionados com a_t , tem-se que $E[a_t z_{t-k}] = 0$, $k > 0$, do que resulta:

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p} \quad (4.21)$$

onde $\gamma_k = \text{Cov}(z_{t-k}, z_t)$ é o coeficiente de covariância.

Dividindo a Equação (4.21) por γ_0 , nota-se que o coeficiente de autocorrelação satisfaz a mesma forma da Equação (4.19), isto é,

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}, \quad k > 0 \quad (4.22)$$

Considerando $k = 0$, o valor esperado $E[a_t z_{t-k}]$, em (4.20), é $E[a_t^2] = \sigma_a^2$ e, assim, a covariância do processo AR(p) é dada por:

$$\gamma_0 = \phi_1 \gamma_{-1} + \phi_2 \gamma_{-2} + \dots + \phi_p \gamma_{-p} + \sigma_a^2 \quad (4.23)$$

Dividindo a Equação (4.23) por $\gamma_0 = \sigma_z^2$ e substituindo $\gamma_k = \gamma_k$, a variância σ_z^2 pode ser escrita como:

$$\sigma_z^2 = \frac{\sigma_a^2}{1 - \rho_1\phi_1 - \rho_2\phi_2 - \dots - \rho_p\phi_p} \quad (4.24)$$

Usando as estimativas de covariância c_k e substituindo ρ_k pelas estimativas r_k , obtém-se uma estimativa para a variância do resíduo a_t :

$$\hat{\sigma}_a^2 = c_0 (1 - r_1\phi_1 - r_2\phi_2 - \dots - r_p\phi_p) \quad (4.25)$$

onde c_0 é a estimativa da variância do processo σ_z^2 .

4.5.2 – FUNÇÃO DE AUTOCORRELAÇÃO PARCIAL DE MODELOS AUTO-REGRESSIVOS

Uma outra ferramenta utilizada na identificação da ordem dos modelos de série temporal é a função de autocorrelação parcial. Essa função, denotada por ϕ_{kk} para vários passos k é definida como segue:

Definição: O coeficiente de autocorrelação parcial de ordem k , denotado por ϕ_{kk} , é definido como sendo o último coeficiente de um modelo AR(k), ajustado à série temporal z_t , $t = 1, 2, \dots, N$.

Supondo que para uma série z_t , $t = 1, 2, \dots, N$, um modelo AR(1), isto é, de ordem $k = 1$, foi ajustado:

$$z_t = \phi_1 z_{t-1} + a_t \quad (4.26)$$

Tem-se que o coeficiente de autocorrelação parcial deste modelo é $\phi_{11} = \phi_1$. Agora, supondo que, para a série z_t se ajuste uma modelo AR(2):

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t \quad (4.27)$$

Então, o coeficiente de autocorrelação parcial para este modelo é $\phi_{22} = \phi_2$. Procedendo desta maneira, para o modelo geral AR(k), de ordem k :

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_k z_{t-k} + a_t \quad (4.28)$$

o coeficiente de autocorrelação parcial é dado por $\phi_{kk} = \phi_k$.

Para um processo auto-regressivo de ordem p , o coeficiente de autocorrelação parcial ϕ_{kk} será diferente de zero para k menor ou igual a p e será igual a zero para k maior que p . Essa propriedade, juntamente com o comportamento da função de autocorrelação, são duas ferramentas úteis para identificar a ordem dos modelos auto-regressivos.

Denotando por ϕ_{kj} o coeficiente de um modelo AR(k), tal que, ϕ_{kk} é o último coeficiente do modelo, da Equação (4.22) o coeficiente de autocorrelação parcial ϕ_{kj} satisfaz a equação:

$$\rho_j = \phi_{k1} \rho_{j-1} + \phi_{k2} \rho_{j-2} + \dots + \phi_{k(k-1)} \rho_{j-k+1} + \phi_{kk} \rho_{j-k}, \quad j = 1, 2, \dots, k \quad (4.29)$$

a partir das quais obtêm-se as equações de Yule-Walker:

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{p-1} & \rho_{p-2} & \rho_{p-3} & \dots & 1 \end{bmatrix} \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kp} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_p \end{bmatrix}$$

Resolvendo estas equações sucessivamente para $k = 1, 2, \dots$, obtém-se:

$$\phi_{11} = \rho_1; \quad \phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}; \quad \phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

Em geral, para ϕ_{kk} , determinante no numerador tem os mesmos elementos que no denominador, mas com a última coluna formada pelo vetor ρ_k . O coeficiente ϕ_{kk} considerado como função do intervalo k é chamado de função de autocorrelação parcial (BOX & JENKINS, 1976).

A função de autocorrelação parcial pode ser estimada através de sucessivos ajustes dos modelos auto-regressivos de ordens 1,2,..., usando o método dos momentos. Uma outra forma é usar uma aproximação da equação de Yule-Walker, substituindo as funções de autocorrelação ρ_j por suas estimativas r_j :

$$r_j = \hat{\phi}_{k1}r_{j-1} + \hat{\phi}_{k2}r_{j-2} + \dots + \hat{\phi}_{k(k-1)}r_{j-k+1} + \hat{\phi}_{kk}r_{j-k}, \quad j = 1, 2, \dots, k \quad (4.30)$$

e resolvendo as equações resultantes para $k = 1, 2, \dots$, recursivamente, como proposto por DURBIN, citado por BALLINI (2000), obtendo-se, assim, uma estimativa para os coeficientes de autocorrelação parcial.

4.5.3 – ERRO PADRÃO DAS ESTIMATIVAS DE AUTOCORRELAÇÃO PARCIAL

QUENOUILLE (1949) mostrou que, para as hipóteses do processo auto-regressivo de ordem p , as estimativas dos coeficientes de autocorrelação parcial de ordem $p+1$ e superiores são, aproximadamente, independentemente distribuídas. Se N é o número de observações usadas no ajuste do modelo, tem-se que:

$$Var[\hat{\phi}_{kk}] \cong \frac{1}{N}, \quad k \geq p+1 \quad (4.31)$$

Assim, o desvio padrão (DP) da estimativa $\hat{\phi}_{kk}$ é

$$DP[\hat{\phi}_{kk}] = \hat{\sigma} \cong \frac{1}{\sqrt{N}}, \quad k \geq p+1 \quad (4.32)$$

Supondo que o número de observações N é suficientemente grande, pode-se dizer que ϕ_{kk} tem distribuição aproximadamente normal, o que permite a construção de um intervalo de confiança para ϕ_{kk} usando o desvio padrão $DP[\hat{\phi}_{kk}]$, considerando que a estimativa é diferente de zero quando $|\hat{\phi}_{kk}| > 2 / \sqrt{N}$, ou seja, $|\hat{\phi}_{kk}| > 2DP[\hat{\phi}_{kk}]$.

4.6 – MODELO MÉDIAS MÓVEIS

O método das médias móveis tira a média dos dados de alguns períodos recentes, que se torna à previsão para o período seguinte, é de especial importância o número de períodos de dados a serem incluídos na média, chamado de período de recorrência (**Pr**). A escolha do **Pr** é feita com base na análise do erro absoluto médio. Calcula-se a previsão para valores de **Pr** diferentes, e com estas previsões calcula-se o erro absoluto médio. O **Pr** mais acurado tende a variar conforme as características únicas de cada conjunto de dados; por tanto, o **Pr** deve ser determinado por experimentação, a sua escolha dependerá dos critérios de precisão, resposta ao impulso e capacidade de atenuação do ruído, o que for mais desejável. Um erro absoluto médio pequeno determina uma elevada resposta ao impulso e uma menor capacidade de atenuação do ruído. Na análise final o **Pr** escolhido dependerá de um completo conhecimento do uso pretendido da previsões e da natureza da situação de previsão.

Mediante o emprego de médias móveis das ordens apropriadas, podem ser eliminadas as variações cíclicas, estacionais e irregulares, conservando-se dessa forma, apenas o movimento de tendência (SPIEGEL, 1974).

Uma desvantagem do método, é que as médias móveis podem gerar movimentos cíclicos, ou de outra natureza, que não existem nos dados originais. Uma segunda desvantagem é que as médias móveis são fortemente afetadas pelos valores extremos. Para superar de certo modo essas desvantagens, usam-se, às vezes, uma média ponderada, com pesos apropriados.

4.7 – ANÁLISE DOS ERROS

Embora na função objetivo do modelo de RNA tenha sido adotada a função de minimização do erro quadrático médio, o desempenho dos modelos de previsão será avaliado através de um conjunto maior de indicadores estatísticos. Assim, além do erro quadrático médio (**EQM**), serão calculados e analisados o erro absoluto médio (**EAM**), o erro relativo percentual médio (**EPM**) e o erro relativo percentual máximo (**EPmax**), definidos como se segue:

$$EQM = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (4.33)$$

$$EAM = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (4.34)$$

$$EPM = \frac{100}{n} \sum_{j=1}^n \frac{|y_j - \hat{y}_j|}{y_j} \quad (4.35)$$

$$EPmax = \max 100 \frac{|y_j - \hat{y}_j|}{y_j} \quad (4.36)$$

onde $n = 1, \dots, N$, N é o número de padrões analisados, y_j é o valor real e $\hat{y}_j$ é o valor previsto.

4.8 – IMPACTO DA QUALIDADE DA PREVISÃO NAS POLÍTICAS OPERACIONAIS

Nesta etapa, o resultado da previsão horária obtido com o modelo de RNA e com o modelo Médias Móveis, para o reservatório de Penha, serviu como entrada para um modelo de otimização do trecho de uma rede de abastecimento de água, visando ilustrar a importância da qualidade da previsão de demanda no planejamento da operação da rede. Tal modelo usa o software GAMS (*General Algebraic Modeling System*), com solver CONOPT, que utiliza o algoritmo do Gradiente Reduzido Generalizado, um software de otimização. Será tomada uma rede hipotética, estudada por ALMEIDA (2001) e obtido a política ótima de operação para a previsão de demanda por Médias Móveis, RNA's e para a curva real de demanda. Os resultados da aplicação do modelo de otimização são utilizados no software EPANET, para simular a política de operação.

4.9 – ESTRUTURA DE APLICAÇÃO DOS MODELOS

Foram aplicados o modelo de redes neurais (RNA), o modelo de média móveis (MM) e o modelo auto-regressivo (AR). O modelo RNA sofreu algumas variações, as quais incidiram sobre a estratificação dos dados de entrada, as variáveis de entrada e o tipo de previsão realizada (previsão da demanda horária e previsão da demanda média diária). A Tabela 4.2 mostra como foi feita a estratificação dos dados, quais foram as variáveis de entrada e que tipo de previsão foi realizada.

Tabela 4.2 – Variações do Modelo de RNA, Modelo de Médias Moveis (MM) e Auto-Regressivo

Variante/Modelo de Previsão	Variáveis de Entrada	Variáveis de Saída	Obs.
RNA 1.1 (Primeiro Caso)	- Consumo médio do dia anterior ao que se quer prever - Consumos horários do respectivo dia da semana anterior	Previsão da demanda para as 24 horas do dia	Divisão dos dados em período seco e chuvoso. <i>Aplicado ao reservatório de Penha</i>
RNA 1.2 Previsão Univariada (Segundo Caso)	- Consumo médio do dia anterior ao que se quer prever - Consumos horários do respectivo dia da semana anterior	Previsão da demanda para as 24 horas do dia	Divisão dos dados em quatro estações. (verão, outono, inverno e primavera) <i>Aplicado aos 7 reservatórios do sistema.</i>
RNA 2.1.1 (Terceiro Caso)	- Temperatura média e Consumo médio do dia anterior ao que se quer prever.	Previsão da demanda média diária	Divisão dos dados em quatro estações com inclusão da temperatura. <i>Aplicado ao reservatório de Penha.</i>
RNA 2.1.2 (Terceiro Caso)	- A previsão da temperatura média do dia que se quer prever e a Consumo médio do dia anterior ao que se quer prever	Previsão da demanda média diária	Divisão dos dados em quatro estações com inclusão da temperatura. <i>Aplicado ao reservatório de Penha.</i>
RNA 2.1.3 (Terceiro Caso)	- Temperatura média e a Consumo médio do dia anterior ao que se quer prever. - Consumo médio do respectivo dia da semana anterior.	Previsão da demanda média diária	Divisão dos dados em quatro estações com inclusão da temperatura. <i>Aplicado ao reservatório de Penha.</i>
RNA 2.2.1 (Quarto Caso)	- Consumo médio do dia anterior ao que se quer prever e a Consumo médio do respectivo dia da semana anterior.	Previsão da demanda média diária	Divisão dos dados em quatro estações, sem inclusão da temperatura <i>Aplicado ao reservatório de Penha.</i>
MM	- Consumos horários	Previsão da demanda para as 24 horas do dia	Divisão dos dados em quatro estações <i>Aplicado aos 7 reservatórios do sistema</i>
AR	- Consumos horários	Previsão da demanda para as 24 horas do dia	Divisão dos dados em quatro estações <i>Aplicado aos 7 reservatórios do sistema</i>
Previsão Multivariada (RNA) (Quinto Caso)	- Consumo médio do dia anterior ao que se quer prever - Consumos horários do respectivo dia da semana anterior	Previsão da demanda para as 24 horas do dia	Divisão dos dados em quatro estações <i>Aplicado a combinações dos reservatórios (2 a 2 e todos reservatórios)</i>

5 – ESTUDO DE CASO

5.1 – ÁREA DE ESTUDO

O subsistema utilizado no estudo está localizado na região metropolitana de São Paulo e é denominado Alça Leste. É composto por 8 reservatórios, com características descritas na Tabela 5.1. A Figura 5.1 mostra a topologia da Alça Leste. Na Tabela 5.2 são informadas as cotas dos nós.

Tabela 5.1 – Características dos Reservatórios da Alça Leste do Sistema Adutor de São Paulo

Reservatórios	Cotas (m)	Nível mín.(m)	Nível inicial (m)	Nível máx.(m)	Diâm.res. (m)
Guaraú	825,97	1,00	2,78	5,00	50
Jaçanã	815,77	0,80	3,53	5,72	45
Edu Chaves	782,91	0,20	4,12	5,72	73
Gopoúva	783,40	0,12	1,88	7,80	90
Penha	783,12	1,00	4,15	5,50	67
Cangaíba	794,14	1,00	3,70	5,30	33
Jardim Popular	795,13	0,50	3,28	4,50	53
Erm. Matarazzo	788,79	0,60	4,01	5,37	81

Tabela 5.2 – Nós e Cotas da Alça Leste

Nós	Cota (m)
1	777,50
2	779,47
3	809,20
5	756,10
6	743,35
7	765,18
8	752,00
9	781,90
10	750,01
11	771,45
12	780,79

Os nós estão numerados conforme a Figura 5.1. Da mesma forma, os trechos, reservatórios, bombas e válvulas.




Figura 5.1 – Topologia da Alça Leste

A seguir a Tabela 5.3 apresenta as características dos trechos da Alça Leste, que são, o comprimento, o diâmetro e o coeficiente de rugosidade de Hazen Willians.

Tabela 5.3 – Trechos da Alça Leste

Trecho	Comprimento (m)	Diâmetro (mm)	Coef. – Rugosidade (Hazen- Willians)
P-42	1	3.200	130,0
P-43	1	150	130,0
T1	660	3.530	137,0
T2	2.840	2.100	137,0
T3	2.105	2.100	137,0
T4	20	900	133,0
T5	1	900	130,0
T6	1	900	130,0
T7	2.625	1.800	137,0
T8	810	500	132,5
T9	1	500	130,0
T10	1	500	130,0
T11	1.050	1.800	129,0
T12	5.700	1.050	131,5
T13	1	1.050	130,0
T14	1	1.050	130,0
T15	860	1.500	129,0
T16	6.830	1.500	129,0
T17	530	1.200	100,0
T18	180	1.050	100,0
T19	1	1.050	130,0
T20	1	1.050	130,0
T21	1.300	1.500	135,0
T22	1.050	1.500	135,0
T23	2.350	150	135,0
T24	820	500	118,0
T25	1	500	130,0
T26	1	500	130,0
T27	2.200	900	124,0
T28	690	600	95,0
T29	1	600	130,0
T30	1	600	130,0
T31	3.180	900	127,0
T32	160	600	127,0
T33	1	600	130,0
T34	1	600	130,0

Os trechos **P42** e **P43** são trechos esquemáticos que representam as saídas de consumos.

Os perfis de consumo de água na rede conectados a cada reservatório são apresentados na Figura 5.2 e a seguir a Figura 5.3 mostra os perfis de consumo adimensionalizados, ou seja, a média da vazão de consumo em cada hora dividida pela vazão média diária de consumo.

PERFIL DE CONSUMO DOS RESERVATÓRIOS




Figura 5.2 – Perfis de Consumo Associados aos 7 Reservatórios em Estudo

PERFIS DE CONSUMO




Figura 5.3 –Perfis dos Reservatórios Adimensionalizados

5.2 – APLICAÇÃO DOS MODELOS DE RNA'S MULTICAMADAS, MÉDIAS MÓVEIS E AUTO-REGRESSIVO PARA A PREVISÃO DE DEMANDA

Nesta seção são mostrados todos os modelos desenvolvidos, utilizando RNA's multicamadas, Médias Móveis e Auto-Regressivo, aplicados na área de estudo. Foram feitas as execuções de vários modelos, as quais diferem entre si pelos dados de entrada, pela saída produzida e também pelo período de dados analisados.

Primeiramente dividiu-se a série de dados em meses secos e chuvosos, gerando dois modelos, um para cada período, tendo como entrada valores de consumos e produzindo na saída a previsão da demanda horária, aplicados ao reservatório Penha.

Em uma segunda etapa dividiu-se a série em quatro segmentos, referentes às quatro estações do ano, gerando assim quatro modelos, um para cada estação. As entradas foram valores de consumo, produzindo na saída a previsão horária, o que foi feito para sete reservatórios.

Na terceira etapa também optou-se em dividir a série em quatro (quatro estações), porém os dados de entrada foram: valores de temperaturas e consumos. Houve variações nos dados de entrada, gerando três modelos, os quais possuem entradas distintas. Estes modelos foram executados para as quatro estações do ano, totalizando assim doze modelos diferentes, aplicados ao reservatório Penha. Estes produziram na saída a previsão da demanda média diária.

No quarto caso, a série de dados foi dividida em quatro estações, porém os dados de entrada foram os valores de consumo médio. Este modelo foi aplicado para o reservatório Penha e produziu a previsão da demanda média diária. Logo a seguir, os modelos de médias móveis e auto regressivo (com estratificação sazonal dos dados em quatro estações) foram aplicados aos sete reservatórios da rede.

No quinto caso a série de dados foi dividida em quatro estações, os dados de entrada foram os valores de consumo médio e consumo horário, o modelo foi aplicado para os

reservatórios dois a dois e para os sete reservatórios, caracterizando a previsão multivariada. A saída produzida foi à previsão horária da demanda.

5.3 – PRIMEIRO CASO : ESTRATIFICAÇÃO SAZONAL DOS DADOS EM DUAS ESTAÇÕES (RNA 1.1)

No primeiro caso optou-se por dividir a série em meses secos e chuvosos, uma vez que a região metropolitana de São Paulo apresenta períodos bem distintos de estação seca e chuvosa. Foram considerados meses secos, os meses compreendidos entre Junho a Novembro (08/06/98 a 31/11/98) e meses chuvosos, de Dezembro a Maio (01/12/98 a 31/05/99).

Os coeficientes de correlação entre algumas variáveis relevantes foram estudados para ambos períodos. Com base nos dados coletados foi possível estabelecer seis correlações para cada período, as quais constam na Tabela 5.4.


Observando a Tabela 5.4, verificamos que as melhores correlações se apresentam quando se relaciona consumo médio do dia da semana analisado com o consumo médio deste mesmo dia da semana anterior, e consumo médio do dia, com o consumo médio do dia anterior. Isto acontece tanto para os meses chuvosos quanto para os secos. As Figuras 5.4 e 5.5 ilustram tais correlações, podemos observar um pico na Figura 5.4, o qual caracteriza uma demanda média superior ao normal, analisando os dados observa-se um frente quente que aumentou a demanda neste período.

Esperava-se uma correlação forte entre consumo e temperatura, mas isso não se verificou, pois há outras variáveis independentes que afetam a variável dependente, que é o consumo de água (dia da semana, eventos, época do ano, etc.). Por esse motivo optou-se neste primeiro caso não trabalhar com a temperatura, e sim usar apenas os consumos.

Tabela 5.4 – Coeficientes de Correlação para Meses Chuvosos e Secos

	<i>Temp. Max. e Con. Médio (do dia)</i>	<i>Temp. Méd. e Con. Médio (do dia)</i>	<i>Com. Médio (do dia) e Com. Médio da Semana Anterior</i>	<i>Temp. Máx. (do dia anterior) e Com. Médio (do dia)</i>	<i>Temp. Média (do dia anterior) e Com. Médio (do dia)</i>	<i>Com. Médio. (do dia) e Con. Méd. (do dia anterior)</i>
01/12/98 à 31/05/99 Meses Chuvosos	-0,29067	-0,3869	0,562385	-0,29236	-0,40733	0,715999
08/06/98 à 31/11/98 Meses Secos	0,264018	0,274045	0,572824	0,157733	0,189214	0,42661

**Consumo Méd. e Consumo Méd. da Semana Anterior
(Meses Chuvosos)**



**Consumo Médio e Consumo Médio do Dia Anterior
(Meses Chuvosos)**





Figura 5.4 – Correlações Para os Meses Chuvosos

**Consumo Médio e Consumo Médio da Semana Anterior
(Meses Secos)**



**Consumo Médio e Consumo Médio do Dia Anterior
(Meses Secos)**




Figura 5.5 – Correlações Para os Meses Secos

Podemos observar um pico na Figura 5.4, analisando os dados de temperatura e consumo verificamos que houve a entrada de uma frente quente, porém não havendo dados de precipitação não podemos afirmar que somente a temperatura tenha influenciado o consumo. Pode ter havido uma inundação, assim aumentando o consumo de água, devido a necessidade de limpezas posteriores a ela.

Em outra análise foram escolhidos dois meses, um no período chuvoso e outro no seco, e analisadas as demandas das 24 horas do dia. Os meses escolhidos foram janeiro e julho, e a análise foi realizada para os sábados contidos em cada mês. As Tabelas 5.5 e 5.6 apresentam as demandas referentes aos meses de janeiro e julho respectivamente, todos referentes ao consumo de água a partir do abastecimento do reservatório Penha.

Tabela 5.5 – Consumos Para os Sábados do Mês de Janeiro no Reservatório Penha

	01/01/99	08/01/99	15/01/99	22/01/99	29/01/99
Horas	Vazão (l/s)	Vazão (l/s)	Vazão (l/s)	Vazão (l/s)	Vazão (l/s)
1	385,00	527,00	796,00	593,00	530,00
2	381,00	458,00	625,00	478,00	509,00
3	381,00	358,00	599,00	468,00	398,00
4	381,00	363,00	585,00	409,00	381,00
5	341,00	351,00	625,00	404,00	355,00
6	344,00	343,00	755,00	376,00	381,00
7	330,00	445,00	834,00	387,00	426,00
8	423,00	525,00	938,00	601,00	669,00
9	437,00	656,00	1120,00	796,00	781,00
10	474,00	708,00	1134,00	880,00	892,00
11	556,00	887,00	884,00	929,00	942,00
12	461,00	818,00	1264,00	927,00	916,00
13	550,00	844,00	845,00	924,00	886,00
14	472,00	751,00	796,00	903,00	892,00
15	524,00	922,00	804,00	883,00	848,00
16	472,00	788,00	770,00	841,00	854,00
17	467,00	786,00	781,00	803,00	797,00
18	375,00	719,00	715,00	724,00	795,00
19	385,00	630,00	822,00	698,00	666,00
20	459,00	613,00	793,00	606,00	674,00
21	414,00	668,00	796,00	602,00	675,00
22	414,00	544,00	729,00	592,00	664,00
23	492,00	595,00	729,00	578,00	641,00
24	477,00	459,00	755,00	568,00	571,00

Tabela 5.6 – Consumos Para os Sábados do Mês de Julho no Reservatório Penha

	04/07/98	11/07/98	18/07/98	25/07/98
<i>Horas</i>	<i>Vazão (l/s)</i>	<i>Vazão (l/s)</i>	<i>Vazão (l/s)</i>	<i>Vazão (l/s)</i>
1	467,00	512,00	493,00	510,00
2	465,00	428,00	517,00	504,00
3	430,00	505,00	440,00	424,00
4	410,00	424,00	461,00	421,00
5	391,00	340,00	415,00	450,00
6	359,00	417,00	440,00	439,00
7	359,00	372,00	462,00	466,00
8	512,00	474,00	473,00	504,00
9	589,00	587,00	562,00	643,00
10	726,00	624,00	717,00	706,00
11	759,00	683,00	791,00	791,00
12	802,00	758,00	796,00	770,00
13	751,00	730,00	791,00	813,00
14	718,00	701,00	739,00	754,00
15	740,00	694,00	735,00	746,00
16	666,00	640,00	637,00	684,00
17	666,00	625,00	615,00	622,00
18	614,00	539,00	637,00	601,00
19	610,00	559,00	604,00	664,00
20	610,00	558,00	632,00	598,00
21	580,00	533,00	579,00	597,00
22	474,00	533,00	550,00	592,00
23	502,00	533,00	544,00	539,00
24	477,00	457,00	489,00	535,00

Calculando os coeficiente de correlação entre valores de consumo dos sábados consecutivos verificamos que a média dos coeficientes de correlação para o mês de julho (Tabela 5.7), aproxima-se da unidade, porém diminuindo no mês de janeiro (Tabela 5.9).

Tabela 5.7 – Correlações Entre os Consumos dos Sábados do Mês de Julho (Reservatório Penha)

<i>Correlação Entre os Consumos dos Dias</i>	<i>04/07/98 e 11/07/98</i>	<i>11/07/98 e 18/07/98</i>	<i>18/07/98 e 25/07/98</i>
<i>Coef. De Correlação</i>	0,948562	0,931958	0,967122

Tabela 5.8 – Correlações Entre os Consumos nos Sábados do Mês de Janeiro (Reservatório Penha)

Correlação Entre os Consumos dos Dias	01/01/99 e 08/01/99	08/01/99 e 15/01/99	15/01/99 e 22/01/99	22/01/99 e 29/01/99
Coef. De Correlação	0,787755	0,504491	0,610255	0,972179

As Figuras 5.6 e 5.7 mostram o desenvolvimento das vazões ao longo dos dias de sábado para os meses de julho e janeiro respectivamente. Podemos observar que para o mês de julho os consumos dos sábados tem um comportamento mais uniforme do que os consumos do mês de janeiro, o que se reflete nos coeficientes de correlação destes meses.




Figura 5.6 – Consumos Horários para 4 Sábados do Mês de Julho (Reservatório Penha)




Figura 5.7 – Consumos Horários para 5 Sábados do Mês de Janeiro (Reservatório Penha)

Com base nestas análises foram produzidos arquivos de entrada para cada período, visando à modelagem e previsão via RNA. Cada arquivo contém 25 colunas que se referem aos 25 neurônios da camada de entrada. Assim foram usadas 25 informações, que são os consumos horários do respectivo dia da semana anterior ao dia que se quer prever e o consumo médio do dia anterior ao que se quer prever. Por exemplo, para prever uma segunda-feira, utiliza-se como entrada às 24 horas do consumo da segunda-feira anterior e o consumo médio do domingo. Fazendo isso utilizamos duas informações. Uma que traz informações horárias com uma semana de defasagem, assim reproduzindo o padrão de consumo do particular dia da semana. A outra é uma informação mais próxima, o consumo médio do dia anterior ao que se quer prever. Esta última traz a tendência conjuntural mais atual possível e evita à necessidade de utilizar previsões de temperatura, em nível horário, o que normalmente não se encontra disponível com facilidade. Estas informações interligadas são capazes de produzir uma previsão horária coerente para demanda. A separação da série em meses secos e chuvosos tem a finalidade de tornar o treinamento da rede mais rápido, devido às particularidades inerentes a esses dois períodos, o que tornariam difícil a obtenção de um único conjunto de parâmetros da RNA para todos os meses do ano.

5.3.1– MODELO DE RNA's

Os dados utilizados para a simulação do modelo de RNA's, com topologia constituída por uma camada intermediária e treinamento do tipo supervisionado, foram apenas os consumos como informado. A seguir, é apresentado o esquema dos dados de entrada do primeiro caso.

1 – Conjunto de dados de entrada-saída $(x_k^1, x_k^2, \dots, x_k^{25}; d_k)_{k=1}^N$

Meses secos:

$$x_k^1, x_k^2, \dots, x_k^{25} = vazões \text{ (l/s)}$$

$$d_k = vazões \text{ (l/s)} - \text{previsão para as 24 horas do dia}$$

Meses chuvosos:

$$x_k^1, x_k^2, \dots, x_k^{25} = vazões \text{ (l/s)}$$

$$d_k = vazões \text{ (l/s)} - \text{previsão para as 24 horas do dia}$$

Dimensão da RNA:

Fixa: 1 camada de entrada, 1 camada intermediária e 1 camada de saída. O número de neurônios da camada intermediária e o número de parâmetros livres dependem do treinamento para cada período (seco ou chuvoso). Às camadas intermediárias e de saída foram atribuídos limiares e estes foram computados juntamente com os pesos no total de parâmetros livres da rede.

5.3.1.1 – SIMULAÇÃO DO MODELO EM RNA's

O treinamento e o teste do modelo de RNA's foram executados considerando diversas topologias, variando o número de neurônios na camada intermediária e fixando esta em uma camada e observando o número de iterações máximas para pequenas variações dos erros quadráticos. Assim a topologia escolhida para a discussão dos resultados foi a que tem como base o menor erro quadrático e o menor número de neurônios na camada intermediária.

A Tabela 5.9 mostra os testes realizados para o período seco. Nela podemos observar que a topologia que produziu menor erro foi a que tem 50 neurônios na camada intermediária e 1500 iterações.

Tabela 5.9 – Testes Realizados com Algumas Topologias no Período Seco

<i>NEURÔNIOS/ITERAÇÕES</i>	<i>EQM TREINAMENTO</i>	<i>EQM TESTE</i>	<i>TEMPO DE PROCESSAMENTO (s)</i>
10/1500	1,8468	10,0551	41,03
30/1500	1,5978	8,5495	41,03
50/1500	1,7012	7,4255	89,42
50/3000	1,1625	16,4055	183
100/5500	0,6144	31,4428	561

Para comparar os resultados referentes ao período seco do primeiro caso com os resultados obtidos nos outros casos, apresenta-se a Figura 5.8, para a topologia de 10 neurônios na camada intermediária e 1500 iterações. Os valores plotados são valores médios diários das demandas. Em cada caso há um período de treino do modelo de RNA e um período (distinto) de testes.




Figura 5.8 – Valores de Demanda Média para o Reservatório Penha (Treinamento e Teste)




Figura 5.9 – Valores de Demanda Horária para os Dias 28/09/98 e 28/10/98 (Meses Secos)




Figura 5.10 – Valores de Demanda Horária para o Dia 28/11/98 (Meses Secos)

A Tabela 5.10 mostra os testes realizados para o período chuvoso, onde pode-se observar que a topologia que produziu menor erro foi a que tem 50 neurônios na camada intermediária e 1500 iterações.

Tabela 5.10 – Testes Realizados com Algumas Topologias no Período Chuvoso

NEURÔNIOS/ITERAÇÕES	EQM TREINAMENTO	EQM TESTE	TEMPO DE PROCESSAMENTO (s)
10/1500	1,0837	3,6644	39,60
30/1500	0,9949	3,3026	88,81
50/1500	1,0477	3,2408	99,63
50/3000	0,8417	3,7388	188,12
100/5500	0,6638	6,550	550

Para comparar os resultados referentes ao período chuvoso do primeiro caso com os resultados obtidos nos outros casos, apresenta-se a Figura 5.11, para a topologia de 10 neurônios na camada intermediária e 1500 iterações. Os valores plotados são valores médios diários das demandas.




Figura 5.11 - Valores de Demanda Média para o Reservatório Penha (Treinamento e Teste)




Figura 5.12 - Valores de Demanda Horária para os Dias 22/03/99 e 22/04/99 (Meses Chuvosos)




Figura 5.13 - Valores de Demandas Horária para o Dia 22/05/99 (Meses Chuvosos)

Podemos observar que tanto para o período seco quanto para o período chuvoso o resultado da rede neural não se aproxima dos picos. A função objetivo que está sendo minimizada é o erro quadrático médio, esse pode ser um dos motivos, que faz com que a rede não produza boas previsões dos picos de demanda. No caso em estudo, como pretende-se prever demandas em sistemas urbanos de abastecimento o modelo de redes neurais terá utilidade enquanto subsídio à melhoria do controle operacional, especialmente nos sistemas com maior capacidade de reservação.

5.4 – SEGUNDO CASO: PREVISÃO UNIVARIADA – COM ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES (RNA 1.2)

No segundo caso optou-se em dividir a série em quatro períodos, correspondente às quatro estações do ano. O Inverno compreendido entre 21/06/98 a 21/09/98, a Primavera de 22/09/98 a 20/12/98, o Verão de 21/12/98 a 20/03/99 e o Outubro compreendido entre 21/03/99 a 20/06/99.

5.4.1– MODELO DE RNA's

Os dados utilizados para a simulação do modelo de RNA's, com topologia constituída por uma camada intermediária e treinamento do tipo supervisionado, foram, como no primeiro caso, somente os consumos. Os consumos das 24 horas do respectivo dia da semana anterior e o consumo médio do dia anterior ao que se quer prever foram utilizados como variáveis de entrada. A seguir, é apresentado o esquema dos dados de entrada do segundo caso.

1 – Conjunto de dados de entrada-saída $(x_k^1, x_k^2, \dots, x_k^{25}; d_k)_{k=1}^N$

Estação Inverno:

$$x_k^1, x_k^2, \dots, x_k^{25} = vazões \text{ (l/s)}$$

$$d_k = vazões \text{ (l/s)} - \text{previsão para as 24 horas do dia}$$

Estação Primavera:

$$x_k^1, x_k^2, \dots, x_k^{25} = vazões \text{ (l/s)}$$

$$d_k = vazões \text{ (l/s)} - \text{previsão para as 24 horas do dia}$$

Estação Verão:

$$x_k^1, x_k^2, \dots, x_k^{25} = vazões \text{ (l/s)}$$

$$d_k = vazões \text{ (l/s)} - \text{previsão para as 24 horas do dia}$$

Estação Outono:

$$x_k^1, x_k^2, \dots, x_k^{25} = vazões \text{ (l/s)}$$

$$d_k = vazões \text{ (l/s)} - \text{previsão para as 24 horas do dia}$$

Dimensão da RNA:

Fixa: 1 camada de entrada, 1 camada intermediária e 1 camada de saída. O número de neurônios da camada intermediária e o número de parâmetros livres dependem do treinamento para cada período. Às camadas intermediárias e de saída foram atribuídos limiares e estes foram computados juntamente com os pesos no total de parâmetros livres da rede.

5.4.1.1 – SIMULAÇÃO DO MODELO EM RNA's

O treinamento e o teste do modelo de RNA's foram executados considerando diversas topologias, variando o número de neurônios na camada intermediária e fixando esta em uma e variando o número de iterações, observando assim as variações dos erros quadráticos. A topologia escolhida para a discussão dos resultados, foi a topologia que tem 10 neurônios na camada intermediária e 1500 iterações para as quatro estações do ano, para o reservatório Penha. O motivo de escolher a mesma topologia para as quatro estações do ano, é que o erro quadrático não varia substancialmente para as outras topologias, ficando assim mais fácil as comparações entre as redes. As tabelas a seguir mostram estes testes.

Tabela 5.11 – Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Inverno)

Iterações	1000		1500		2000		3000		5000	
Nº Neurônios	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)
05	0,9798	2,993	0,8627	4,352	0,8476	3,035	0,7938	4,4770	0,7532	5,0035
10	0,9078	1,715	0,67	2,81	0,6663	3,238	0,6031	2,6367	0,5181	3,2048
20	0,7007	2,100	0,5522	2,908	0,4675	2,3147	0,359	3,1210	0,2377	5,5588
30	0,739	1,866	0,5220	2,344	0,3767	3,5080	0,2641	3,9448	0,1177	4,3037
60	0,7886	1,890	0,5577	2,329	0,4894	2,4283	0,2414	2,9418	0,0323	3,8647
90	0,8412	1,887	0,5895	2,213	0,4758	2,3725	0,2915	2,9540	0,0953	3,8115
100	0,8233	1,881	0,5866	2,093	0,5062	2,2606	0,2558	2,9819	0,0646	3,9454

Tabela 5.12 - Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Primavera)

Iterações	1000		1500		2000		3000		5000	
Nº Neurônios	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)
05	0,4359	2,476	0,4132	3,080	0,388	4,9020	0,3437	2,5786	0,3426	24,55
10	0,3553	2,805	0,3948	2,709	0,2805	2,7662	0,2609	17,347	0,2181	7,4208
20	0,3445	3,127	0,2857	3,525	0,2451	5,1549	0,1771	10,405	0,0979	41,900
30	0,3429	2,880	0,2787	3,813	0,2560	5,4017	0,1623	12,083	0,0659	19,19
60	0,3983	2,396	0,3160	4,054	0,2684	4,6973	0,1906	12,586	0,0726	21,026
90	0,4282	2,657	0,3198	4,881	0,2626	5,9265	0,1971	9,0341	0,0995	19,494
100	0,4706	2,310	0,4157	3,020	0,2545	7,8508	0,1996	7,7427	0,0958	26,092

Tabela 5.13 – Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Verão)

Iterações	1000		1500		2000		3000		5000	
Nº Neurônios	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)
05	0,2689	0,378	0,2658	0,355	0,2498	0,3467	0,2246	0,3380	0,1890	0,7057
10	0,2288	0,384	0,2196	0,375	0,1900	0,38	0,1612	0,4086	0,1305	0,6830
20	0,2179	0,454	0,1804	0,399	0,1637	0,4011	0,1105	0,4916	0,0744	0,6879
30	0,2476	0,525	0,1738	0,446	0,1472	0,4065	0,1047	0,4774	0,063	0,76
60	0,2628	0,548	0,1964	0,494	0,1383	0,4007	0,1148	0,4884	0,0746	0,7400
90	0,3164	0,603	0,2082	0,427	0,1560	0,4060	0,1111	0,4469	0,0789	0,5779
100	0,3323	0,526	0,2300	0,529	0,1552	0,4431	0,1169	0,5380	0,1183	2,2568

Tabela 5.14 – Teste das Topologias de RNA's para a Demanda Associada ao Reservatório Penha (Outono)

Iterações	1000		1500		2000		3000		5000	
Nº Neurônios	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)	EQM (Treino)	EQM (Teste)
05	1,3359	2,093	1,2773	2,828	1,0771	4,8195	1,0807	8,6702	0,9945	24,837
10	1,1659	2,528	0,9428	2,921	0,8334	3,0944	0,8222	3,4493	0,6955	7,7584
20	0,8697	2,775	0,6448	3,401	0,5724	3,9479	0,4064	6,3496	0,2833	7,1776
30	0,9337	2,584	0,639	3,626	0,4658	3,6824	0,2645	4,7043	0,12	5,071
60	0,8172	2,684	0,655	2,768	0,4569	3,7322	0,2387	3,7264	0,0196	5,9778
90	0,8246	2,631	0,6484	3,139	0,5352	3,370	0,2846	6,0642	0,0164	5,0663
100	0,8582	2,665	0,6234	3,50	0,4901	3,5009	0,2653	4,6356	0,0272	5,3213

Para a representação gráfica foi escolhido o reservatório Penha, com a topografia de 10 neurônios na camada intermediária e 1500 iterações.

Tabela 5.15 – Resultados da Etapa de Treinamento e Teste para o Reservatório Penha (10 neurônios na camada intermediária e 1500 iterações)

RESERVATÓRIO PENHA			
	EQM Treinamento	EQM Teste	Tempo de Processamento (s)
INVERNO	0,6700	2,8100	34,5
PRIMAVERA	0,3948	2,7090	109
VERÃO	0,2196	0,3752	34,76
OUTONO	0,9428	2,9212	33,89

Observando a Tabela 5.15 verificamos que os melhores resultados estão nas estações: primavera e verão. Confirmando o resultado do primeiro caso, onde o melhor resultado ocorreu no período compreendido entre dezembro e maio.

As figuras a seguir mostram o resultado da previsão para as quatro estações do ano, para o reservatório Penha. A Figura 5.14, apresenta os resultados de treinamento e do teste para a estação de inverno. Para melhor visualização, os resultados plotados são valores médios de

vazão. A Figura 5.15, mostra a previsão horária para um dia escolhido aleatoriamente. Na sequência as figuras mostram os resultados para as estações de inverno, primavera, verão e outono.




Figura 5.14 - Valores de Demanda Média para o Reservatório Penha Inverno (Treinamento e Teste)




Figura 5.15 - Valores de Demanda Horária para o Dia 28/08/98 (Inverno)




Figura 5.16 - Valores de Demanda Média para o Reservatório Penha Primavera (Treinamento e Teste)




Figura 5.17 - Valores de Demanda Horária para o Dia 28/11/98 (Primavera)




Figura 5.18 - Valores de Demanda Média para o Reservatório Penha Verão (Treinamento e Teste)




Figura 5.19 - Valores de Demanda Horária para o Dia 20/03/99 (Verão)




Figura 5.20 - Valores de Demanda Média para o Reservatório Penha Outubro (Treinamento e Teste)




Figura 5.21 - Valores de Demanda Horária para o Dia 22/05/99 (Outubro)

As tabelas a seguir mostram o resultados do treinamento e teste para os outros reservatórios.

Tabela 5.16 – Resultados da Etapa de Treinamento e Teste para o Reservatório Jardim Popular (10 neurônios na camada intermediária e 1500 iterações)

RESERVATÓRIO JARDIM POPULAR			
	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de Processamento (s)</i>
<i>INVERNO</i>	1,2335	12,1613	34,38
<i>PRIMAVERA</i>	0,7907	6,0637	33,28
<i>VERÃO</i>	1,5360	8,0472	34,87
<i>OUTONO</i>	0,3664	3,9553	35,21

Tabela 5.17 – Resultados da Etapa de Treinamento e Teste para o Reservatório Edu Chaves (10 neurônios na camada intermediária e 1500 iterações)

RESERVATÓRIO EDU CHAVES			
	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de Processamento (s)</i>
<i>INVERNO</i>	0,4918	3,9421	35,20
<i>PRIMAVERA</i>	0,1350	1,4761	38,17
<i>VERÃO</i>	0,3346	1,5614	33,94
<i>OUTONO</i>	0,7968	3,3969	34,60

Tabela 5.18 – Resultados da Etapa de Treinamento e Teste para o Reservatório Ermelino Matarazzo (10 neurônios na camada intermediária e 1500 iterações)

RESERVATÓRIO ERMELINO MATARAZZO			
	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de Processamento (s)</i>
<i>INVERNO</i>	0,7665	1,8950	34,87
<i>PRIMAVERA</i>	0,3934	3,7465	35,81
<i>VERÃO</i>	1,1578	3,3577	36,03
<i>OUTONO</i>	0,7413	3,4772	36,08

Tabela 5.19 – Resultados da Etapa de Treinamento e Teste para o Reservatório Jaçanã (10 neurônios na camada intermediária e 1500 iterações)

RESERVATÓRIO JAÇANÃ			
	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de Processamento (s)</i>
<i>INVERNO</i>	0,8500	3,8100	38,10
<i>PRIMAVERA</i>	0,6628	6,2184	34,87
<i>VERÃO</i>	0,8809	2,1151	33,90
<i>OUTONO</i>	0,6998	1,8542	35,02

Tabela 5.20 – Resultados da Etapa de Treinamento e Teste para o Reservatório Gopoúva (10 neurônios na camada intermediária e 1500 iterações)

RESERVATÓRIO GOPOÚVA			
	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de Processamento (s)</i>
INVERNO	1,3511	3,0443	35,15
PRIMAVERA	2,5977	7,9544	34,66
VERÃO	1,8377	16,9528	34,66
OUTONO	4,1925	29,6342	35,37

Tabela 5.21 – Resultados do Treinamento e Teste para o Reservatório Cangaíba (10 neurônios na camada intermediária e 1500 iterações)

RESERVATÓRIO CANGAÍBA			
	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de Processamento (s)</i>
INVERNO	0,6771	2,8464	34,61
PRIMAVERA	0,5966	16,5777	33,95
VERÃO	0,9553	16,5772	33,95
OUTONO	0,3230	3,1984	35,59

5.5 – TERCEIRO CASO: ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES E INCLUSÃO DA VARIÁVEL TEMPERATURA (RNA 2.1.1, RNA 2.1.2 e RNA 2.1.3)

No terceiro caso optou-se em dividir a série em quatro períodos, correspondente às quatro estações do ano. O inverno compreendido entre 21/06/98 a 21/09/98, a primavera de 22/09/98 a 20/12/98, o verão de 21/12/98 a 20/03/99 e o outono de 21/03/99 a 20/06/99.

Foram processados três variantes do modelo RNA, que produziram a previsão da demanda média, isto é, variações que possuem entradas diferentes. Cada variação do modelo foi treinada e testada para as quatro estações do ano. Na primeira variação (RNA 2.1.1) tivemos como dados de entrada a temperatura média e o consumo médio do dia anterior ao que se quer prever. Nesta variação há dois neurônios na camada de entrada. Na segunda variação (RNA 2.1.2) os dados de entrada foram a previsão da temperatura média do dia que se quer prever e o consumo médio do dia anterior ao que se quer prever. Esta variação também possui dois neurônios na camada de entrada. Na terceira variação (RNA 2.1.3) as entradas foram: a temperatura média e o consumo médio do dia anterior ao que se quer prever e o consumo médio

do respectivo dia da semana anterior, possuindo esta variação três neurônios na camada de entrada.

5.5.1– MODELO DE RNA's

Os dados utilizados para a simulação do modelo de RNA's, com topologia constituída por uma camada intermediária e treinamento do tipo supervisionado, foram valores de consumo médio e temperatura média conforme já informado anteriormente. A seguir, estão estruturadas todas as informações que constituem a simulação neural:

1 – Conjunto de dados de entrada-saída para RNA 2.1.1 e RNA 2.1.2 $(x_k^1, t_k^2; d_k)_{k=1...N}^N$

Estação Inverno:

$$x_k^1, t_k^2 = \text{vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

Estação Verão:

$$x_k^1, t_k^2 = \text{vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

Estação Primavera:

$$x_k^1, t_k^2 = \text{vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

Estação Outono:

$$x_k^1, t_k^2 = \text{vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

2 – Conjunto de dados de entrada-saída para RNA 2.1.3 $(x_k^1, x_k^2, t_k^3; d_k)_{k=1...N}^N$

Estação Inverno:

$$x_k^1, x_k^3, t_k^2 = \text{vazões (l/s), vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

Estação Primavera:

$$x_k^1, x_k^3, t_k^2 = \text{vazões (l/s), vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

Estação Verão:

$$x_k^1, x_k^3, t_k^2 = \text{vazões (l/s), vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

Estação Outono:

$$x_k^1, x_k^3, t_k^2 = \text{vazões (l/s), vazões (l/s), temperaturas (} ^\circ \text{C)}$$

$$d_k = \text{vazões (l/s)}$$

Dimensão da RNA:

A RNA 2.1.1 e RNA 2.1.2 possuem uma rede com uma camada de entrada, uma camada intermediária e uma camada de saída. A camada de entrada possui 2 neurônios (referentes aos dados de entrada), a camada intermediária possui 10 neurônios (definido com base nos testes realizados) e a camada de saída possui 1 neurônio (referente à previsão da demanda média diária). A RNA 2.1.3 é análoga as outras e possui três camadas. A primeira possui 3 neurônios, a camada intermediária possui 10 neurônios e a de saída possui 1 neurônio. Nas camadas intermediárias e de saída foram atribuídas entradas adicionais (*Bias*), que foram computadas juntamente com os pesos.

5.5.1.1 – SIMULAÇÃO DO MODELO EM RNA's

O treinamento e o teste das três variações foram simulados considerando a topologia, de 10 neurônios na camada intermediária e 1500 iterações, para as quatro estações do ano e para o reservatório Penha. As tabelas a seguir mostram o erro quadrático médio (EQM) para o treinamento e teste para as três variações (RNA 2.1.1, RNA 2.1.2 e RNA 2.1.3).

Tabela 5.22 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.1.1.

	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de processamento</i>
<i>INVERNO</i>	0,99796	0,68941	29,82 s
<i>PRIMAVERA</i>	0,66503	0,46681	29,11 s
<i>VERÃO</i>	0,89511	0,22425	21,15 s
<i>OUTONO</i>	0,64880	0,88173	40,43 s

Tabela 5.23 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.1.2.

	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de processamento</i>
<i>INVERNO</i>	0,88480	0,90905	29,27 s
<i>PRIMAVERA</i>	0,75151	0,43568	21,09 s
<i>VERÃO</i>	0,92169	0,21579	27,03 s
<i>OUTONO</i>	0,65039	0,74291	21,59 s

Tabela 5.24 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.1.3.

	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de processamento</i>
<i>INVERNO</i>	0,79650	0,97628	16,26 s
<i>PRIMAVERA</i>	0,86975	1,01271	18,07 s
<i>VERÃO</i>	0,72237	0,24811	17,96 s
<i>OUTONO</i>	0,64495	0,73003	19,17 s

Podemos observar que para alguns casos o EQM de teste é menor que o EQM de treinamento, o que pode-se explicar com base nos valores do desvio padrão de cada segmento da série de vazões de consumo e temperatura observadas. Estes valores são mostrados nas Tabelas 5.25 a 5.27.

Tabela 5.25 – Valores de Média e Desvio Padrão para os Dados de Treino e Teste (RNA 2.1.1)

PRIMEIRO MODELO								
TREINAMENTO					TESTE			
	Temperatura Média (°C)		Demanda Média (l/s)		Temperatura Média (°C)		Demanda Média (l/s)	
	Média	DP	Média	DP	Média	DP	Média	DP
Inverno	18,47	2,93	523,61	27,72	20,33	3,31	521,51	28,11
Primavera	19,93	2,53	529,68	30,27	23,26	2,27	566,47	23,77
Verão	24,03	2,14	541,58	29,40	24,90	1,71	540,45	22,41
Outono	21,27	3,27	583,58	20,10	16,66	1,99	584,69	28,90

Tabela 5.26 – Valores de Média e Desvio Padrão para os Dados de Treino e Teste (RNA 2.1.2)

SEGUNDO MODELO								
TREINAMENTO					TESTE			
	Temperatura Média (°C)		Demanda Média (l/s)		Temperatura Média (°C)		Demanda Média (l/s)	
	Média	DP	Média	DP	Média	DP	Média	DP
Inverno	18,53	2,91	523,61	23,71	20,22	3,40	521,51	28,11
Primavera	19,98	2,48	529,68	30,27	23,42	2,12	566,47	23,77
Verão	24,13	2,20	540,65	30,02	23,73	1,54	542,27	20,35
Outono	21,09	3,33	583,58	20,10	16,65	1,99	584,69	28,90

Tabela 5.27 – Valores de Média e Desvio Padrão para os Dados de Treino e Teste (RNA 2.1.3)

TERCEIRO MODELO												
TREINAMENTO							TESTE					
	Temperatura (°C)		Demanda Média (l/s)		Demanda Média semana anterior (l/s)		Temperatura (°C)		Demanda Média (l/s)		Demanda Média semana anterior (l/s)	
	Média	DP	Média	DP	Média	DP	Média	DP	Média	DP	Média	DP
Inverno	18,47	2,93	523,61	23,71	522,65	23,74	20,33	3,31	521,51	28,11	523,65	27,82
Primavera	19,93	2,53	529,68	30,27	526,01	28,73	23,26	2,27	566,47	23,77	564,66	23,84
Verão	24,07	2,16	540,65	30,02	544,60	30,52	23,80	1,65	542,27	20,35	536,73	20,59
Outono	21,27	3,27	583,58	20,10	578,08	20,23	16,66	1,99	584,69	28,90	592,25	29,18

A seguir serão mostrados os melhores resultados para as três variações propostas.

Para RNA 2.1.1, os melhores resultados foram observados para as estações de primavera

e verão, como podemos observar na Tabela 5.21. As Figuras 5.22 e 5.23, mostram o resultado da previsão para estas duas estações.




Figura 5.22 – Resultado do Treinamento e Teste para a Estação de Primavera (RNA 2.1.1)




Figura 5.23 – Resultado do Treinamento e Teste para a Estação de Verão (RNA 2.1.1)

Para RNA 2.1.2, como na RNA 2.1.1 os melhores resultados foram observados para as estações de primavera e verão, como podemos observar na Tabela 5.23 As Figuras 5.24 e 5.25 mostram o resultado da previsão para estas duas estações.




Figura 5.24 – Resultado do Treinamento e Teste para a Estação de Primavera (RNA 2.1.2)




Figura 5.25 – Resultado do Treinamento e Teste para a Estação de Verão (RNA 2.1.2)

Para RNA 2.1.3, os melhores resultados foram detectados para as estações de verão e outono, como podemos observar na Tabela 5.24. As Figuras 5.26 e 5.27 mostram os resultados da previsão para estas estações.




Figura 5.26 – Resultado do Treinamento e Teste para a Estação de Verão (RNA 2.1.3)




Figura 5.27 – Resultado do Treinamento e Teste para a Estação de Outono (RNA 2.1.3)

Até o momento podemos avaliar os resultados da seguinte maneira: há uma tendência dos resultados de previsão serem melhores no período chuvoso da região metropolitana de São Paulo, que compreende os meses de dezembro até maio, como foi confirmado no segundo caso, com os melhores resultados nos meses de primavera e verão, e se confirma no terceiro caso, cuja as duas variações do modelo de RNA, que são RNA 2.1.1 e RNA 2.1.2 apresentaram melhores

resultados nos meses de primavera e verão e o modelo RNA 2.1.3, nas estações de outono e verão.

5.6 – QUARTO CASO: ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES SEM INCLUSÃO DA VARIÁVEL TEMPERATURA (RNA 2.2.1)

No quarto caso optou-se em dividir a série em quatro períodos, correspondente às quatro estações do ano. O inverno compreendido entre 21/06/98 a 21/09/98, a primavera de 22/09/98 a 20/12/98, o verão de 21/12/98 a 20/03/99 e o outono de 21/03/99 a 20/06/99.

Foi processado uma variação do modelo de RNA, que produziu a previsão da demanda média. Esta variação do modelo (RNA 2.2.1) foi treinada e testada para as quatro estações do ano. Os dados de entrada desta variação foram o consumo médio do dia anterior ao que se quer prever e o consumo médio do respectivo dia da semana anterior, possuindo dois neurônios na camada de entrada.

5.6.1– MODELO DE RNA's

Os dados utilizados para a simulação do modelo de RNA's, com topologia constituída por uma camada intermediária e treinamento do tipo supervisionado, foram valores de consumo médio do dia anterior ao que se quer prever e o consumo médio do respectivo dia da semana anterior, conforme já informado anteriormente. A seguir, estão estruturadas todas as informações que constituem a simulação neural:

1 – Conjunto de dados de entrada-saída para RNA 2.2.1 $(x_k^1, x_k^2; d_k)_{k=1...N}^N$

Estação Inverno:

$x_k^1, x_k^2 = \text{vazões (l/s)}, \text{vazões (l/s)}$

$d_k = \text{vazões (l/s)}$

Estação Primavera:

$x_k^1, x_k^2 = \text{vazões (l/s)}, \text{vazões (l/s)}$

$d_k = \text{vazões (l/s)}$

Estação Verão:

$$x_k^1, x_k^2 = \text{vazões (l/s)}, \text{vazões (l/s)}$$

$$d_k = \text{vazões (l/s)}$$

Estação Outono:

$$x_k^1, x_k^2 = \text{vazões (l/s)}, \text{vazões (l/s)}$$

$$d_k = \text{vazões (l/s)}$$

Dimensão da RNA:

A RNA 2.2.1 possui uma rede com uma camada de entrada, uma camada intermediária e uma camada de saída. A camada de entrada possui 2 neurônios (referentes aos dados de entrada), a camada intermediária possui 10 neurônios (definido com base nos testes realizados) e a camada de saída possui 1 neurônio (referente à previsão da demanda média diária). Na camada intermediária e de saída foram atribuídas entradas adicionais (*Bias*), que foram computadas juntamente com os pesos.

5.6.1.1 – SIMULAÇÃO DO MODELO EM RNA's

O treinamento e o teste da RNA 2.2.1 foi simulado considerando a topologia de 10 neurônios na camada intermediária e 1500 iterações, para as quatro estações do ano e para o reservatório Penha. As tabelas a seguir mostram o erro quadrático médio (EQM) para o treinamento e teste.

Tabela 5.28 – Erro Quadrático Médio de Treinamento e Teste para RNA 2.2.1

	<i>EQM Treinamento</i>	<i>EQM Teste</i>	<i>Tempo de processamento</i>
INVERNO	0,46990	1,26570	16,31 s
PRIMAVERA	0,54823	1,41632	16,37 s
VERÃO	0,52739	0,27747	42,51 s
OUTONO	0,43582	0,78535	31,86 s

Para a RNA 2.2.1, os melhores resultados foram detectados para as estações de verão e outono, como podemos observar na Tabela 5.28. As Figuras 5.28 e 5.29 mostram os resultados da previsão para estas estações.




Figura 5.28 – Resultado do Treinamento e Teste para a Estação de Verão (RNA 2.2.1)




Figura 5.29 – Resultado do Treinamento e Teste para a Estação de Outono (RNA 2.2.1)

5.7 – APLICAÇÃO DO MODELO DE MÉDIAS MÓVEIS PARA A PREVISÃO DE DEMANDA – ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES

Foram previstas as demandas horárias para 7 reservatórios da Alça Leste, usando o modelo de médias móveis, para os dados estratificados em quatro estações. O período de recorrência (Pr) foi escolhido com base em testes realizados com o reservatório Penha estação inverno. As previsões foram calculadas com $Pr = 3$ dias, $Pr = 5$ dias e $Pr = 7$ dias e calculados os erros absolutos médios (EAM) para as três situações. O menor erro foi para o $Pr = 3$, sendo assim as previsões para o restante dos reservatórios também usaram o $Pr = 3$ em todas as estação do ano. A Figura 5.30 mostra o resultado da previsão por médias móveis para 4 dias, usando os períodos de referência citados acima.




Fig 5.30 – Valores Observados x Valores Previstos Por Médias Móveis Para Três Períodos de Referência (22/06/98 a 25/06/98).

A Tabela 5.29 apresenta o resultado da análise estatística realizada com a finalidade de escolher o melhor Pr .

Tabela 5.29 – Erro Absoluto Médio Para os Períodos de Recorrência (Reservatório Penha – Inverno)

	<i>Pr</i> = 3	<i>Pr</i> = 5	<i>Pr</i> = 7
<i>EAM (l/s)</i>	70,79	98,02	120,60

5.8 – APLICAÇÃO DO MODELO AUTO REGRESSIVO PARA A PREVISÃO DE DEMANDA – ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES

Foram previstas as demandas horárias para 7 reservatórios da Alça Leste, usando o modelo de auto-regressivo, para os dados estratificados em quatro estações.

5.8.1 – ANÁLISE DA SÉRIE DE DEMANDAS

Nesta seção, serão apresentados os resultados da análise estatística realizada para a série de consumos horários para o reservatório Penha (estação inverno), Figura 5.31. Como mencionado anteriormente, as séries de consumos são séries não-estacionárias. As séries de consumos serão denotadas por $(x_{i,m}, i = 1, \dots, n ; m = 1, \dots, 24)$, onde i é o índice do dia com n denotando o número de dias do histórico, e m representa o número de horas, $m = 1$ equívale a primeira hora do dia e $m = 24$ a última hora do dia. Para transformar as séries de demandas em uma série estacionária os seguintes passos foram realizados:

Cálculo das estimativas da média $\hat{\mu}_m$ e da variância $\hat{\sigma}_m^2$ para cada hora m da seguinte forma:

$$\hat{\mu}_m = \frac{1}{n} \sum_{i=1}^n x_{i,m} \quad (5.1)$$

$$\hat{\sigma}_m^2 = \frac{1}{n-1} \sum_{i=1}^n (x_{i,m} - \hat{\mu}_m)^2 \quad (5.2)$$

onde $x_{i,m}$ denota a vazão no dia $i = 1, 2, \dots, n$ e na hora $m = 1, 2, \dots, 24$.




Figura 5.31 – Série de Consumos Horários para o Reservatório Penha (Estação Inverno)

A Tabela 5.30 mostra a média e o desvio padrão para cada hora da série de consumos considerada. A Figura 5.32 mostra as médias e desvios padrões horários.

A seguir, os dados da série são padronizados, pois assim elimina-se o componente sazonal. Para isso, deve-se subtrair de cada dado de vazão a média horária e dividir pelo desvio padrão horário.

$$\tilde{z}_{i,m} = \frac{x_{i,m} - \hat{\mu}_m}{\hat{\sigma}_m} \quad (5.3)$$

Tabela 5.30 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Inverno)

HORAS	MÉDIA (l/s)	DESVIO PADRÃO (l/s)
1	394,03	32,61
2	353,92	26,37
3	329,55	25,53
4	322,68	24,03
5	317,43	24,82
6	333,02	26,22
7	388,68	45,45
8	474,37	56,70
9	570,80	62,64
10	665,62	61,00
11	734,08	64,45
12	732,12	43,99
13	718,33	38,22
14	692,88	39,43
15	664,42	42,30
16	632,27	40,36
17	605,85	46,06
18	590,78	50,29
19	571,80	41,06
20	554,93	36,45
21	528,17	33,66
22	494,42	28,06
23	478,65	28,85
24	436,42	32,69

A série padronizada $\tilde{z}_{i,m}$, apresenta, aproximadamente, média zero e variância unitária, ou seja:

$$\tilde{z} = \frac{1}{N} \sum_{i=1}^N \sum_{m=1}^{24} \tilde{z}_{i,m} \approx 0 ; \text{Var}[\tilde{z}] = \frac{1}{N} \sum_{i=1}^N \sum_{m=1}^{24} (\tilde{z}_{i,m} - \bar{\tilde{z}})^2 \approx 1.0 \quad (5.4)$$

onde $N = 1440$. A Figura 5.33 mostra a série padronizada.




Figura 5.32 – Média e Desvio Padrão Horário para a Série de Consumos do Reservatório Penha (Estação Inverno)




Figura 5.33 – Série Padronizada para os Dados de Consumo do Reservatório Penha (Estação Inverno)

As estimativas dos coeficientes de autocovariância e autocorrelação para a série de consumos foram calculadas. Os 36 valores de r_k são dados na Tabela 5.31 e plotados na Figura 5.34. Pode-se notar que a estimativa da função de autocorrelação é caracterizada por um decaimento nos valores de r_k quando o intervalo k aumenta. Também observa-se uma tendência da curva a um comportamento senoidal. Esta forma de comportamento da função de autocorrelação é típica de modelos auto-regressivos.

Tabela 5.31 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Penha (Estação Inverno)

k	r_k	k	r_k	k	r_k
1	0,420	13	0,179	25	0,103
2	0,467	14	0,166	26	0,048
3	0,357	15	0,107	27	0,051
4	0,329	16	0,064	28	0,036
5	0,220	17	0,066	29	-0,001
6	0,213	18	0,039	30	0,022
7	0,201	19	0,048	31	0,032
8	0,181	20	0,083	32	0,038
9	0,190	21	0,104	33	0,072
10	0,185	22	0,109	34	0,080
11	0,196	23	0,108	35	0,085
12	0,203	24	0,109	36	0,067




Figura 5.34 – Função de Autocorrelação para a Série de Consumo para o Reservatório Penha (Estação Inverno)

5.8.2 – AJUSTE DO MODELO AUTO-REGRESSIVO PARA A SÉRIE DE CONSUMOS

Considerando a série de consumos do reservatório Penha, juntamente com os resultados da análise da série e observando o comportamento da função de autocorrelação (Figura 5.34), verifica-se que as estimativas dos coeficientes de autocorrelação decaem exponencialmente e oscilam na forma de uma senóide após um certo intervalo k , sendo que estas características são típicas de modelos auto-regressivos. Através da análise das funções de autocorrelação e autocorrelação parcial, um modelo AR(2) foi selecionado para a série de consumos do reservatório Penha, com ϕ_1 e ϕ_2 assumindo valores positivos. Esse modelo apresentou-se como o mais parcimonioso, ou seja, com menor número de parâmetros possíveis e com variância dos resíduos $\sigma_a^2 = 0,760$, como pode ser visto na Tabela 5.32, onde é mostrada a variância para um modelo auto-regressivo de ordem 1, 2 e 3.

Tabela 5.32 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,871	0,760	0,702

Assim o modelo AR(2) é estimado para a série de consumos do reservatório Penha da seguinte forma:

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t \quad (5.5)$$

onde $\phi_2 = \phi_{22}$ e o coeficiente ϕ_1 é dado pela estimativa do coeficiente de autocorrelação parcial ϕ_{21} , ou seja:

$$\phi_1 = \phi_{21} = \frac{r_1(1-r_2)}{1-r_1^2} = 0,272 \quad ; \quad \phi_2 = \phi_{22} = \frac{r_2-r_1^2}{1-r_1^2} = 0,241 \quad (5.6)$$

Logo o modelo AR(2) para o reservatório Penha pode ser escrito com:

$$z_t = 0,272z_{t-1} + 0,241z_{t-2} + a_t \quad (5.7)$$

Da mesma forma foram estudados os outros reservatórios do sistema, cujos resultados da análise da série temporal encontram-se no anexo D.

5.9 – QUINTO CASO: PREVISÃO MULTIVARIADA – COM ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES (RNA 3.1, RNA 3.2 e RNA 3.3)

No segundo caso foi gerado um modelo de RNA's para a fazer a previsão univariada (Figura 5.35), o qual possui como entrada os consumos horários e médios para um único reservatório e produziu na saída a previsão de demandas horárias. No quinto caso gerou-se um modelo de RNA's capaz de fazer uma previsão multivariada, isto é, utilizando como entrada dois ou mais reservatórios da Alça Leste (Figura 5.36) simultaneamente, possuindo como entrada os consumos horários e médios para os dois ou mais reservatórios correlacionados e produzindo a previsão da demanda horária para os dois ou mais reservatórios correlacionados.




Figura 5.35 – Esquema da Previsão Univariada




Figura 5.36 – Esquema da Previsão Multivariada

Optou-se neste caso pela estratificação da série de consumos em quatro períodos, correspondentes às quatro estações do ano. Foram correlacionados os reservatórios do sistema dois a dois e todos os sete reservatórios.

5.9.1 – MODELO DE RNA's

Os dados utilizados para a simulação do modelo de RNA's, com topologia constituída por uma camada intermediária e treinamento do tipo supervisionado, foram os valores de consumos associados aos reservatórios de distribuição. Tais consumos compreendiam as 24 horas do respectivo dia da semana anterior e a demanda média do dia anterior ao que se quer prever, para cada reservatório. A seguir, é apresentado o esquema dos dados de entrada do quinto caso para correlações dos reservatórios dois a dois e para a correlação de sete reservatórios do sistema.

1 – Conjunto de dados de entrada-saída (*correlação dois a dois – RNA 3.1 e RNA 3.2*)

$$\left(x_k^1, x_k^2, \dots, x_k^{25}; x_j^1, x_j^2, \dots, x_j^{25}; d_k, d_j \right)_{k=1; j=1}^N$$

Estação Inverno:

$$x_k^1, x_k^2, \dots, x_k^{25}, x_j^1, x_j^2, \dots, x_j^{25} = \text{vazões} (l/s)$$

$d_k, d_j = \text{vazões} (l/s)$ – previsão para as 24 horas do dia, para cada reservatório

Estação Primavera:

$$x_k^1, x_k^2, \dots, x_k^{25}, x_j^1, x_j^2, \dots, x_j^{25} = \text{vazões} (l/s)$$

$d_k, d_j = \text{vazões} (l/s)$ – previsão para as 24 horas do dia, para cada reservatório

Estação Verão:

$$x_k^1, x_k^2, \dots, x_k^{25}, x_j^1, x_j^2, \dots, x_j^{25} = \text{vazões} (l/s)$$

$d_k, d_j = \text{vazões} (l/s)$ – previsão para as 24 horas do dia, para cada reservatório

Estação Outono:

$$x_k^1, x_k^2, \dots, x_k^{25}, x_j^1, x_j^2, \dots, x_j^{25} = \text{vazões}(l/s)$$

$d_k, d_j = \text{vazões}(l/s)$ – previsão para as 24 horas do dia, para cada reservatório

2 – Conjunto de dados de entrada-saída (*correlação dos sete reservatórios – RNA 3.3*)

$$\left(x_k^1, \dots, x_k^{25}, x_j^1, \dots, x_j^{25}, x_i^1, \dots, x_i^{25}, x_t^1, \dots, x_t^{25}, x_w^1, \dots, x_w^{25}, x_r^1, \dots, x_r^{25}, x_z^1, \dots, x_z^{25}; d_k, \dots, d_z \right)^N$$

$$k = 1, j = 1, i = 1, t = 1, w = 1, r = 1, z = 1 \quad \text{até } N$$

Estação Inverno:

$$x_k^1, \dots, x_k^{25}, x_j^1, \dots, x_j^{25}, x_i^1, \dots, x_i^{25}, x_t^1, \dots, x_t^{25}, x_w^1, \dots, x_w^{25}, x_r^1, \dots, x_r^{25}, x_z^1, \dots, x_z^{25} = \text{vazões}(l/s)$$

$d_k, d_j, d_i, d_t, d_w, d_r, d_z = \text{vazões}(l/s)$ – previsão para as 24 horas do dia, para cada reservatório

Estação Primavera:

$$x_k^1, \dots, x_k^{25}, x_j^1, \dots, x_j^{25}, x_i^1, \dots, x_i^{25}, x_t^1, \dots, x_t^{25}, x_w^1, \dots, x_w^{25}, x_r^1, \dots, x_r^{25}, x_z^1, \dots, x_z^{25} = \text{vazões}(l/s)$$

$d_k, d_j, d_i, d_t, d_w, d_r, d_z = \text{vazões}(l/s)$ – previsão para as 24 horas do dia, para cada reservatório

Estação Verão:

$$x_k^1, \dots, x_k^{25}, x_j^1, \dots, x_j^{25}, x_i^1, \dots, x_i^{25}, x_t^1, \dots, x_t^{25}, x_w^1, \dots, x_w^{25}, x_r^1, \dots, x_r^{25}, x_z^1, \dots, x_z^{25} = \text{vazões}(l/s)$$

$d_k, d_j, d_i, d_t, d_w, d_r, d_z = \text{vazões}(l/s)$ – previsão para as 24 horas do dia, para cada reservatório

Estação Outono:

$$x_k^1, \dots, x_k^{25}, x_j^1, \dots, x_j^{25}, x_i^1, \dots, x_i^{25}, x_t^1, \dots, x_t^{25}, x_w^1, \dots, x_w^{25}, x_r^1, \dots, x_r^{25}, x_z^1, \dots, x_z^{25} = \text{vazões}(l/s)$$

$d_k, d_j, d_i, d_t, d_w, d_r, d_z = \text{vazões}(l/s)$ – previsão para as 24 horas do dia, para cada reservatório

Dimensão da RNA:

Fixa: 1 camada de entrada, 1 camada intermediária e 1 camada de saída. O número de neurônios da camada intermediária e o número de parâmetros livres dependem do treinamento para cada período. Às camadas intermediárias e de saída foram atribuídos limiares e estes foram computados juntamente com os pesos no total de parâmetros livres da rede.

5.9.1.1 – SIMULAÇÃO DO MODELO EM RNA's

O treinamento e o teste do modelo de RNA's foram executados considerando diversas topologias, variando o número de neurônios na camada intermediária e fixando esta em uma e fixando o número de iterações em 1500.

Observa-se nos perfis adimensionalizados dos reservatórios (Figura 5.3), que alguns reservatórios apresentam um comportamento no consumo muito próximo e outros mostram perfis diferenciados. Procura-se investigar a previsão multivariada para situações em que os reservatórios apresentam perfis de consumo próximos e distintos e também como seria a previsão correlacionando todos os reservatórios do sistema.

Em uma primeira fase foram correlacionados os reservatórios que possuem perfis de consumo mais próximos (RNA 3.1). As tabelas a seguir mostram estes testes, realizados correlacionando os reservatórios dois a dois.

Tabela 5.33 - Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Edu Chaves e Gopoúva

EDU CHAVES E GOPOÚVA (ESTAÇÃO INVERNO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	4,82	18,92	39,38
20/1500	2,83	19,69	49,33
30/1500	1,50	18,29	61,63
40/1500	0,96	18,46	70,69
50/1500	0,61	19,32	93,98
EDU CHAVES E GOPOÚVA (ESTAÇÃO PRIMAVERA)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	6,51	321,70	42,90
20/1500	2,48	249,89	54,65
30/1500	0,97	239,19	65,41
40/1500	0,40	226,51	77,61
50/1500	0,25	243,45	90,95
EDU CHAVES E GOPOÚVA (ESTAÇÃO VERÃO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	2,87	39,76	104,25
20/1500	1,27	28,79	63,33
30/1500	0,45	37,78	138,79
40/1500	0,13	30,16	162,69
50/1500	0,038	26,96	172,74
EDU CHAVES E GOPOÚVA (ESTAÇÃO OUTONO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	12,44	221,10	44,71
20/1500	5,42	231,06	53,94
30/1500	1,54	191,12	64,38
40/1500	0,57	243,31	77,55
50/1500	0,15	185,49	90,57

Tabela 5.34 - Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Cangaíba e Jardim Popular

CANGAÍBA E JARDIM POPULAR (ESTAÇÃO INVERNO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	1,13	36,92	48,61
20/1500	0,59	41,37	64,43
30/1500	0,27	47,04	71,46
40/1500	0,15	45,58	87,88
50/1500	0,09	44,74	98,92
CANGAÍBA E JARDIM POPULAR (ESTAÇÃO PRIMAVERA)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	0,88	24,28	41,74
20/1500	0,53	28,24	53,45
30/1500	0,29	26,27	63,60
40/1500	0,17	29,02	75,96
50/1500	0,12	27,36	89,37
CANGAÍBA E JARDIM POPULAR (ESTAÇÃO VERÃO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	1,53	27,42	111,50
20/1500	0,71	25,71	54,15
30/1500	0,32	33,63	66,46
40/1500	0,14	19,92	78,71
50/1500	0,04	25,06	92,06
CANGAÍBA E JARDIM POPULAR (ESTAÇÃO OUTONO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	0,59	19,74	40,70
20/1500	0,33	12,27	54,98
30/1500	0,24	19,77	63,71
40/1500	0,18	24,96	79,53
50/1500	0,17	20,33	92,82

Tabela 5.35 - Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Penha e Jaçanã

PENHA E JAÇANÃ (ESTAÇÃO INVERNO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	2,42	18,47	54,17
20/1500	1,15	15,48	61,74
30/1500	0,51	20,49	71,24
40/1500	0,26	19,01	86,18
50/1500	0,14	18,55	98,37
PENHA E JAÇANÃ (ESTAÇÃO PRIMAVERA)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	0,74	17,63	93,59
20/1500	0,44	17,37	124,44
30/1500	0,22	16,85	137,76
40/1500	0,09	18,28	162,74
50/1500	0,03	16,75	181,09
PENHA E JAÇANÃ (ESTAÇÃO VERÃO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	0,48	3,95	41,12
20/1500	0,23	4,16	55,14
30/1500	0,12	3,75	63,88
40/1500	0,08	4,14	76,07
50/1500	0,06	4,40	94,42
PENHA E JAÇANÃ (ESTAÇÃO OUTONO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	2,03	21,87	37,07
20/1500	1,32	23,32	49,37
30/1500	0,68	24,49	58,06
40/1500	0,51	23,45	71,62
50/1500	0,27	23,92	80,68

Observando as tabelas, verificamos que para cada correlação os melhores resultados ocorrem em topologias diferentes, a análise estatística foi realizada para os melhores resultados.

Em uma segunda fase foram correlacionados os reservatórios que possuem perfis de consumo diferentes (RNA 3.2). As tabelas a seguir mostram as topologias testadas e os erro de treinamento e teste da rede.

Tabela 5.36 - Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Penha e Edu Chaves

PENHA E EDU CHAVES (ESTAÇÃO INVERNO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	4,78	78,73	38,50
20/1500	1,85	59,85	49,76
30/1500	1,19	71,25	59,65
40/1500	0,40	60,39	72,78
50/1500	0,25	59,07	85,85
PENHA E EDU CHAVES (ESTAÇÃO PRIMAVERA)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	0,56	12,03	49,81
20/1500	0,33	12,41	50,59
30/1500	0,18	14,59	58,99
40/1500	0,14	13,23	73,27
50/1500	0,12	12,81	86,46
PENHA E EDU CHAVES (ESTAÇÃO VERÃO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	0,63	38,56	53,78
20/1500	0,30	15,86	49,71
30/1500	0,15	16,11	61,69
40/1500	0,05	18,13	75,69
50/1500	0,01	15,50	84,59
PENHA E EDU CHAVES (ESTAÇÃO OUTONO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	1,55	113,46	46,96
20/1500	0,71	151,75	50,48
30/1500	0,29	126,12	59,26
40/1500	0,12	113,19	73,93
50/1500	0,08	125,34	84,25

Tabela 5.37 - Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Gopoúva e Cangaíba

GOPOÚVA E CANGAÍBA (ESTAÇÃO INVERNO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	7,15	23,37	38,23
20/1500	3,25	36,56	52,23
30/1500	1,53	33,06	59,26
40/1500	0,59	34,36	73,77
50/1500	0,48	32,80	84,64
GOPOÚVA E CANGAÍBA (ESTAÇÃO PRIMAVERA)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	6,26	148,47	41,96
20/1500	2,98	169,04	59,54
30/1500	1,27	172,43	70,31
40/1500	0,47	162,36	84,64
50/1500	0,22	158,84	97,44
GOPOÚVA E CANGAÍBA (ESTAÇÃO VERÃO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	3,89	58,54	44,21
20/1500	1,57	53,97	60,14
30/1500	0,67	48,30	69,16
40/1500	0,28	61,70	84,48
50/1500	0,14	70,47	96,34
GOPOÚVA E CANGAÍBA (ESTAÇÃO OUTONO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	14,32	214,66	37,90
20/1500	5,23	198,01	51,41
30/1500	1,74	193,23	58,99
40/1500	0,65	204,43	72,61
50/1500	0,20	175,90	83,59

Tabela 5.38 - Erro Quadrático Médio de Treinamento e Teste para os Reservatórios Jardim Popular e Jaçanã

JARDIM POPULAR E JAÇANÃ (ESTAÇÃO INVERNO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	3,64	65,07	49,98
20/1500	1,64	62,36	63,28
30/1500	0,71	47,99	71,74
40/1500	0,46	69,54	84,26
50/1500	0,30	64,12	97,22
JARDIM POPULAR E JAÇANÃ (ESTAÇÃO PRIMAVERA)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	1,60	36,99	46,30
20/1500	0,71	44,42	60,03
30/1500	0,26	42,54	68,16
40/1500	0,08	43,97	84,53
50/1500	0,01	43,05	97,38
JARDIM POPULAR E JAÇANÃ (ESTAÇÃO VERÃO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	3,47	18,70	43,23
20/1500	1,30	17,96	61,46
30/1500	0,58	19,31	68,77
40/1500	0,29	20,32	83,00
50/1500	0,13	17,74	97,77
JARDIM POPULAR E JAÇANÃ (ESTAÇÃO OUTONO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	14,85	313,42	39,82
20/1500	5,85	245,41	49,49
30/1500	1,62	182,43	58,27
40/1500	0,69	189,10	71,56
50/1500	0,27	181,47	83,49

Assim como na etapa anterior, os melhores resultados de cada correlação ocorrem em topologias diferentes, a análise estatística foi realizada somente para os melhores resultados.

Também foram correlacionados sete reservatórios da rede (RNA 3.3). Os erro de treinamento e teste encontram-se nas tabelas a seguir.

Tabela 5.39 - Erro Quadrático Médio de Treinamento e Teste para os Sete Reservatórios da Rede

SETE RESERVATÓRIOS (ESTAÇÃO INVERNO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	6,34	111,59	98,26
20/1500	3,18	69,50	139,84
30/1500	1,60	67,66	191,09
40/1500	0,70	71,71	457,70
50/1500	0,23	69,68	1366,3
SETE RESERVATÓRIOS (ESTAÇÃO PRIMAVERA)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	8,30	128,27	444,90
20/1500	3,54	103,30	578,69
30/1500	1,38	98,14	779,34
40/1500	0,62	104,97	1187,10
50/1500	0,22	106,79	2042,68
SETE RESERVATÓRIOS (ESTAÇÃO VERÃO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	4,89	72,38	96,28
20/1500	2,29	76,64	140,44
30/1500	1,06	84,44	211,95
40/1500	0,44	85,22	451,87
50/1500	0,14	81,00	1515,40
SETE RESERVATÓRIOS (ESTAÇÃO OUTONO)			
Nº Neurônios/Nº de Iterações	EQtreino	EQteste	Tp (s)
10/1500	14,86	181,40	955,87
20/1500	6,95	194,03	1308,54
30/1500	3,34	179,05	1735,43
40/1500	1,35	171,86	2759,78
50/1500	0,40	168,55	3292,18

Podemos observar que os melhores resultados ocorrem em topologias diferentes.

5.10 – ANÁLISE ESTATÍSTICA DOS MODELOS DE PREVISÃO

Modelos de séries temporais e redes neurais artificiais foram estudados neste trabalho e aplicados ao problema de previsão de demandas horárias. Neste capítulo será feita uma análise estatística dos erros de previsão dos modelos aplicados.

Serão apresentados os resultados dos diferentes modelos de redes neurais que foram implementados, e serão comparados os modelos de RNA's que foram gerados com os dados estratificados em quatro estações (segundo caso), com o modelo de médias móveis e o modelo auto regressivo, gerados com os mesmos dados.

5.10.1 – PRIMEIRO CASO: ESTRATIFICAÇÃO DOS DADOS EM DUAS ESTAÇÕES (RNA 1.1)

O modelo de RNA's foi aplicado ao reservatório Penha sendo, estudado neste caso. Foi feita a análise estatísticas dos resultados calculando-se os *EQM*, *EAM*, *EPM* e *EPmax*., apresentados nas Tabelas 5.40 e 5.41.

Tabela 5.40 – Erro para o Reservatório Penha para o Período Chuvoso

<i>EQM</i>	<i>EAM</i>	<i>EPM</i>	<i>EPmax</i>
163,14	93,87	14,79	949,72

Tabela 5.41 – Erro para o Reservatório Penha para o Período Seco

<i>EQM</i>	<i>EAM</i>	<i>EPM</i>	<i>EPmax</i>
191,28	138,05	21,62	4587,97

Observando as Tabelas 5.40 e 5.41 verificamos, que os erros do período chuvoso são menores que os erros do período seco.

5.10.2 – SEGUNDO CASO: ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES (RNA 1.2)

Neste caso a previsão da demanda horária foi obtida para 7 reservatórios da Alça Leste, tanto para o modelo de RNA's , como para o modelo de médias móveis e auto regressivo, neste item serão comparados os resultados dos três modelos.

5.10.2.1- COMPARAÇÃO DOS MODELOS

Nas tabelas a seguir encontram-se o resultado da análise estatística para os modelos de RNA 1.2 , MM e AR(2) para sete reservatórios da Alça Leste.

Tabela 5.42 – Estatística Para os Modelos de Previsão Para o Reservatório Penha

RESERVATÓRIO PENHA (ESTAÇÃO VERÃO)				
	EQM	EAM	EPM	EPmax
RNA	69,76	52,29	10,10	321,93
MM	98,28	75,74	14,65	334,05
AR(2)	90,17	63,66	12,16	376,52
RESERVATÓRIO PENHA (ESTAÇÃO OUTONO)				
	EQM	EAM	EPM	EPmax
RNA	60,88	45,82	8,36	70,78
MM	91,99	72,95	12,97	40,45
AR(2)	51,53	38,99	7,63	31,66
RESERVATÓRIO PENHA (ESTAÇÃO INVERNO)				
	EQM	EAM	EPM	EPmax
RNA	67,19	48,21	9,07	52,39
MM	87,75	69,67	13,98	41,61
AR(2)	30,14	30,19	6,05	28,4
RESERVATÓRIO PENHA (ESTAÇÃO PRIMAVERA)				
	EQM	EAM	EPM	EPmax
RNA	137,25	80,04	14,06	147,42
MM	110,55	78,60	14,55	101,75
AR(2)	67,78	49,98	10,09	116,52

Tabela 5.43 – Estatística Para os Modelos de Previsão Para o Reservatório Edu Chaves

RESERVATÓRIO EDU CHAVES (ESTAÇÃO VERÃO)				
	EQM	EAM	EPM	EPmax
RNA	94,04	61,92	7,95	535,45
MM	107,30	69,43	9,15	587,70
AR(2)	102,64	70,97	90,70	461,84
RESERVATÓRIO EDU CHAVES (ESTAÇÃO OUTONO)				
	EQM	EAM	EPM	EPmax
RNA	119,35	69,34	8,37	112,06
MM	70,16	54,01	6,42	139,24
AR(2)	74,35	57,21	6,98	97,59
RESERVATÓRIO EDU CHAVES (ESTAÇÃO INVERNO)				
	EQM	EAM	EPM	EPmax
RNA	93,31	70,38	8,79	49,37
MM	73,90	57,45	7,10	51,64
AR(2)	61,06	45,69	5,72	53,61
RESERVATÓRIO EDU CHAVES (ESTAÇÃO PRIMAVERA)				
	EQM	EAM	EPM	EPmax
RNA	144,65	66,06	11,63	479,07
MM	115,77	68,10	8,98	151,02
AR(2)	115,78	61,98	10,12	347,35

Tabela 5.44 – Estatística Para os Modelos de Previsão Para o Reservatório Ermelino Matarazzo

RESERVATÓRIO ERMELINO MATARAZZO (ESTAÇÃO VERÃO)				
	EQM	EAM	EPM	EPmax
RNA	124,87	93,86	11,76	86,97
MM	147,10	114,39	15,19	91,78
AR(2)	126,59	96,58	12,61	70,37
RESERVATÓRIO ERMELINO MATARAZZO (ESTAÇÃO OUTONO)				
	EQM	EAM	EPM	EPmax
RNA	223,33	142,84	18,65	348,58
MM	162,86	126,18	17,02	295,23
AR(2)	143,84	107,72	14,71	325,80
RESERVATÓRIO ERMELINO MATARAZZO (ESTAÇÃO INVERNO)				
	EQM	EAM	EPM	EPmax
RNA	117,10	85,23	12,83	234,81
MM	146,44	115,00	17,21	168,11
AR(2)	129,71	99,78	15,02	162,92
RESERVATÓRIO ERMELINO MATARAZZO (ESTAÇÃO PRIMAVERA)				
	EQM	EAM	EPM	EPmax
RNA	244,02	115,05	15,63	252,77
MM	171,54	120,60	17,29	110,93
AR(2)	134,61	89,96	12,59	73,00

Tabela 5.45 – Estatística Para os Modelos de Previsão Para o Reservatório Cangaíba

RESERVATÓRIO CANGAÍBA (ESTAÇÃO VERÃO)				
	EQM	EAM	EPM	EPmax
RNA	244,20	148,00	30,42	734,28
MM	134,02	106,59	20,11	102,76
AR(2)	118,10	92,44	17,75	107,55
RESERVATÓRIO CANGAÍBA (ESTAÇÃO OUTONO)				
	EQM	EAM	EPM	EPmax
RNA	194,84	118,16	24,08	509,41
MM	146,99	103,82	19,81	229,68
AR(2)	146,39	97,86	19,47	422,47
RESERVATÓRIO CANGAÍBA (ESTAÇÃO INVERNO)				
	EQM	EAM	EPM	EPmax
RNA	109,68	79,52	15,60	148,23
MM	124,77	100,63	21,86	130,69
AR(2)	84,90	66,68	14,47	78,09
RESERVATÓRIO CANGAÍBA (ESTAÇÃO PRIMAVERA)				
	EQM	EAM	EPM	EPmax
RNA	103,68	75,74	15,37	107,41
MM	133,77	106,40	21,88	89,28
AR(2)	99,34	75,56	15,05	101,96

Tabela 5.46 – Estatística Para os Modelos de Previsão Para o Reservatório Gopoúva

RESERVATÓRIO GOPOÚVA (ESTAÇÃO VERÃO)				
	EQM	EAM	EPM	EPmax
RNA	844,15	603,77	27,98	210,50
MM	368,72	281,83	13,31	83,80
AR(2)	429,33	341,66	15,96	152,22
RESERVATÓRIO GOPOÚVA (ESTAÇÃO OUTONO)				
	EQM	EAM	EPM	EPmax
RNA	639,21	474,30	22,09	174,59
MM	349,42	264,17	12,62	106,52
AR(2)	410,36	320,38	15,10	89,28
RESERVATÓRIO GOPOÚVA (ESTAÇÃO INVERNO)				
	EQM	EAM	EPM	EPmax
RNA	464,61	369,52	17,54	105,84
MM	418,83	325,58	15,60	77,06
AR(2)	450,00	354,07	16,52	96,59
RESERVATÓRIO GOPOÚVA (ESTAÇÃO PRIMAVERA)				
	EQM	EAM	EPM	EPmax
RNA	508,07	374,95	17,05	128,94
MM	435,63	335,81	15,45	77,34
AR(2)	444,79	358,66	15,95	106,59

Tabela 5.47 – Estatística Para os Modelos de Previsão Para o Reservatório Jaçanã

RESERVATÓRIO JAÇANÃ (ESTAÇÃO VERÃO)				
	EQM	EAM	EPM	EPmax
RNA	77,81	58,83	8,38	48,04
MM	129,86	102,32	15,18	65,00
AR(2)	84,96	64,81	9,18	39,38
RESERVATÓRIO JAÇANÃ (ESTAÇÃO OUTONO)				
	EQM	EAM	EPM	EPmax
RNA	63,65	45,10	13,54	46,82
MM	118,56	95,27	14,14	55,48
AR(2)	78,34	56,77	8,37	53,33
RESERVATÓRIO JAÇANÃ (ESTAÇÃO INVERNO)				
	EQM	EAM	EPM	EPmax
RNA	115,87	77,13	13,11	306,93
MM	123,64	97,94	16,41	155,92
AR(2)	99,79	77,09	13,13	238,89
RESERVATÓRIO JAÇANÃ (ESTAÇÃO PRIMAVERA)				
	EQM	EAM	EPM	EPmax
RNA	164,78	86,81	12,55	246,18
MM	139,53	106,69	16,59	66,66
AR(2)	95,61	71,49	10,79	69,23

Tabela 5.48 – Estatística Para os Modelos de Previsão Para o Reservatório Jardim Popular

RESERVATÓRIO JARDIM POPULAR (ESTAÇÃO VERÃO)				
	EQM	EAM	EPM	EPmax
RNA	88,95	61,67	20,64	318,11
MM	76,99	58,92	20,94	215,88
AR(2)	70,11	53,14	18,93	217,28
RESERVATÓRIO JARDIM POPULAR (ESTAÇÃO OUTONO)				
	EQM	EAM	EPM	EPmax
RNA	129,46	85,69	33,01	317,27
MM	96,70	59,61	22,12	222,36
AR(2)	98,61	64,34	24,90	276,27
RESERVATÓRIO JARDIM POPULAR (ESTAÇÃO INVERNO)				
	EQM	EAM	EPM	EPmax
RNA	92,00	59,40	29,57	459,55
MM	73,50	59,26	24,35	274,56
AR(2)	58,80	44,75	18,86	229,14
RESERVATÓRIO JARDIM POPULAR (ESTAÇÃO PRIMAVERA)				
	EQM	EAM	EPM	EPmax
RNA	99,02	69,15	24,84	169,38
MM	68,75	49,45	20,62	405,55
AR(2)	67,11	50,89	20,38	249,38

Observando os resultados mostrados nas tabelas anteriores verifica-se que, para as demandas associadas aos sete reservatórios analisados, o modelo de RNA's apresentou melhores resultados na estação do Verão, para quatro dos reservatórios analisados, na estação de Inverno, para o reservatório Ermelino Matarazzo e na estação do Outono, para o reservatório Jaçanã. Para as outras estações o modelo AR(2) mostrou-se mais eficaz, enquanto que o modelo MM não apresentou bons resultados quando comparado com os outros modelos. Uma possível explicação para o melhor desempenho do modelo RNA's na maioria das vezes na estação Verão pode ser formulada com base na variabilidade dos consumos ao longo de cada estação, mostradas na Tabela 5.49. Observa-se que no Verão em alguns dos reservatórios ocorrem coeficientes de variação superiores ou iguais às das demais estações, caracterizando maior grau de variabilidade no comportamento temporal das séries. Em situações de maior grau de variabilidade é que o desempenho da RNA se torna superior em relação aos modelos formulados com base em hipóteses de linearidade (como por exemplo o auto-regressivo).

Tabela 5.49 – Coeficiente de Variação dos Consumos

Estação	<i>Coeficiente de Variação (%) do Consumo de Água ao Longo dos Dias da Estação</i>						
	Penha	Edu Chaves	Ermelino Matarazzo	Cangaíba	Gopoúva	Jaçanã	Jardim Popular
Verão	28	16	29	36	17	28	36
Outono	26	14	31	35	16	28	36
Inverno	28	14	31	39	19	29	40
Primavera	28	15	30	38	20	30	36

Analisando os erros de previsão, para os 7 reservatórios da Alça Leste, para as quatro estações do ano, pode-se notar que para cada reservatório e estação do ano definidos, os valores dos erros de previsão para os modelos testados oscilam muito, isto é, para alguns reservatórios e estações do ano os erros do modelo de RNA são melhores, para outros o modelo AR apresenta resultados melhores. Porém analisando no geral o modelo de previsão AR apresentou melhores resultados para os erros: *EQM*, *EAM*, *EPM* e *Epmax*. As estatísticas para o reservatório Penha são mostradas na Figura 5.37.




Figura 5.37 – Visualização dos EQM, EAM, EPM e EPmax Para RNA, MM e AR Reservatório Penha

5.10.3 – TERCEIRO CASO: ESTRATIFICAÇÃO SAZONAL EM QUATRO ESTAÇÕES E INCLUSÃO DA VARIÁVEL TEMPERATURA (RNA 2.1.1, RNA 2.1.2 e RNA 2.1.3)

Neste caso foi obtida a previsão da demanda média para o reservatório Penha para as quatro estações do ano, pelo modelo de RNA's. Foram processados três variações do modelo com entradas diferentes, e para cada uma delas foram calculados os erros *EQM*, *EAM*, *EPM* e *EPmax*, apresentados nas tabelas abaixo.

Na Tabela 5.50 encontram-se o resultado do tratamento estatísticos, para RNA 2.1.1, que teve como entrada a temperatura média e o consumo médio do dia anterior ao que se quer prever.

Tabela 5.50 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.1.1)

	EQM	EAM	EPM	EPmax
INVERNO	25,07	18,60	3,71	14,34
PRIMAVERA	27,95	23,00	4,06	10,74
VERÃO	19,93	16,28	2,97	8,70
OUTONO	28,51	20,88	3,62	16,11

Na Tabela 5.51 encontram-se o resultado do tratamento estatísticos, para RNA 2.1.2. que teve como entrada a previsão da temperatura média do dia que se quer prever e o consumo médio do dia anterior ao que se quer prever.

Tabela 5.51 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.1.2)

	EQM	EAM	EPM	EPmax
INVERNO	29,32	24,01	4,75	16,01
PRIMAVERA	27,00	22,70	3,99	10,11
VERÃO	19,55	15,98	2,92	8,61
OUTONO	28,07	20,76	3,60	15,99

Na Tabela 5.52 encontram-se o resultado do tratamento estatístico, para RNA 2.1.3, que teve como entrada a temperatura média e o consumo médio do dia anterior ao que se quer prever e o consumo médio do respectivo dia da semana anterior.

Tabela 5.52 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.1.3)

	EQM	EAM	EPM	EPmax
INVERNO	30,44	24,21	4,74	14,36
PRIMAVERA	43,11	36,30	6,30	14,26
VERÃO	20,97	16,10	2,94	10,65
OUTONO	27,83	21,35	3,68	13,50

5.10.4 – QUARTO CASO: ESTRATIFICAÇÃO SAZONAL EM QUATRO ESTAÇÕES SEM INCLUSÃO DA VARIÁVEL TEMPERATURA (RNA 2.2.1)

Neste caso foi obtida a previsão da demanda média para o reservatório Penha para as quatro estações do ano, pelo modelo de RNA's. Foram calculados os erros *EQM*, *EAM*, *EPM* e *EPmax*, apresentados nas tabelas abaixo.

Na Tabela 5.53 encontram-se o resultado do tratamento estatístico, para o modelo que teve como entrada o consumo médio do dia anterior ao que se quer prever e o consumo médio do respectivo dia da semana anterior.

Tabela 5.53 – Estatística para os Modelos de Previsão para o Reservatório Penha (RNA 2.2.1)

	EQM	EAM	EPM	EPmax
INVERNO	34,66	24,57	4,85	20,26
PRIMAVERA	153,96	98,81	17,45	66,14
VERÃO	22,17	17,22	3,13	9,39
OUTONO	28,86	24,65	4,21	11,16

5.10.5 – COMPARAÇÃO ENTRE TERCEIRO E QUARTO CASOS

Neste item estaremos comparando as variações dos modelos de RNA do terceiro caso, os quais tiveram a temperatura como um dos dados de entrada, com o modelo de RNA gerado no quarto caso, sem a inclusão da temperatura. Este último será chamado de RNA 2.2.1.




Figura 5.38 – Visualização dos EQM, EAM, EPM e EPmax Para as variações de RNA Reservatório Penha

Visualizando a Figura 5.38, podemos verificar que a RNA 2.2.1, que possui como dados de entrada somente os valores de consumo, comparados com os outros modelos de RNA, que possuem como entrada valores de consumo e temperatura, apresentou erros maiores.

5.10.6 – QUINTO CASO: PREVISÃO MULTIVARIADA – COM ESTRATIFICAÇÃO SAZONAL DOS DADOS EM QUATRO ESTAÇÕES (RNA 3.1, RNA 3.2 e RNA 3.3)

Nas tabelas a seguir encontram-se o resultado da análise estatística para os modelos RNA's, gerados com a correlação dos reservatórios do sistema de abastecimento chamado Alça

Leste. As Tabelas 5.54, 5.55 e 5.56, mostram os erros para a correlação dos reservatórios dois a dois, com os perfis mais próximos.

Tabela 5.54 – Estatística para os Modelos de Previsão para os Reservatórios Edu Chaves e Gopoúva

	EDU CHAVES				GOPOÚVA			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	761,72	596,62	48,14	359,81	757,09	602,64	54,44	265,16
Primavera	2434,30	209,35	160,03	795,15	2551,37	2200,08	208,90	956,61
Verão	898,46	732,62	55,54	405,27	1003,92	820,42	88,71	425,25
Outono	1428,79	1202,62	82,57	475,38	1435,83	1222,86	114,10	478,18

Tabela 5.55 – Estatística para os Modelos de Previsão para os Reservatórios Cangaíba e Jardim Popular

	CANGAÍBA				JARDIM POPULAR			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	334,64	266,80	86,90	500,29	305,35	252,25	68,54	658,16
Primavera	284,89	215,93	64,59	335,50	273,30	214,86	54,78	434,69
Verão	299,09	215,51	66,83	428,43	248,05	192,03	55,60	562,16
Outono	284,50	217,16	65,85	425,34	254,12	198,95	50,19	327,31

Tabela 5.56 – Estatística para os Modelos de Previsão para os Reservatórios Penha e Jaçanã

	PENHA				JAÇANÃ			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	194,96	156,40	25,25	116,07	163,35	130,35	26,54	162,62
Primavera	207,29	165,00	27,65	91,64	271,08	215,32	39,25	171,91
Verão	166,44	134,14	22,35	92,56	165,71	134,66	25,89	117,96
Outono	185,41	133,33	19,56	108,09	183,40	153,20	26,72	146,06

A Tabela 5.57 traz os coeficientes de variação do consumo de água para os dados de entrada para cada dupla de reservatórios acima correlacionados.

Tabela 5.57 – Coeficientes de Variação

	Coeficiente de Variação (%) do Consumo de Água ao Longo dos Dias da Estação		
	Edu Chaves e Gopoúva	Cangaíba e Jardim Popular	Penha e Jaçanã
Inverno	50,48	48,43	30,05
Primavera	54,64	47,80	30,66
Verão	52,25	46,66	30,40
Outono	47,93	46,93	28,39

As Tabelas 5.58, 5.59 e 5.60 mostram os erros para a correlação dos reservatórios dois a dois, com os perfis de consumo diferentes.

Tabela 5.58 – Estatística para os Modelos de Previsão para os Reservatórios Penha e Edu Chaves

	PENHA				EDU CHAVES			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	326,33	268,25	40,53	156,79	310,25	252,02	46,22	274,60
Primavera	273,32	235,96	34,65	125,27	309,47	246,39	42,91	184,39
Verão	319,94	238,51	33,39	242,97	318,96	260,07	43,84	185,08
Outono	431,44	333,25	45,76	273,73	556,27	441,65	72,89	354,24

Tabela 5.59 – Estatística para os Modelos de Previsão para os Reservatórios Gopoúva e Cangaíba

	GOPOÚVA				CANGAÍBA			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	817,79	662,46	89,51	705,34	969,02	763,76	92,88	946,55
Primavera	1984,73	1631,13	256,62	2090,59	1849,19	1506,78	141,36	1012,09
Verão	1248,84	1007,87	144,87	914,38	1273,29	1033,61	108,26	784,27
Outono	1468,75	1180,89	171,63	990,50	1554,32	1255,63	1257,04	1422,92

Tabela 5.60 – Estatística para os Modelos de Previsão para os Reservatórios Jardim Popular e Jaçanã

	JARDIM POPULAR				JAÇANÃ			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	312,84	251,16	70,86	818,58	306,51	245,35	74,08	637,99
Primavera	333,21	276,64	55,47	391,48	352,41	300,77	89,08	450,92
Verão	205,23	161,56	43,31	413,48	183,78	142,71	57,61	698,49
Outono	1494,90	1238,81	185,52	1372,45	1563,46	1300,35	121,18	1626,96

A Tabela 5.61 traz os coeficientes de variação do consumo de água para os dados de entrada para cada dupla de reservatórios acima correlacionados.

Tabela 5.61 – Coeficientes de Variação

	Coeficiente de Variação (%) do Consumo de Água ao Longo dos Dias da Estação		
	Penha e Edu Chaves	Gopoúva e Cangaíba	Jardim Popular e Jaçanã
Inverno	29,70	67,37	50,14
Primavera	27,40	68,77	51,51
Verão	28,11	65,35	49,96
Outono	26,28	62,23	50,06

Comparando os dois casos apresentados, podemos verificar que os melhores resultados ocorrem para os dados de entrada com coeficiente menor de variação.

As tabelas a seguir mostram a análise estatística para os sete reservatórios da rede correlacionados juntos.

Tabela 5.62 – Estatística para os Modelos de Previsão para os Sete Reservatórios da Rede

	PENHA				CANGAÍBA			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	301,21	247,03	38,95	158,92	263,19	215,99	30,78	92,76
Primavera	311,20	257,87	38,45	115,14	243,78	197,72	29,87	135,77
Verão	387,65	322,03	43,71	157,62	282,95	235,34	31,92	121,24
Outono	343,47	285,72	40,17	167,23	256,24	214,54	29,24	126,25
	JARDIM POPULAR				ERMELINO MATARAZZO			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	932,09	642,33	46,56	95,62	1260,60	507,77	180,07	1853,69
Primavera	863,87	511,33	36,84	98,59	1328,35	1111,88	78,27	586,69
Verão	845,97	527,21	37,70	112,40	1401,67	1184,00	79,55	419,67
Outono	798,16	544,42	40,64	98,73	1169,33	1007,68	73,73	447,65
	JAÇANÃ				EDU CHAVES			
	EQM	EAM	EPM	EPmax	EQM	EAM	EPM	EPmax
Inverno	763,96	595,57	145,59	897,08	637,27	507,77	180,07	1853,69
Primavera	872,59	692,86	163,01	856,14	630,86	482,60	156,62	2415,65
Verão	824,43	679,62	132,42	641,65	600,02	499,06	156,98	1057,57
Outono	725,00	568,78	110,97	641,75	663,65	504,13	141,36	1371,35
	GOPOÚVA							
	EQM	EAM	EPM	EPmax				
Inverno	1216,13	1040,92	342,87	1960,85				
Primavera	1095,37	836,44	247,34	1316,75				
Verão	1027,77	800,93	234,33	970,25				
Outono	1077,50	914,72	257,96	1321,58				

Tabela 5.63 – Coeficiente de Variação

	<i>Coeficiente de Variação (%) do Consumo de Água ao Longo dos Dias da Estação</i>
	Todos os Reservatórios
Inverno	71,62
Primavera	81,34
Verão	77,00
Outono	78,38

5.10.7 – COMPARAÇÃO ENTRE O SEGUNDO CASO COM A PREVISÃO MULTIVARIADA

Neste item estão comparados os resultados obtidos no segundo caso (RNA 1.2), que obteve a previsão da demanda horária para sete reservatórios da Alça Leste, para cada um separadamente, caracterizando assim uma previsão univariada, com os resultados obtidos no quinto caso (RNA 3.1, RNA 3.2 e RNA 3.3), que obteve a previsão horária para os reservatórios, correlacionando-os dois a dois e sete reservatórios da rede, caracterizando assim uma previsão multivariada. As figuras a seguir mostram graficamente estas comparações, observando o gráfico que dos coeficientes de variação, verificamos que quanto menor a variação dos dados de entrada, melhor o resultado produzido pelo modelo de RNA. O segundo caso de previsão univariada, produz melhores resultados que os modelos gerados no quinto caso, devido a variação menor dos dados de entrada. Comparando as Tabelas 5.57, 5.61 e 5.63, podemos chegar a esta conclusão.

Para comparação dos resultados graficamente, foram escolhidos os reservatórios Penha e Jaçanã.




Figura 5.39 – EQM e Coeficientes de Variação para o Reservatório Penha (RNA 3.1, RNA 3.2, RNA 3.3 e RNA 1.2)




Figura 5.40 – EQM e Coeficientes de Variação para o Reservatório Jaçanã (RNA 3.1, RNA 3.2, RNA 3.3 e RNA 1.2)

5.11 – IMPACTO DA PREVISÃO DE DEMANDA NO DESEMPENHO OPERACIONAL DE UM SISTEMA DE ABASTECIMENTO

Para ilustrar a utilização das previsões fornecidas pelos modelos numa situação bem próxima da real e para avaliar comparativamente o desempenho do modelo de RNA frente ao modelo de MM e a previsão perfeita (demanda observada), em termos de resultados de interesse operacional, incluindo consumo de energia elétrica para bombeamento, foi o que levou a inclusão deste item no estudo de caso. Foi analisada uma rede hipotética estudada por ALMEIDA (2001), Figura 5.41.

A rede possui dois reservatórios de montante que são alimentados por uma ETA (Estação de Tratamento de Água) com as respectivas vazões $QA_{1,t}$ e $QA_{2,t}$. Ambos reservatórios possuem válvulas controladoras de vazão (do tipo borboleta) em suas saídas.

A rede também apresenta uma estação de bombeamento tipo *booter* que visa garantir pressões operacionais através de uma bomba de rotação variável. Paralela a estação tipo *booster* existe um *By-Pass*, com as mesmas características do trecho em que a bomba se encontra instalada, através do qual ocorre o escoamento, quando a bomba do *booster* 1 é eventualmente desligada.

O modelo hidráulico de otimização proposto no presente neste estudo, será aplicado um sistema de distribuição de água tendo como objetivo a determinação das políticas operacionais que minimizem o consumo de energia elétrica associado às operações de bombeamento de água realizadas por uma estação de bombeamento do tipo *booster*. Serão avaliadas as influências das condições iniciais do sistema (os níveis dos reservatórios) para a obtenção de políticas operacionais que conduzam a um menor consumo de energia elétrica por parte da estação tipo *booster*.

A solução do modelo hidráulico de otimização que compõe um problema de programação não-linear inteira mista de grande escala, será obtida através de uma Linguagem de Programação Algébrica, o *software* GAMS (*General Algebraic Modeling System*) associando-se o *solver*

CONOPT (*Continuous Optimizer*), que utiliza o algoritmo do Gradiente Reduzido Generalizado, com o *solver* SBB (*Standard Branch and Bound*) que utiliza o algoritmo da Ramificação e Limite.




Figura 5.41 – Rede Hipotética

5.11.1 – FORMULAÇÃO DO MODELO HIDRÁULICO DE OTIMIZAÇÃO

A formulação do modelo hidráulico de otimização tem como estrutura básica a forma clássica dos problemas de otimização determinísticas restrita, sendo composto por uma função objetivo sujeita a um conjunto de restrições.

Minimizar ou maximizar uma função objetivo sujeita a:

$$\mathbf{g}(\mathbf{x}) = 0 \quad (5.8a)$$

$$\underline{x} \leq x \leq \bar{x} \quad (5.8b)$$

Para o caso particular da operação de sistemas de distribuição de água, a função objetivo representa um critério de performance que, em função do contexto em que o sistema de distribuição de água se encontra inserido, pode assumir uma série de formulações. Como por exemplo: minimização das pressões, minimização dos déficits de atendimento às demandas, minimização dos custos associados ao bombeamento de água, etc. O conjunto de restrições, composto por uma série de equações e/ou inequações matemáticas, representa a operação do sistema de distribuição de água e de seus elementos, sendo composto pelas seguintes relações: (a) conservação da massa; (b) conservação da energia; (c) regime de operação dos elementos do sistema de distribuição de água (como por exemplo: válvulas, bombas, reservatórios, etc); (d) limitações operacionais do sistema de distribuição de água e de seus elementos (limitação das velocidades nas tubulações; das pressões, das aberturas das válvulas, dos níveis dos reservatórios, etc).

Considerando um sistema de distribuição de água composto por NN nós, NT tubos, NB bombas, NV válvulas controladoras de vazão, NR reservatórios de montante abastecidos diretamente por uma ETA (Estação de Tratamento de Água) e um horizonte de operação NP dividido em períodos de tempos t , iguais e sequenciais, a formulação matemática para o problema de operação ótima pode ser dada como:

Minimizar:

$$\sum_{t=1}^{NP} F_t \quad (5.9)$$

Sujeito a:

Conservação da massa:

$$\left[\sum_{j \in \Psi_i} QT_{j,t} = QD_{i,t} \right]_{i,t} \quad i = 1, NN; t = 1, NP \quad (5.10)$$

Conservação da energia:

$$\left[CG_{i+1,t} + P_{i+1,t} = CG_{i,t} + P_{i,t} - PC_{j,t} + HMB_{b,t} \cdot X_{b,t} - PCV_{v,t} \right]_{j,i \in j, b \in \Psi_{jb}, v \in \Psi_{jv}, t} \\ j = 1, NT; t = 1, NP \quad (5.11)$$

Altura manométrica das bombas:

$$\left[HMB_{b,t} (C_{0b}, C_{1b}, C_{2b}, QT_{j,t}, N_{Nb}, N_{b,t}) \right]_{b, j \in \Psi_{b,t}} \quad b = 1, NB; t = 1, NP \quad (5.12)$$

Rendimento das bombas:

$$\left[\eta_{b,t} (C_{3b}, C_{4b}, QT_{j,t}, N_{Nb}, N_{b,t}) \right]_{b, j \in \Psi_{b,t}} \quad b = 1, NB; t = 1, NP \quad (5.13)$$

Regime de operação das válvulas controladoras de vazão:

$$\left[PCV_{v,t} = \frac{8 \cdot QT_{j,t} \cdot |QT_{j,t}|}{g \cdot \pi^2 \cdot D_j^2} \cdot Ks_{v,t}(\theta_{v,t}) \right]_{v,j \in \Psi_{v,t}} \quad v = I, NV; t = I, NP \quad (5.14)$$

Regime de operação dos reservatórios de montante:

$$\left[HR_{k,t+1} = HR_{k,t} + (QA_{k,t} - QT_{j,t}) \cdot \frac{\Delta t}{SB_k} \right]_{k,j \in \Psi_{k,t}} \quad k = I, NR; t = I, NP \quad (5.15)$$

Recuperação dos níveis iniciais dos reservatórios de montante no final do horizonte:

$$\left[HR_{k,NP+1} = HR_{k,I} \right]_k \quad k = I, NR \quad (5.16)$$

Manutenção das cargas dos reservatórios de montante entre valores limites:

$$\left[HR_{\min k} \leq HR_{k,t} \leq HR_{\max k} \right]_{k,t} \quad k = I, NR; t = I, NP \quad (5.17)$$

Manutenção das pressões entre valores limites:

$$\left[P_{\min i} \leq P_{i,t} \leq P_{\max i} \right]_{i,t} \quad i = I, NN; t = I, NP \quad (5.18)$$

Manutenção das velocidades nos trechos entre valores limites:

$$\left[V_{\min j} \cdot \frac{\pi \cdot D_j^2}{4} \leq QT_{j,t} \leq V_{\max j} \cdot \frac{\pi \cdot D_j^2}{4} \right]_{j,t} \quad j = I, NT; t = I, NP \quad (5.19)$$

Manutenção das alturas manométricas entre valores limites:

$$\left[HMB_{\min b} \leq HMB_{b,t} \leq HMB_{\max b} \right]_{b,t} \quad b = I, NB, t = I, NP \quad (5.20)$$

Manutenção das aberturas das válvulas entre valores limites:

$$\left[\theta_{\min_v} \leq \theta_{v,t} \leq \theta_{\max_v} \right]_{v,t} \quad v = I, NV, t = I, NP \quad (5.21)$$

Manutenção dos rendimentos das bombas acima de um valor limite:

$$\left[\eta_{\min_b} \leq \eta_{b,t} \right]_{b,t} \quad b = I, NB, t = I, NP \quad (5.22)$$

Manutenção das rotações das bombas entre valores limites (para o caso de bombas com rotação variável):

$$\left[N_{\min_b} \leq N_{b,t} \leq N_{\max_b} \right]_{b,t} \quad b = I, NB, t = I, NP \quad (5.23)$$

A perda de carga para cada trecho da rede é calculada pela fórmula empírica de Hazen-Williams:

$$PC_{j,t} = 10,65 \cdot \frac{QT_{j,t} \cdot |QT_{j,t}|^{0,85}}{C_j^{1,85} \cdot D_j^{4,87}} \cdot L_j \quad (5.24)$$

A solução fornecida pelo modelo hidráulico de otimização é obtida através da aplicação das equações acima para cada intervalo discreto do horizonte de operação, de maneira sequencial no tempo. As variáveis de decisão do modelo hidráulico de otimização, obtidas para cada intervalo de tempo do horizonte de operação, são:

- Vazões nos trechos;
- Pressões nos nós;
- Vazão, altura manométrica, rendimento hidráulico, condição operacional (liga/desliga) e rotação (quando a bomba for de rotação variável) das bombas;
- Cargas nos reservatórios;

- Abertura geométrica ou área reduzida das válvulas,

Para o caso de $N_{N_b} = N_{b,t}$ para todo $t \in NP$, a bomba é considerada como sendo de rotação fixa, caso contrário, é considerada como uma bomba de rotação variável.

A variável binária presente na Equação (5.18) tem como função definir as condições operacionais de acionamento e desligamento das bombas (onde $X=1$ representa que as bombas estão em funcionamento e $X=0$ que as bombas estão desligadas), possibilitando, desta forma, simular o escoamento através de um *by-pass* quando as bombas se encontram desligadas.

A reversão do fluxo no escoamento é garantida pela função módulo presente nas Equações 5.14 e 5.19 (o que torna o modelo hidráulico de otimização descontínuo). Para os trechos da rede em que não é permitida tal reversão, o sentido da vazão é adotado como fixo e esta como uma variável positiva, dispensando, assim, o uso da função módulo.

Os sucessivos níveis dos reservatórios fornecidos pela Equação (5.15) ao final de cada período t , garantem a conexão temporal ao longo de todo o horizonte de operação, possibilitando, desta forma, o modelo realizar uma análise não míope em período extensivo.

Uma outra característica da formulação apresentada para o modelo hidráulico de otimização, é que todas as relações que definem o escoamento no sistema (conservação da massa e conservação da energia) e o modo de operação de seus elementos (válvulas, bombas e reservatórios) estão incorporadas no conjunto de restrições, dispensando, deste modo, a criação de uma estrutura híbrida entre um simulador hidráulico e um algoritmo de otimização usualmente utilizada por muitos autores (BRION e MAYS, 1991; ORMSBEE e REDDY, 1995; PERZESHK e HELWEG, 1996; SAKARYA e MAYS, 2000).

5.11.2 – TÉCNICA DE SOLUÇÃO DO MODELO HIDRÁULICO DE OTIMIZAÇÃO

O modelo hidráulico de otimização proposto compõe um problema de programação não-linear inteira mista de grande escala devido à presença de não-linearidades associadas ao

processo (Equações 5.11, 5.12, 5.13 e 5.14) e a presença de uma variável binária (Equação (5.11)), cuja função é simular as condições operacionais de acionamento e desligamento das bombas.

Na Figura 5.42 é apresentada a estrutura utilizada pelo *software* GAMS para a solução do modelo hidráulico de otimização proposto.




Figura 5.42 – Estrutura de Solução Apresentada pelo Software GAMS

A Figura 5.43 apresenta os perfis de demanda ao qual o sistema está submetido, e que é aplicado a todos os nós com demandas (nós nº 5, 6, 11, 14 e 15). Estes perfis foram chamados de $QD_{1,t}$ na equação da conservação da massa (Equação (5.10)).




Figura 5.43 – Curvas de Modulação de Demanda

Em uma primeira etapa não foi fixado o nível inicial dos reservatórios, e o modelo obteve a política ótima de operação para as três curvas de demanda. Os resultados obtidos para a política de operação em um horizonte de 24 horas, foram relativos à potência da bomba, à operação das válvulas, ao nível dos reservatório e às vazões de entrada.




Figura 5.44 – Potencia da Bomba




Figura 5.45 – Operação da Válvula 1




Figura 5.46 – Operação da Válvula 2




Figura 5.47 – Níveis de Operação para o Reservatório 1




Figura 5.48 – Níveis de Operação para o Reservatório 2




Figura 5.49 – Vazões QA1 de Entrada




Figura 5.50 – Vazões QA2 de Entrada

Depois de analisados os resultados da primeira etapa, decidiu-se executar o modelo fixando o nível inicial dos reservatórios. A políticas operacionais apresentadas nas figuras a seguir e nas Tabelas 5.64, 5.65 e 5.66 foram obtidas para as curvas de modulação de demanda real e previstas por redes neurais e médias móveis. Para os três casos, os níveis iniciais (às 00:00 horas) dos reservatórios 1 e 2 foram fixados em 731 m e 729,507m respectivamente. Tais níveis foram obtidos a partir de um modelo hidráulico de otimização utilizando a curva real de demanda e estabelecendo que estes devem ser alcançados no final do horizonte de operação (24 horas). Neste estudo também foram obtidas as políticas de operação para a bomba, as válvulas, os reservatórios e para as vazões de entrada do sistema.

O objetivo de fixar o nível dos reservatórios no nível determinado pela curva de demanda real foi verificar, se mantido um nível operacional ótimo para a curva real, qual seria o comportamento do sistema para as previsões realizadas por RNA e MM.




Figura 5.51 – Regime de Operação da ETA (Vazão QA_1)




Figura 5.52 – Regime de Operação da ETA (Vazão QA_2)




Figura 5.53 – Abertura da Válvula 1




Figura 5.54 – Abertura da Válvula 2




Figura 5.55 – Regime de Operação da Bomba de Booster 1 (Rotação)




Figura 5.56 – Volumes Úteis do Reservatório 1




Figura 5.57 – Volumes Úteis do Reservatório 2

Tabela 5.64 – Pontos de Operação da Bomba do Booster 1.

Tempo (h)	Real				Previsão RNA				Previsão MM			
	Status	QB (m³/s)	HMB (m)	N (rpm)	Status	QB (m³/s)	HMB (m)	N (rpm)	Status	QB (m³/s)	HMB (m)	N (rpm)
1	Off	-	-	-	Off	-	-	-	Off	-	-	-
2	Off	-	-	-	Off	-	-	-	Off	-	-	-
3	Off	-	-	-	Off	-	-	-	Off	-	-	-
4	Off	-	-	-	Off	-	-	-	Off	-	-	-
5	Off	-	-	-	Off	-	-	-	Off	-	-	-
6	Off	-	-	-	Off	-	-	-	Off	-	-	-
7	Off	-	-	-	Off	-	-	-	Off	-	-	-
8	Off	-	-	-	Off	-	-	-	Off	-	-	-
9	On	0,38	6,39	450	Off	-	-	-	Off	-	-	-
10	On	0,38	6,37	450	On	0,30	8,15	450	Off	-	-	-
11	On	0,39	6,67	459	On	0,33	7,54	450	On	0,27	8,71	450
12	On	0,41	8,45	507	On	0,42	8,84	516	On	0,37	6,68	450
13	On	0,38	6,43	450	On	0,37	6,67	450	On	0,38	6,37	450
14	On	0,38	6,41	450	On	0,37	6,58	450	On	0,39	7,00	468
15	On	0,38	6,39	450	On	0,37	6,50	450	On	0,38	6,48	453
16	On	0,38	6,38	450	On	0,38	6,42	450	On	0,38	6,37	450
17	On	0,26	8,77	450	Off	-	-	-	On	0,30	8,13	450
18	Off	-	-	-	Off	-	-	-	On	0,38	6,37	450
19	Off	-	-	-	Off	-	-	-	On	0,25	9,00	450
20	Off	-	-	-	Off	-	-	-	Off	-	-	-
21	Off	-	-	-	Off	-	-	-	Off	-	-	-
22	Off	-	-	-	Off	-	-	-	Off	-	-	-
23	Off	-	-	-	Off	-	-	-	Off	-	-	-
24	Off	-	-	-	Off	-	-	-	Off	-	-	-

Tabela 5.65 – Potência Hidráulica Consumida em 24 horas pela Bomba do Booster 1.

Tempo (h)	Real			Previsão RNA			Previsão MM		
	Status	PH (kW)	PH acum. (kW)	Status	PH (kW)	PH acum. (kW)	Status	PH (kW)	PH acum. (kW)
1	Off	-	-	Off	-	-	Off	-	-
2	Off	-	-	Off	-	-	Off	-	-
3	Off	-	-	Off	-	-	Off	-	-
4	Off	-	-	Off	-	-	Off	-	-
5	Off	-	-	Off	-	-	Off	-	-
6	Off	-	-	Off	-	-	Off	-	-
7	Off	-	-	Off	-	-	Off	-	-
8	Off	-	-	Off	-	-	Off	-	-
9	On	23,74	23,74	Off	-	-	Off	-	-
10	On	23,67	47,41	On	23,63	23,63	Off	-	-
11	On	25,18	72,59	On	24,08	47,71	On	22,63	22,63
12	On	34,20	106,80	On	36,14	83,85	On	23,97	46,59
13	On	23,76	130,56	On	23,97	107,83	On	23,67	70,27
14	On	23,75	154,30	On	23,91	131,73	On	26,74	97,01
15	On	23,74	178,04	On	23,81	155,54	On	24,21	121,22
16	On	23,68	201,72	On	23,73	179,27	On	23,66	144,88
17	On	22,43	224,15	Off	-	179,27	On	23,59	168,47
18	Off	-	224,15	Off	-	179,27	On	23,71	192,19
19	Off	-	224,15	Off	-	179,27	On	21,87	214,06
20	Off	-	224,15	Off	-	179,27	Off	-	214,06
21	Off	-	224,15	Off	-	179,27	Off	-	214,06
22	Off	-	224,15	Off	-	179,27	Off	-	214,06
23	Off	-	224,15	Off	-	179,27	Off	-	214,06
24	Off	-	224,15	Off	-	179,27	Off	-	214,06

Tabela 5.66 – Regime de Operação das Válvulas.

Tempo (h)	Real				Previsão RNA				Previsão MM			
	θ_1 (°)	k_1	θ_2 (°)	k_2	θ_1 (°)	k_1	θ_2 (°)	k_2	θ_1 (°)	k_1	θ_2 (°)	k_2
1	51,681	5,96	44,194	13,84	68,738	1,28	44,852	12,78	61,386	2,36	54,513	4,47
2	63,286	2,00	34,61	51,62	81	0,53	43,093	15,86	56,628	3,64	53,227	5,09
3	66,123	1,58	38,036	31,05	81	0,53	40,852	21,14	55,442	4,08	44,662	13,08
4	81	0,53	29,074	131,93	72,256	0,98	37,046	35,79	18	1743,76	81	0,53
5	81	0,53	30,343	104,82	18	1743,76	71,669	1,02	48,372	8,51	35,271	46,62
6	60,108	2,64	33,839	58,27	67,192	1,45	39,543	25,19	81	0,53	35,635	44,11
7	62,425	2,16	41,038	20,63	22,776	491,14	73,85	0,87	81	0,53	38,274	30,03
8	75,382	0,78	54,258	4,59	59,605	2,77	51,434	6,12	81	0,53	46,448	10,59
9	81	0,53	57,101	3,48	81	0,53	81	0,53	81	0,53	81	0,53
10	81	0,53	64,86	1,75	37,158	35,21	81	0,53	81	0,53	72,385	0,97
11	81	0,53	80,565	0,55	41,192	20,22	81	0,53	34,34	53,84	81	0,53
12	81	0,53	81	0,53	81	0,53	81	0,53	81	0,53	78,012	0,65
13	81	0,53	76,824	0,71	81	0,53	69,963	1,17	81	0,53	78,728	0,62
14	81	0,53	72,587	0,96	81	0,53	72,066	0,99	81	0,53	81	0,53
15	81	0,53	58,661	3,01	81	0,53	64,003	1,88	81	0,53	80,856	0,54
16	81	0,53	49,861	7,23	81	0,53	53,857	4,77	81	0,53	65,163	1,71
17	33,359	62,93	81	0,53	81	0,53	81	0,53	36,94	36,34	81	0,53
18	81	0,53	81	0,53	74	0,86	70,515	1,12	81	0,53	52,42	5,52
19	81	0,53	63,476	1,97	81	0,53	81	0,53	32,73	69,72	81	0,53
20	81	0,53	64,716	1,78	81	0,53	64,263	1,84	81	0,53	77,58	0,67
21	50,048	7,08	81	0,53	81	0,53	62,722	2,10	81	0,53	67,258	1,44
22	41,425	19,61	81	0,53	81	0,53	58,26	3,13	81	0,53	68,248	1,33
23	34,949	48,98	81	0,53	35,104	47,82	81	0,53	76,93	0,70	66,163	1,58
24	75,809	0,76	60,154	2,63	81	0,53	49,475	7,54	81	0,53	61,133	2,41

5.12 – SIMULAÇÃO DA POLÍTICA ÓTIMA DE OPERAÇÃO

O objetivo deste item é verificar se as políticas operacionais obtidas a partir das curvas de demanda prevista por redes neurais artificiais e médias móveis, quando implementadas na rede de distribuição sob ação da curva de demanda real, serão possíveis de serem implementadas.

Quando se fala de políticas operacionais, se fala em: (a) abertura das válvulas 1 e 2; (b) modo de operação (ligado ou desligado) e rotação da bomba do *Booster* 1; (c) vazões QA_1 e QA_2 da ETA que abastece a rede de distribuição.

Para verificar a possibilidade de implementação das políticas operacionais acima citadas, utilizar-se-á o simulador hidráulico EPANET 2.0 (EPA, 2000), fixando as políticas operacionais obtidas pelo modelo hidráulico de otimização com base nas curvas de demanda previstas, por redes neurais artificiais e médias móveis. A curva de demanda que é fixada no simulador hidráulico EPANET é a curva real de demanda, justamente para verificar a possibilidade de implementação das políticas operacionais obtidas a partir das curvas de demanda previstas

5.12.1 – RESULTADOS DAS VERIFICAÇÕES

Foram implementadas as políticas operacionais geradas com base na curva de demanda prevista por RNA's e MM.

5.12.1.1 – IMPLEMENTAÇÃO PARA RNA

Como a curva de demanda prevista por RNA é bem próxima a curva real, as políticas operacionais geradas com base na curva de previsão por RNA e implementadas no simulador hidráulico EPANET sob ação da curva real de demanda, conduziu a resultados satisfatórios, mas que merecem algumas observações:

1) No modelo hidráulico de otimização o limite mínimo permitido para as pressões nos nós da rede de distribuição era de 5 m.c.a.. As políticas operacionais obtidas a partir da curva de demanda prevista por RNA, implementadas no simulador hidráulico EPANET sob ação da curva real de demanda, conduz a valores de pressão inferiores a 5 m.c.a. em alguns nós para determinados períodos do horizonte de operação. A tabela a seguir mostra estes nós.

Tabela 5.67 – Pressões Abaixo do Limite de 5 m.c.a. para as Políticas Operacionais Obtidas a partir da Curva de Demanda Prevista por RNA.

Nó	Pressão (m.c.a.)	Horário
4	4,75	07:00
4	4,02	08:00
4	3,43	09:00
4	2,94	10:00
8	4,79	10:00
4	2,15	11:00
8	3,71	11:00
9	4,81	11:00
11	4,55	11:00
4	3,80	12:00
8	4,66	12:00
11	4,60	12:00
4	2,84	13:00
8	4,06	13:00
9	4,94	13:00
11	4,26	13:00
4	3,30	14:00
8	4,54	14:00
11	4,68	14:00
4	4,10	15:00
4	4,46	16:00
4	3,50	17:00
4	3,32	18:00
4	4,33	19:00
4	3,67	20:00
4	3,24	21:00
4	3,31	22:00
4	3,63	23:00

2) As políticas operacionais obtidas a partir da curva de demanda prevista por RNA, implementadas no simulador hidráulico EPANET sob ação da curva real de demanda, conduz a um pressão relativa negativa na saída da Válvula 1 a jusante do Reservatório 1. O valor da pressão relativa é de: -0,7 m.c.a. às 07:00 horas; -2,60 m.c.a. às 10:00 horas; e -0,68 m.c.a. às 11:00 horas. O caso real (políticas operacionais ótimas com base na curva real de demanda), só conduz a um valor de pressão negativa na saída da Válvula 1, que é de -3,76 m.c.a. às 17:00 horas.

Tais políticas operacionais conduzem a um potência hidráulica consumida pela bomba do *Booster 1* , apresentada na Tabela 5.68.

Tabela 5.68 – Potência Hidráulica Consumida pela Bomba do Booster 1 para as Políticas Operacionais Obtidas a partir da Curva de Demanda Prevista por RNA.

Horário	Vazão (l/s)	Altura Manométrica (m)	Potência Hidráulica (kW)
10:00	311,06	7,88	24,02
11:00	348,29	7,11	24,27
12:00	422,31	8,78	36,34
13:00	382,99	6,34	23,80
14:00	379,58	6,42	23,88
15:00	372,42	6,58	24,01
16:00	371,40	6,61	24,06
Total Consumido em 24 horas (kW)			180,38

3) Deve-se observar que as políticas implementadas na rede de distribuição, com base na previsão por RNA, conduz a um consumo de potência hidráulica na bomba do *Booster 1*, de 180 kW em 24 horas, menor que no caso real (Tabela 5.65), de 224,15 kW em 24 horas. Mas em compensação, a rede de distribuição não opera mantendo os níveis de pressão mínima (de 5 m.c.a.) em vários períodos do horizonte de operação (Tabela 5.67). Se o critério de pressão mínima nos nós da rede não for um critério de grande relevância, tais políticas podem ser implementadas na rede sem grandes problemas.

Nas Figuras 5.58 e 5.59 são apresentados os volumes úteis dos Reservatórios 1 e 2 para o caso real (políticas operacionais ótimas para a curva real de demanda) e o caso onde se utilizam as políticas operacionais, obtidas com base na curva prevista por RNA. Observa-se que ambos os reservatórios tendem a esvaziar no final do horizonte, indicando a necessidade de se realizar alterações em tais políticas para tentar chegar ao final do horizonte com uma capacidade maior de reservação.




Figura 5.58 – Volumes Úteis do Reservatório 1 (Comparação).




Figura 5.59 – Volumes Úteis do Reservatório 2 (Comparação).

5.12.1.2 – IMPLEMENTAÇÃO PARA MM

Como a previsão de demanda realizada pelo modelo de médias móveis, apresentou valores de erros bastante expressivos, as políticas operacionais geradas com base na curva de previsão por MM e implementadas no simulador hidráulico EPANET sob ação da curva real de demanda, conduziram a resultados não muito satisfatórios e que não são possíveis de implementação. Um exemplo é para a 09:00 horas, onde as políticas operacionais obtidas com base na curva de previsão por MM, geram valores de pressão negativa em vários pontos da rede sendo esse o horário mais crítico. Dentre esse valores de pressão negativa, o nó 4 apresenta o maior valor, de -10,57 m.c.a., superando o valor de -10,09 m.c.a. que é o valor máximo de pressão negativa para não ocorrer vaporização da água ao nível mar, isso indicaria um fenômeno de separação de coluna. Em resumo, as políticas operacionais obtidas com base na curva de demanda prevista por MM não são possíveis de implementação na rede sob ação da curva real de demanda.

6 – CONCLUSÕES E RECOMENDAÇÕES

Como contribuição para o estudo da previsão de demanda de água em sistemas urbanos de abastecimento, foi proposto neste trabalho um modelo de redes neurais artificiais (RNA's), capaz de produzir a previsão univariada e multivariada da demanda de água, com discretização horária e diária. Tal modelo foi estruturado de forma a conter uma camada de entrada, uma camada intermediária e uma camada de saída.

Os estudos foram concentrados no subsistema localizado no Estado de São Paulo, na região metropolitana, denominado Alça Leste, constituído de oito reservatórios, dos quais sete deles foram estudados, a saber: Jaçanã, Edu Chaves, Gopoúva, Penha, Cangaíba, Jardim Popular e Ermelino Matarazzo.

O modelo de RNA's usou um algoritmo de otimização chamado gradiente conjugado escalonado proposto por MOLLER (1993), sendo adotada como função objetivo o erro quadrático médio (EQM) e tendo como dados de entrada valores de demanda e temperatura.

Para comparar os resultados obtidos com o modelo de RNA, que sofreu diversas variantes segundo os dados de entrada e resposta produzida, foram também estudados os modelos de médias móveis e auto regressivo.

O modelo de médias móveis previu as demandas para sete reservatórios da Alça Leste, com período de recorrência de 3 dias, período esse usado por apresentar menor erro. Um modelo AR(2) foi escolhido por ser mais parcimonioso. Após, foram feitas comparações dos resultados obtidos através da análise dos erros quadrático médio, absoluto médio, percentual médio e percentual máximo.

A primeira etapa do trabalho foi fazer a previsão da demanda horária, para cada reservatório separadamente, caracterizando a previsão univariada. Com a finalidade de estudar a relação existente entre as variáveis envolvidas na previsão (demanda e temperatura), é que calculou-se o coeficiente de correlação que indicou o grau de intensidade da correlação entre as variáveis correlacionadas, sendo usado para tanto o coeficiente de Pearson.

Esperava-se uma correlação forte entre o consumo e a temperatura, mas isso não se verificou, pois existem outras variáveis independentes que afetam a variável dependente, que é o consumo de água (dia da semana, eventos, época do ano, frentes quentes, frentes frias etc.)

Na primeira proposta, estudaram-se quatro casos. O primeiro caso (RNA 1.1) e o segundo caso (RNA 1.2), produziram a previsão de demanda para as 24 horas do dia, o terceiro caso (RNA 2.1.1, RNA 2.1.2 e RNA 2.1.3) e o quarto caso (RNA 2.2.1), produziram a previsão da demanda média diária, os quais apresentaram resultados aceitáveis para a previsão da demanda. Nota-se uma dificuldade na previsão de demandas devido à presença da sazonalidade inerente aos períodos úmidos e secos do ano.

O primeiro caso foi construído com estratificação sazonal dos dados em período seco e chuvoso (RNA 1.1), que tiveram como dados de entrada a demanda média do dia anterior ao que se quer prever e demandas horárias do respectivo dia da semana anterior. Os erros apresentaram-se grandes se comparados aos do segundo caso, com estratificação sazonal dos dados em quatro estações (RNA 1.2), que tiveram os mesmos dados de entrada que o caso anterior. Conclui-se que quanto melhor definidos os períodos sazonais, mais facilidade a RNA tem em encontrar resultados próximos aos observados.

Comparando as três variações do modelo de RNA obtidos no terceiro caso, com estratificação sazonal em quatro estações e inclusão da variável temperatura (RNA 2.1.1, RNA 2.1.2 e RNA 2.1.3), com o quarto caso, com estratificação sazonal dos dados em quatro estações, sem inclusão da temperatura (RNA 2.2.1), verifica-se que os erros são maiores no quarto caso. Pode-se concluir que na modelagem com a inclusão da temperatura, os erros são menores, trazendo ganhos à qualidade da previsão.

Comparando o segundo caso, com estratificação sazonal dos dados em quatro estações (RNA 1.2), com os resultados obtidos com a previsão realizada pelo método de médias móveis, verifica-se a superioridade dos resultados obtidos pela previsão realizada pela RNA. Comparando também, o segundo caso (RNA 1.2) com a previsão realizada pelo modelo Auto-Regressivo, podemos concluir que o modelo RNA 1.2 apresenta melhores resultados quando os dados de entrada apresentam coeficiente de variação maior, caracterizando maior grau de variabilidade no comportamento temporal das séries, sendo esta situação de vantagem competitiva do modelo de RNA's. Já quando os dados possuem coeficiente de variação menor o modelo AR apresentou melhores resultados.

Pode-se dizer que nesta etapa do trabalho os objetivos foram alcançados. A previsão horária foi obtida com níveis de erros aceitáveis e comparados os resultados de todos os casos, observa-se a mesma tendência para todos, isto é, erros menores para os períodos em que o consumo e a temperatura não apresentam grandes variações.

Verifica-se no terceiro caso que a amplitude dos dados tem grande influência nos resultados. O erro quadrático médio mostra melhores resultados quando a variância dos dados é menor, tanto para valores de consumo quanto para valores de temperatura.

Prova-se que a previsão multivariada é possível de ser realizada, apresentando resultados bastante satisfatórios. Comparando o segundo caso, previsão univariada (RNA 1.2), com as variações dos modelo de RNA gerados no quinto caso, previsão multivariada (RNA 3.1, RNA 3.2 e RNA 3.3), verifica-se que os melhores resultados foram para a previsão univariada.

Conclui-se que o modelo de redes neurais univariado quando confrontado com os modelos de MM e AR apresenta melhores resultados, para série de dados com maior variabilidade. O modelo de RNA's univariado quando comparado, com o modelo de RNA's multivariado, apresenta melhores resultados, porque, verifica-se que os dados de entrada para o modelo univariado apresentam menores coeficientes de variação do que os dados de entrada do modelo multivariado.

Verifica-se que o algoritmo do gradiente conjugado escalonado apresentou grande capacidade de generalização e velocidade de processamento. A função objetivo usada (EQM), mostrou ser adequada para todos os modelos. Apesar de alguns picos de vazão não terem sido alcançados, o valor da média prevista foi muito bom como podemos ver nos resultados. Isto significa que, a demanda prevista pelo modelo de RNA's terá utilidade enquanto subsídio à melhoria do controle operacional, especialmente nos sistemas com maior capacidade de reservação.

No estudo do impacto da previsão no desempenho operacional da rede estudada, feito com o auxílio de um modelo de otimização, e posterior uso do EPANET, pode-se verificar que para a previsão por RNA, que obteve erros menores que a previsão por MM, a operação do sistema aproxima-se bastante da operação do sistema gerada com dados reais, enquanto que para a MM os gráficos mostram uma aproximação de pior qualidade.

Como a curva de demanda prevista por RNA é bem próxima à curva real, as políticas operacionais geradas com base na curva de previsão por RNA e implementadas no simulador hidráulico EPANET sob ação da curva real de demanda, conduziram a resultados satisfatórios. Se o critério de pressão mínima nos nós da rede não for um critério de grande relevância, tais políticas podem ser implementadas na rede sem grandes problemas.

Como a previsão de demanda realizada pelo modelo MM apresentou erros bastantes expressivos, as políticas operacionais geradas com base na curva de previsão por MM e implementadas no simulador hidráulico EPANET sob ação da curva real de demanda, conduziu a resultados não satisfatórios e que não são possíveis de implementação.

RECOMENDAÇÕES

Sugere-se como continuidade deste trabalho que seja implementada uma variação do modelo de redes neurais artificiais, que produza uma previsão multivariada com discretização horária, tendo como dados de entrada variáveis de demanda e temperatura. E que sejam estudados outras variáveis que influenciam o consumo. Sugere-se ainda que sejam implementadas novas topologias de redes neurais, como redes com mais de uma camada

intermediária e redes com saídas recorrentes, para a previsão de demanda de água, para que os resultados já obtidos neste estudos possam ser comparados com outros resultados para melhor permitir avaliação mais ampla.

BIBLIOGRAFIA

- ABELÉM, A. J., **Redes neurais artificiais na previsão de séries temporais**. Dissertação de mestrado. Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro: PUC/DEE, 1994.
- ABELÉM, A. J., PACHECO, M. A. C. e VELLASCO, M. M. B. R., **Modelagem de redes neurais artificiais para previsão de séries temporais**. In: II Simpósio Brasileiro de Redes Neurais, p.107-113, 1995.
- ALMEIDA, R., **Operação de sistemas urbanos de abastecimento de água com base em modelos de otimização não-lineares**. Dissertação de mestrado. Campinas. Faculdade de Engenharia Civil/UNICAMP, 279 p, 2001.
- BALLINI, R., **Redes neurais artificiais para previsão chuva-vazão**. Dissertação de mestrado. São Carlos: Instituto de Ciências Matemática de São Carlos/USP, 105p, 1996.
- BALLINI, R., FRANÇA, E., KADOWAKI, M., SOARES, S. e ANDRADE, M. G., **Modelos de redes neurais e Box & Jenkins para previsão de vazões médias mensais**. In: XII Simpósio Brasileiro de Recursos Hídricos. **Anais**. Vitória-ES, nov. 1997.
- BALLINI, R. **Análise e previsão de vazões utilizando modelos de séries temporais, redes neurais e redes neurais nebulosas**. Tese de doutorado, UNICAMP, Faculdade de Engenharia Elétrica e de Computação, 2000.
- BARDOSSY, A. et al., **Knowledge based classification of circulation patterns for stochastic precipitation modeling. Stochastic and statistical methods in hydrology and environmental engineering**. In: Internacional Conference, University of Waterloo, Canadá, 1993.
- BARP, A. R. B., **Modelagem chuva-vazão em bacias hidrográficas com suporte em redes neurais artificiais**. Tese de doutorado. Faculdade de Engenharia Civil da Universidade Estadual de Campinas. Campinas FEC, 1999.

- BARP, A. R. B., e BARBOSA, P. S. F., **Comparação entre modelo hidrológico conceitual chuva-vazão (SMAP) e modelo de redes neurais artificiais**. In: Simpósio Luso Brasileiro de Recursos Hídricos. **Anais**. Coimbra, Portugal, 1999.
- BISHOP, C. M., **Neural networks for pattern recognition**. New York: Oxford University Press Inc., 2^a ed., 1997.
- BOLAND, J. J., **Forecasting water use: A tutorial**. Computer Applications in water Resources, edited by H. C. Torno, Buffalo, Nova York, p. 907-916, 1985.
- BOX, G. E., e JENKINS, G. M., **Time series analysis forecasting and control**. São Francisco, Califórnia, 1976.
- BRION, E. C., e MAYS, L. W., Methodology for Optimal Operation of Pumps Stations in Water Distribution Systems. **Journal of Hydraulic Engineering, ASCE**, vol. 117, N. 1, p. 1551-1568, 1991.
- BRUCE, B. e DONALD, E. A., State-space versus multiple regression for forecasting urban water demand. **Journal of water resources planning and management**, vol. 124, N. 2, p. 113-117, march/april, 1998.
- BUNN, D. W. e FARMER, E. D., **Comparative models for electrical load forecasting**; John Wiley & Sons, 1985.
- CAJAL, S. R., **Die retine der willberthiere**. J. F. Bergman, 1894.
- CASTRO, L. N. e VON ZUBEM, F. J., **Optimization training techniques for feed forward neural network**. Technical Report DCA-RT 03/98. Campinas: UNICAMP/FEEC/DCA, julho, 1998.
- CHAKRABORTY, K., MEHROTRA, K., MOHAN, C. K., e RANKA, S., **Forecasting the behavior of multivariate time series using neural network**. Neural Networks, vol. 5, N. 6, p. 961-970, 1992.

- CIRILO, J. A., e CABRAL, J. J. S. P., **A programação não linear como um instrumento de projetos hidráulicos.** Submetido à Revista Brasileira de Recursos Hídricos – RBRH.
- CZERNICHOW, T. et al., **Short term electrical load forecasting with artificial neural networks.** Engineering Intelligent Syst., vol. 2, pag. 85-99, 1996.
- DARR, P., **Forecasting models for determining peak water consumption.** Proc. of the International Water Works Association Congress, Rio de Janeiro, p. 551-9 a 551-10, 1988.
- DAVIES, M., **The relationship between weather and electricity demand.** The Instuty
- DECK, S. et al., **Comparison of a neural network and traditional classifier for machine vision inspection.** Applied Engineering in Agriculture, vol. 11, N. 2, p. 319-326, 1995.
- EPANET 2.0 – U. S. Environmental Protection Agency (EPA) dos Estados Unidos da América, setembro (2000).
- FARMER, E. D. e POTTON. M. J., **Development of online load-production techniques with results from trials in the south-west region of the CEGB.** Proc. of the Institution of Electrical Engineers, vol. 115, N. 10, p.1549-1558, october, 1968.
- FERNANDES, L. G. L., **Utilização de redes neurais na análise e previsão de séries temporais.** Tese mestrado. Univesidade Federal do Rio Grande do Sul, Instituto de Informática, 1995.
- FLACK, J. E., **Urban water conservation: increasing efficiency-in-use residential water demand.** ASCE, New York, N. Y., 1982.
- FRANCATO, A. L., **Operação multiobjetivo de sistemas urbanos de abastecimento de água.** Tese de Doutorado. Faculdade de Engenharia Civil, Universidade Estadual de Campinas, 182 p. Campinas, Fevereiro de 2002.
- FREEMAN, J. A. e SKAPURA, D. M., **Neural networks: Algorithms, applications and programming techniques.** Addison-Wesley, 1991.

- HARTLEY, J. A. e POWELL, R. S., **The development of a combined demand prediction system**, Civil Engineering Systems, vol. 8, N. 4, p. 231-236, 1991.
- HAYKIN, S., **Neural network – A comprehensive foudantions**. New York: McMillan College Company, 1994
- HERTZ, J., KROGH, A. e PALMER, R. G., **Introduction to theory of neural computation**. Addison-Wesley, Santa Fé, EUA. 327p., 1991.
- HILL, T., O’CONNOR, M., e REMUS, W., **Neural network models for time series forecasts**. Management Science. Vol. 42, N. 7, p. 1082-1092, julho, 1996.
- HILTON, G. E. e SEJNOWSKI, T. J., **Learning and relearning in Boltzmann machines**. In Parallel Distributed Processing. Anais do congresso, vol. 1, cap. 7, 1986.
- HIMMELBLAU, D. M., **Applied nonlinear programming**. McGraw-hill Book Company, 498p, 1972.
- HIPPERT, H. S., PEDREIRA, C. E. e SOUZA, R. C., **Neural network for short-term load forecasting: a review and evaluation**. IEEE Transactins on power systems, vol. 16, N. 1, Fev. 2001.
- HOPFIELD J., **Neural networks and physical systems with emergent collective computational capabilities**. Proceedings of the National Academy of Science 79, p. 2554-2558, 1982.
- HSU, K., GUPTA, H. V. e SOROOSHIAN, S., Artificial neural network modeling of the rainfall-runoff process. **Water Resources Research**, vol. 31, N. 10, p. 2517-2530, october, 1995.
- HU, M. S., **Statistics and water demand forecasts in Hong-Kong**, Proceeding of the International Water Works Association Congress, Rio de Janeiro, p. 551-7 a 551-9, 1988.

- JAIN, A. e ORMSBEE, L., **A comparison of short term forecast methods for municipal water use**. Departament of Civil Engineering, University of Kentucky Lexington, Kentucky, pag. 649 – 652, 1995.
- JOOST, M. e SCHIFFMAN W., **Speeding up backpropagation algorithms by using cross-entropy combined with Pattern normalization**. International Journal of Uncertainty, Fuzzyness and Knowledge-Based Systems, 1993, URL: http://www.uni-koblenz.de/~schiff/cenprop_eng.ps.gz
- JORDAN, M. L., **Why the logistic function? A tutorial discussion on probabilities and neural networks**. 1995. URL: <ftp://psyche.mit.edu/pub/jordan/uai.ps.Z>
- JOWITT, P. W., e XU, C., **Demand forecasting for water distribution system**. Civil Engineering Systems , vol. 9, p. 105-121, 1992.
- KAN, A. H. G. e TIMMER, G. T. Global Optimization. In: NEMHAUSER, G. L., KAN, A H. G. (org) **Handbooks in operations research and management science: Optimization**. Amsterdam: Elsevier, vol. 1, cap. 9, p.631-661, 1989.
- KINGDON, J., **Neural nets for time series forecasting: criteris for performance with na application in gulf futures pricing**. In: Neural Network in Capital Markets, I. Londres, p. 18-19, anais, London Business School, nov. 1993.
- KOSKO, B., **Neural network and fuzzy systems – A dynamical systems approach to machine intelligence**. University of Southern California, Prentice-Hall International, Inc., 1992.
- KOVÁCS, Z. L., **Redes neurais artificiais: fundamentos e aplicações**. São Paulo: Edição Acadêmica, 2^a ed., 1996.
- LE CUN, Y., **Learning process in an asymmetric threshold network**. Disordered Systems and Biological Organization. E. Bienenstock. Ed. New York: Springer-Verlag. p. 233-240, 1986.
- LEE, S. e KIL, R. M., **A gaussian potencial function network with hierarchically self-organizing learning**. Neural Networks, vol. 4, N. 2, p. 207-224, 1991.

- LEONDES, C. T., **Algorithms and architectures**. San Diego: Academic Press, vol. 1, 1998.
- LINAWEAVER, F. P. Jr., GEYER, J. C., e WOLFF, J. B., **Residential water use, final and summary rep.** Johns Hopkins Univ., Baltimore, Md., 1966.
- MAIDMENT, D. R., MIAOU, S. P. e CRAWFORD, M. M., Transfer function models for daily urban water use. **Water Resources Research**, vol. 21 N. 4, p. 425-432, 1985.
- MAIDMENT, D. R. e PARZEN, E., Time patterns of water use in six texas cities. **Journal of Water Resources Planning Management**, ASCE, vol. 110, N. 1, p. 90-106, 1984.
- MATHWORKS, **Neural Network Toolbox User's Guide** – For use with MATLAB v.3. Mass: The Mathworks, Inc. 1998.
- MAYS, L. W. e TANG, Y. K., **Hydrosystems Engineering & Management**, McGraw-Hill, 1992.
- McCULLOCH, E. S. e PITTS, W., **A logical calculus of the ideas immanent in neurons activity**. Bulletins of Mathematical Biophysics, vol.5, p. 115-133, 1943.
- MERLO, G., **Statistics for water demand forecasts**. Proc. of the IWWA Congress, Rio de Janeiro, p. 551-1 a 551-7, 1988.
- MOLLER, M. F., **A scaled conjugate gradient algorithm for fast supervised learnig**. Neural Network. Vol. 6, p.525-533, 1993.
- MORETTIN, P. A. e TOLOI, C. M C., **Previsão de séries temporais**, Editora Atual, São Paulo, 1985.
- MUSTER, H. et al., **Adaptive neuro-fuzzy modeling of a non-stationary hydrologic variable**. Proc. International Symposium Water Resources Planning in a Changing World, p. 221-230, 1994.
- NIGRINI, A., **Neural networks for pattern recognition**. Cambridge, MA: The MIT Press, 1993.

- NOVAES, G. N., **Métodos de otimização: aplicações aos transportes**. São Paulo: Edgar Blücher, 1978.
- NUNES, L. C. S., **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. Tese de mestrado. Faculdade de Engenharia Elétrica da Universidade Estadual de Campinas. Campinas FEE, 1998.
- NVULE, D. N. e MAIDMENT, D. R., **Water use forecasting and evaluating the effects of conservation measures**. Computer Applications in Water Resources, edited by H. C. Torno, Buffalo, Nova York, p. 401-411, 1985.
- ORMSBEE, L. E. e REDDY, S. L., Nonlinear Heuristic for Pump Operation. **Journal of Water Resources Planning and Management, ASCE**, vol. 121, N. 4, p. 302-309, 1995.
- PARKER, D. B., **Learning logic: casting the cortex of the human brain in silicon**. TR-47, M.I.T. Center for Computational Research in Economics and Management Science. Cambridge, MA, Feb., 1985.
- PARMA, G. G., MENEZES, B. R. e BRAGA, A. P., **Aprendizado on-line da RNAs multicamadas baseado na teoria de sistemas de estrutura variável**. Anais, Simpósio de Redes Neurais. Goiania: Ed. UFG, 3-5 de dezembro, p. 80-82, 1997.
- PERRY, P. F., Demand forecasting in water supply networks. **Journal of the Hydraulics Division, ASCE**, vol. 107, N. HY9, p. 1077-1087, september, 1981.
- PEZESHK, S. e HELWEG, O. J., Adaptive Search Optimization in Reducing Pump Operating Cost. **Journal of Water Resources Planning and Management, ASCE**, vol. 122, N. 1, p. 57-63, 1996.
- PLANO DIRETOR DE ÁGUAS DE CAMPINAS, **Relatório Técnico 1**. SANASA, julho, 1992.
- PRECHELT, L., **Early stopping – but when?, Technical report**, 1997, URL: http://www.ipd.ira.uka.de/~prechelt/Biblio/stop_tricks1997.ps.gz

- RANJINTHAN, S., EHEART, J. W. e GARRETT, J. H., Neural network-based screening for groundwater reclamation under uncertainty. **Water Resources Research**, vol. 29, N. 3, p. 563-574, 1993.
- REFENES, A. N., Currency exchange rate prediction and neural network desing strategies. **Neural computing & Aplications Journal**. Londres, vol. 1, p. 46-58, 1992.
- RELATÓRIO SÍNTESE, **Curva de consumo dos setores da região Metropolitana de São Paulo**. SABESP, junho, 1999.
- ROJAS, R., **Neural networks; a systematic indroduction**. Berlin: Springer, 1996.
- RUMELHART, D. E., McCLEALAND, J. L. and the PDP Research Group (Eds), **Parallel distribuited processing: Explorations in the microstructure of cognition**, vol. 1: Foundions. Cambridge, MA: MIT Press, 1986.
- SAKARYA, B. A., e MAYS, L. W., Optimal Operation of Water Distribution Pumps Considering Water Quality. **Journal of Water Resources Planning and Management, ASCE**, vol. 126, N. 4, p. 210-220, 2000.
- SANTOS, V. P. e ROMERO, R. A. F., **Utilização do MATLAB para o desenvolvimento de redes neurais**. Relatórios Técnicos, N. 18. Intitulo de Ciências Matemáticas de São Carlos. USP, 1994.
- SARMENTO, F. J., **Modelagem de séries hidrológicas através de redes de neurônios**. Revista Brasileira de Recursos Hídricos, vol. 1, N. 2, p. 19-31, jul./dez., 1996.
- SHARDA, R. e PATIL, R., **Neural networks as forecasting experts: Na empirical test**. In: International Joint Conference on Neural Networks, vol. 1, p.491-494. Washingtyon, DC. IEEE.
- SHVARTSER, L., SHAMIR, U., e FELDEMAN, M., Forecasting hourly water demand by pattern recognition approach. **Journal of water resources planning and management, ASCE**, vol. 119, N. 6, p. 611-627, nov./dec. 1993.

- SILVA, L. N. C., **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. Dissertação de mestrado. Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas. Campinas: FEE/DECAI, 1998.
- SILVA, O. S., Notas de aula da disciplina IM326, Gerenciamento da Cadeia de Suprimentos, ministrada na Faculdade de Engenharia Mecânica/ Unicamp, 2002.
- SPIEGEL, M. R., **Estatística: Resumo da Teoria, 875 Problemas Resolvidos, 619 Problemas Propostos**, São Paulo, McGraw-Hill, 1974.
- STEVEN, G. B. e GREG, J. W., Intensity, duration, and frequency of residential water demands. **Journal of water resources planning and management**, vol. 122, N. 1, p. 11-19, jan./feb. 1996.
- TANG, Z., ALMEIDA, C. e FISHWICK, P. A., **Times séries forecasting using neural network vs. Box-Jenkins. Simulation**. Vol 57, N. 5, p. 303-310, 1991.
- TAO, Y. et al., **Machine vision for color inspection of potatoes and apples**. Transactions of the American Society of Agricultural Engineers, vol. 38, N.5, p. 1555-1561, 1995.
- TAWEL, R., MARKO, K., e FELDKAMP, L., **Custom VLSI ASIC for automotive applications with recurrent networks**. 1998. URL: <http://www.jpl.nasa.gov/releases/98/ijcnn98.pdf>.
- TRIPPI, R. R. e TUBAN, E., **Neural networks in finance and investing**. Chicago: Probus, 1993.
- YOUNG, G. K., KILGORE, R. T. e SAUNDERS, K. G., **Practical water demand forecasting**. Computer Application in Water Resources, edited by H. C. Torno, Buffalo, Nova York, p. 927-933, 1985
- URL1: TSP BIB Home Page. URL: http://www.ing.unlp.edu.ar/cetad/mos/TSPBIB_home.html
- VON ZUBEN, F. J., **Redes neurais aplicadas ao controle de máquinas de indução**. Tese de mestrado, Faculdade de Engenharia Elétrica, Unicamp, 1993.

- VON ZUBEN, F. J., **Modelos paramétricos e não-paramétricos de redes neurais artificiais e aplicações.** Tese de doutorado. Faculdade de Engenharia Elétrica da Universidade Estadual de Campinas. Campinas FEE/DECAI, 1996
- VON ZUBEN, F. J., Notas de aula. 1999. URL:
<http://www.dac.fee.unicamp/~vonzuben/vonzuben.html>
- WASSERMAN, P. D., **Neural computing – Theory and practice.** New York: VNR, 1989.
- WEIJUN, H., e JING, D., **An artificial neural network for reservoir operation.** Proc. International Symposium Water Resources Planning in Changing Word, p. 133-140, 1994.
- WERBOS, P. J., **Beyond regression; new tools for prediction and analysis in the behavioral science.** Havard University, PhD Thesis, 1974.
- WIDROW, B. e LEHR, M. A., **30 – year of adaptive neural networks: peceptrons, madaline, and backpropagation.** Proceeding of IEEE, vol. 78, N. 9, p. 1415-1441, sep. 1990.
- WILLIAMS, M. F. e COULBECK, B., Dynamic modelling and control optmization in the development of the wolverhamptom water supply and distribution system, **Water Pollution Control**, vol. 85, N. 2, p. 272-291, 1987.
- ZAHED, K. F., **Previsão de demanda de consumo em tempo real no desenvolvimento operacional de sistemas de distribuição de água.** Tese de doutorado, Escola Politécnica da Universidade de São Paulo – USP, 1990.
- ZHANG, S. P. et al., **Prediction of daily water demands by neural networks.** Nihon Suido Consultants, Co. Ltd., Okubo 2-2-6, Shinjuku-ku, Tokyo, 169, Japan, 1994.
- ZHANG, S. P. e YAMADA, R., **Comparison of daily water demand prediction models.** Annual Reports of NSC,1992, vol. 18, N. 1.

- ZUBULUM (a), R. S., GUEDES, K., PACHECO. M. A.C. e VELLASCO, M. M. B. R., **Short-term load forecasting using neural nets**. International Workshop on Artificial Neural Networks – IWANN95. Lecture Notes in Computer Science, Springer – Verlag 930, p. 1001-1008, Torremolinos (Málaga), Spain, junho, 1995.
- ZUBULUM (b), R. S., GUEDES, K., PACHECO. M. A.C. e VELLASCO, M. M. B. R., **An intelligent load forecasting system**, IEEE International Conference on Electricity Sector Development and Demand Side Management – ESDDM95, Kuala Lumpur, Malásia, p. 21-22, nov.1995.
- ZURADA, J. M., **Introduction to artificial neural systems**. Boston: Plus Publishing Company, 1992.

Código fonte *MATLAB* (*normatestel.m*)

```
%Programa normatestel.m
%Pré processamento da rede neural
%Este programa normaliza os dados de entrada e saída para a
%rede neural artificial
%no intervalo de [0,1]
clear all;format compact;format long;
load entchu.dat;
[x,n]=size(entchu); %x é o número de linhas, e n é o número
                    %de colunas
entchu=entchu(:,2:n); %elimina a coluna de anos (primeira
                    %coluna)

n = n-1;
vazao = reshape(entchu',x*n,1); % toma primeiro o
                                %transposto de arquivo
                                %e escreve o arquivo como
                                %sendo uma coluna

m=min(vazao);
M=max(vazao);
A=vazao;
S_norm=(A-m) / (M-m);
load saichu.dat;
[y,t]=size(saichu); %x é o número de linhas, e n é o número
                    %de colunas
saichu=saichu(:,2:t); %elimina a coluna de anos (primeira
                    %coluna)

t=t-1;

saida=reshape(saichu',y*t,1); % toma primeiro o transposto
```

```

%de arquivo e escreve o
%arquivo como sendo uma
% coluna

m_sai=min(saida);
M_sai=max(saida);
B=saida;
Y_norm=(B-m_sai)/(M_sai-m_sai);
for k=1:174
    for i=1:25
        X2(k,i)=S_norm(25*(k-1)+i);
        V1(k,i)=vazao(25*(k-1)+i);
    end
end
for k=1:174
    for i=1:24
        S2(k,i)=Y_norm(24*(k-1)+i);
        V2(k,i)=saida(24*(k-1)+i);
    end
end
X=X2(1:100,:);
S=S2(1:100,:);
V=V1(1:100,:);
VS=V2(1:100,:);
save dados X S;
save treino -ascii X S;
save real -ascii VS;
X=X2(101:174,:);
S=S2(101:174,:);
V=V1(101:174,:);
VS=V2(101:174,:);
save dadtest X S;

```

```
save teste -ascii X S;  
save real_teste -ascii VS;
```

Código fonte *MATLAB* (*moller.m*)

```

% moller.m
% Treinamento de rede perceptron com uma camada
%intermediaria
% Metodo de Otimizacao Irrestrita de 2a. ordem
% Algoritmo do Gradiente Conjugado e Escalonado
% Calculo exato da matriz hessiana (produto H*p)
% Resultados parcialmente baseados no artigo:
% Moller, M.F. A Scaled Conjugate Gradient Algorithm for
% Fast Supervised Learning, Neural Networks, 6:525-533,
%1993.
% Excecoes:
% 1) introducao do calculo exato do produto H*p
% 2) refinamento do processo para calcular lamb em funcao
%de comp
% 3) calculo de beta pela formula de Polak-Ribiere
%A formula original nao pode ser adequadamente aplicada
%devido a possivel positivacao de delta, fazendo com que
%não se possa corrigir o produto r'*H*p da mesma forma que
%p'*H*p.
% 4) calculo de comp pelo original
% 5) ajuste de pesos e' aceito apenas se comp > 0 (e nao
%>=)
% 6) lamb inicial = 0.0
% 7) (no. de iteracoes antes do reset de p) = 1.0*(no. de
%parametros)
% 8) recalculo de lamb, com comp<corde, com p1 e nao p
% Arquivo de dados para treinamento supervisionado:
% dados.mat, contendo X (matriz de entrada) e S (matriz de
%saida)

```

```
% Funcoes auxiliares:
% inic.m / processa.m / norma.m / hprocess.m / gravainf.m
%
clear all;format long;format compact;
% Norma minima admitida para o vetor gradiente
limiar = 1.0e-6;
taxa0 = 0.25;
taxa = taxa0;
corte = 0.25;
it1 = 0; % para lamb
it2 = 0; % para comp
% Parametro de escalamento para positivacao da hessiana
% (coeficiente Levenberg-Marquardt)
it1 = it1+1;lamb(it1) = 0.0;
blamb = 0;
m = 25; % Dimensao do vetor de entradas
n = [10;24]; % Dimensao da rede neural (camadas
              % intermediaria e de saida)
[w1,w2,eq,eq1,stw1,stw2,niter,nflops] = inic(n,m);
% w1:n(1)x(m+1) w2:n(2)x(n(1)+1)
%
% Carregamento dos dados para treinamento (e' assumido que
% o intervalo de
% valores para os dados esta' adequado. Caso contrario, e'
% necessario submeter os dados a um pre-processamento antes
% de prosseguir a partir deste ponto.
load dados; % X (matriz de entrada Nxm) e S (matriz de
              % saida Nx(2))
N = length(X(:,1));
disp(sprintf('Numero de padroes = %d',N));
npesos = n(1)*(m+1)+n(2)*(n(1)+1);
```

```

disp(sprintf('Numero de pesos da rede neural =✓
%d',npesos));

%[Ew,ro,dEw] = processa(X,S,w1,w2,n,m,N);
[Ew,dEw] = processa(X,S,w1,w2,n,m,N);
eq = [eq;Ew];
%eq1 = [eq1;ro];
%disp(sprintf('EQ inicial = %.12g / Erro_percentual =
%.12g',Ew,ro));

disp(sprintf('EQ inicial = %.12g',Ew));
itermenor = 1;
p = -dEw;p_1 = p;r = -dEw;
t0=clock;
sucesso = 1;
while norma(dEw) > limiar & niter < 1500,
if sucesso,
p1 = reshape(p(1:n(1)*(m+1)),m+1,n(1))';
p2 = reshape(p(n(1)*(m+1)+1:npesos),n(1)+1,n(2))';
s = hprocess(X,S,w1,w2,p1,p2,n,m,N);
delta = p'*s;
end
delta = delta+(lamb(it1)-blamb)*(p'*p);
if delta <= 0, % positivando delta
blamb = 2*(lamb(it1)-delta/(p'*p));
delta = -delta+lamb(it1)*(p'*p);
it1 = it1+1;lamb(it1) = blamb;
end
mi = p'*r;
alfa = mi/delta;
vw =✓
[reshape(w1',n(1)*(m+1),1);reshape(w2',n(2)*(n(1)+1),1)];
vw1 = vw + alfa*p;

```

```

w11 = reshape(vw1(1:n(1)*(m+1)),m+1,n(1))';
w21 = reshape(vw1(n(1)*(m+1)+1:npesos),n(1)+1,n(2))';
%[Ew1,ro1,dEw1] = processa(X,S,w11,w21,n,m,N);
[Ew1,dEw1] = processa(X,S,w11,w21,n,m,N);
it2 = it2+1;
comp(it2) = (Ew-Ew1)/(-dEw'*(alfa*p)-0.5*(alfa^2)*delta);
%Em lugar de comp(it2) = 2*delta*(Ew-Ew1)/(mi^2); (da' na
% mesma)
if comp(it2) > 0,
Ew = Ew1;eq = [eq;Ew];
%ro = ro1;eq1 = [eq1;ro];
dEw = dEw1;
deltaw1 = norma(w1-w11);deltaw2 = norma(w2-w21);stw1 = ✓
[stw1;deltaw1];stw2 = [stw2;deltaw2];
w1 = w11;w2 = w21;
niter = niter+1;
%disp(sprintf('%5d %d %.12g %.12g
%.12g',niter,itermenor,comp(it2),Ew,ro));
%disp(sprintf('%5d %d %.12g %.12g
%',niter,itermenor,comp(it2),Ew));
r1 = r;
r = -dEw;
blamb = 0;
sucesso = 1;
% E' possivel parar a iteracao menor antes e reiniciar a
%direcao de busca
if (itermenor == npesos),
p_1 = p;p = r;
itermenor = 1;
gravainf;
else

```

```

itermenor = itermenor + 1;
beta = (r'*r-r'*r1)/(r1'*r1); % Polak-Ribiere (Luenberger,
                                % pg 253)
%beta = -(r'*s)/delta; % problemas com s e delta
% (positivacao de delta)
%beta = (r'*r-r'*r1)/mi; % versao do Moller
p_1 = p;p = r+beta*p;
end
if comp(it2) >= corte,
it1 = it1+1;lamb(it1) = taxa*lamb(it1-1); % /4
taxa = taxa*taxa0;
end
else
blamb = lamb(it1);
sucesso = 0;
end
if comp(it2) < corte,
it1 = it1+1;lamb(it1) = lamb(it1-1) + ✓
(delta*(1-comp(it2)))/(p_1'*p_1));
taxa = taxa0;
end
end
gravainf;

```

Código fonte *MATLAB* (*inic.m*)

```

% Geracao aleatoria de pesos para a rede neural, com
% distribuicao uniforme no intervalo [-0.1,0.1]
% function [w1,w2,eq,eq1,stw1,stw2,niter,nflops] =
%inic(n,m)
% m = no. de entradas

```

```

% n = no. de neuronios nas camadas intermediaria e de saida
% -> n = [n(1);n(2)]
% w1, w2: matrizes de pesos (por camada)
% w1:n(1)x(m+1)    w2:n(2)x(n(1)+1)
% Tipos de geracao de pesos:
% Opcao 1 -> iniciar o treinamento
% Opcao 2 -> reiniciar o treinamento com a mesma condicao
%inicial
% Opcao 3 -> reiniciar o treinamento a partir da ultima
%atualizacao de pesos
%
function [w1,w2,eq,eq1,stw1,stw2,niter,nflops] = inic(n,m)
disp('(1) Gera w10 e w20 e salva');
disp('(2) Copia w10 e w20 existentes');
disp('(3) Copia w1 e w2 existentes');
resp = input('Tipo de geracao de pesos: ');
if resp == 1;
w1 = -0.1 + 0.2*rand(n(1),m+1);
w2 = -0.1 + 0.2*rand(n(2),n(1)+1);
save w10 w1;save w20 w2;
eq = [];eq1 = [];stw1 = [];stw2 = [];niter = 0;nflops = 0;
elseif resp == 2,
load w10;load w20;
eq = [];eq1 = [];stw1 = [];stw2 = [];niter = 0;nflops = 0;
elseif resp == 3,
load w1;load w2;
load evol;
else
error('Opcao invalida!');
end
flops(0);

```

Código fonte *MATLAB* (*norma.m*)

```
% norma.m
% Fornece uma medida do tipo erro quadratico medio
%
function [E] = norma(S)
[nr,nc] = size(S);
E = sum(sum(S.*S));
E = sqrt(E/(nr*nc));
```

Código fonte *MATLAB* (*processa.m*)

```
% function [Ew,ro,dEw] = processa(X,S,w1,w2,n,m,N)
% Fornece o erro quadratico na saida e o vetor gradiente
% Todos os neuronios apresentam entrada de polarizacao
%
function [Ew,dEw] = processa(X,S,w1,w2,n,m,N)
x1 = [X ones(N,1)];
y1 = tanh(x1*w1');
x2 = [y1 ones(N,1)];
% y2 = tanh(x2*w2');
y2 = x2*w2';
erro = y2-S;
erro2 = erro;
dw2 = erro2'*x2;
erro1 = (erro2*w2(:,1:n(1))).*(1.0-y1.*y1);
dw1 = erro1'*x1;
verro = reshape(erro,N*n(2),1);
Ew = 0.5*(verro'*verro);
dEw=
[reshape(dw1',n(1)*(m+1),1);reshape(dw2',n(2)*(n(1)+1),1)];
```

✓

Código fonte *MATLAB* (*hprocess.m*)

```
% function [s] = hprocess(X,S,w1,w2,p1,p2,n,m,N)
% s = produto H*p calculado exatamente
%
function [s] = hprocess(X,S,w1,w2,p1,p2,n,m,N)
x1 = [X ones(N,1)];
rx1 = zeros(N,m+1);
y1 = tanh(x1*w1');
ry1 = (x1*p1'+rx1*w1').*(1.0-y1.*y1);
x2 = [y1 ones(N,1)];
rx2 = [ry1 zeros(N,1)];
y2 = x2*w2';
ry2 = x2*p2'+rx2*w2';
erro = y2-S;
erro2 = erro;
rerro2 = ry2;
rw2 = erro2'*rx2+rerro2'*x2;
errol = (erro2*w2(:,1:n(1))).*(1.0-y1.*y1);
rerrol = (rerro2*w2(:,1:n(1))+erro2*p2(:,1:n(1))).* ✓
(1.0-y1.*y1)+(erro2*w2(:,1:n(1))).*(-2*y1.*ry1);
rw1 = errol'*rx1+rerrol'*x1;
rEw=
[reshape(rw1',n(1)*(m+1),1);reshape(rw2',n(2)*(n(1)+1),1)];
s = rEw; ✓
```

Código fonte *MATLAB* (*gravainf.m*)

```
% gravainf.m
% nflops = nflops+flops;
% flops(0);
```

```

disp(sprintf('No. de flops = %.12g',nflops));
disp(sprintf('EQ atual = %.12g',eq(niter+1)));
disp(sprintf('No. de iteracoes = %d',niter));
disp(sprintf('Tempo          de          processamento✓
(s)=%d',etime(clock,t0)));
save w1 w1;
save w2 w2;
save evol eq eq1 stw1 stw2 niter nflops lamb comp;

```

Código fonte *MATLAB* (“*tertarn1.m*”)

```
% Verificacao do desempenho da rede neural treinada
% Utilizacao dos pesos obtidos apos o treinamento da rede neural
% Saida de dados treinados pos-processados (arquivo calibracao)
% Apresentacao dos resultados graficos
% DADOS DE TREINAMENTO
% testarn1.m

clear all;format compact;format long;
load w1;load w2;load dados;load evol;
N = length(X(:,1));
X = [X ones(N,1)];
n = length(w1(:,1));
r = length(w2(:,1));
m = length(w1(1,:))-1;
disp(sprintf('No. de padroes de treinamento = %d', N));
disp(sprintf('No. de neuronios na camada intermediaria = %d', n));
disp(sprintf('No. de iteracoes realizadas = %d',niter));
disp(sprintf('No. de flops = %d',nflops));
Srnn = [tanh(X*w1') ones(N,1)]*w2';
verro = reshape(S-Srnn,N*r,1);
eqf = 0.5*(verro'*verro);
disp(sprintf('Erro quadratico final = %.12g',eqf));
for k=1:r,
figure(k);subplot(111);plot(S(:,k),'r');hold on;plot(S(:,k), '*r');
plot(Srnn(:,k), 'g');plot(Srnn(:,k), '*g');hold off;
title('Des (r) RN (g)');
end
for k=(r+1):(r+r),
figure(k);subplot(111);plot(S(:,k-r)-Srnn(:,k-r),'r');
hold on;plot(S(:,k-r)-Srnn(:,k-r), '*g');hold off;
```

```

title('Erro = S-Srn');
end
for k=1:r,
Smedio(1,k) = (1/N)*S(:,k)'*ones(N,1);
end
den = 0; num = 0;
for l=1:N,
for k=1:r,
num = num+(S(l,k)-Srn(l,k))^2;
den = den+(S(l,k)-Smedio(1,k))^2;
end
end

% Desnormalizacao dos dados de saida da rede (treinamento)
load saichu.dat; % arquivo de entrada normalizados
[m,n]=size(saichu); % m e o numero de linhas e n e o numero de colunas
saichu=saichu(:,2:n); % elimina a coluna de anos (primeira coluna)
n=n-1;
vazao=reshape(saichu',m*n,1); % toma primeiro o transposto do arquivo e escreve
                                %o arquivo como sendo uma coluna

m=min(vazao);
M=max(vazao);
calib=((M-m)*(Srn))+m; %Expressao para desnormalizar
                        %as vazoes treinadas

%save calibrado -ascii calib Srn;
%salva o arquivo de dados das vazoes treinadas do
%modelo calibrado
save calibrado -ascii calib;
fvu = num/den;
disp(sprintf('FVU = %.12g',fvu));

```

```
figure(r+r+1);subplot(111);plot(eq);title('EQ');
figure(r+r+3);subplot(211);plot(stw1);title('Delta pesos');subplot(212);plot(stw2);
```

Código fonte *MATLAB* (“*tertarn.m*”)

```
% Verificacao do desempenho da rede neural treinada
% Utilizacao dos pesos obtidos apos o treinamento da rede neural
% Apresentacao dos resultados graficos
% DADOS DE TESTE
%
clear all;format compact;format long;
load w1;load w2;load dadtest;load evol;
N = length(X(:,1));
X = [X ones(N,1)];
n = length(w1(:,1));
r = length(w2(:,1));
m = length(w1(1,:))-1;
disp(sprintf('No. de padroes de treinamento = %d',N));
disp(sprintf('No. de neuronios na camada intermediaria = %d',n));
disp(sprintf('No. de iteracoes realizadas = %d',niter));
disp(sprintf('No. de flops = %d',nflops));
Srnr = [tanh(X*w1') ones(N,1)]*w2';
verro = reshape(S-Srnr,N*r,1);
eqf = 0.5*(verro'*verro);
disp(sprintf('Erro quadratico final = %.12g',eqf));
for k=1:r,
figure(k);subplot(111);plot(S(:,k),'r');hold on;plot(S(:,k),'*r');
plot(Srnr(:,k),'g');plot(Srnr(:,k),'*g');hold off;
title('Des (r) RN (g)');
end
```

```

for k=(r+1):(r+r),
figure(k);subplot(1 1 1);plot(S(:,k-r)-Srn(:,k-r),'r');
hold on;plot(S(:,k-r)-Srn(:,k-r),'*g');hold off;
title('Erro = S-Srn');
end
for k=1:r,
Smedio(1,k) = (1/N)*S(:,k)'*ones(N,1);
end
den = 0;num = 0;
for l=1:N,
for k=1:r,
num = num+(S(l,k)-Srn(l,k))^2;
den = den+(S(l,k)-Smedio(1,k))^2;
end
end

% Desnormalizacao dos dados de saida da rede (treinamento)
load saichu.dat; % arquivo de entrada normalizados
[m,n]=size(saichu); %m e o numero de linhas e n e o numero de colunas
saichu=saichu(:,2:n); %elimina a coluna de anos (primeira coluna)
n=n-1;
vazao=reshape(saichu',m*n,1); % toma primeiro o transposto do arquivo e escreve
                                %o arquivo como sendo uma coluna

m=min(vazao);
M=max(vazao);
calib_teste=((M-m)*(Srn))+m; %Expressao para desnormalizar
                                %as vazoes treinadas

%save calibrado_teste -ascii calib_teste Srn;%salva o arquivo de dados das vazoes
%treinadas do modelo calibrado

save calibrado_teste -ascii calib_teste;

```

```
fvu = num/den;  
disp(sprintf('FVU = %.12g',fvu));  
figure(r+r+1);subplot(111);plot(eq);title('EQ');  
figure(r+r+3);subplot(211);plot(stw1);title('Delta pesos');subplot(212);plot(stw2);
```

Tabela D.1 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Verão)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	410,70	37,45
<i>2</i>	373,52	41,82
<i>3</i>	347,28	44,79
<i>4</i>	333,42	49,34
<i>5</i>	332,53	49,41
<i>6</i>	340,57	41,92
<i>7</i>	388,12	57,73
<i>8</i>	469,53	59,29
<i>9</i>	564,55	77,17
<i>10</i>	652,08	79,66
<i>11</i>	715,55	89,69
<i>12</i>	759,53	215,22
<i>13</i>	734,77	63,55
<i>14</i>	700,60	51,75
<i>15</i>	684,32	76,56
<i>16</i>	637,35	49,92
<i>17</i>	616,87	51,08
<i>18</i>	611,20	47,69
<i>19</i>	599,88	44,54
<i>20</i>	582,07	49,43
<i>21</i>	573,78	39,92
<i>22</i>	528,05	38,68
<i>23</i>	524,58	41,51
<i>24</i>	463,28	31,87

Tabela D.2 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Penha (Estação Verão)

K	r_k	k	r_k	k	r_k
<i>1</i>	0,481	<i>13</i>	0,079	<i>25</i>	0,164
<i>2</i>	0,446	<i>14</i>	0,064	<i>26</i>	0,155
<i>3</i>	0,330	<i>15</i>	0,019	<i>27</i>	0,074
<i>4</i>	0,251	<i>16</i>	0,000	<i>28</i>	0,056
<i>5</i>	0,133	<i>17</i>	-0,033	<i>29</i>	0,020
<i>6</i>	0,115	<i>18</i>	-0,034	<i>30</i>	0,019
<i>7</i>	0,078	<i>19</i>	0,015	<i>31</i>	0,003
<i>8</i>	0,093	<i>20</i>	0,083	<i>32</i>	0,005
<i>9</i>	0,129	<i>21</i>	0,109	<i>33</i>	0,000
<i>10</i>	0,151	<i>22</i>	0,172	<i>34</i>	0,018
<i>11</i>	0,149	<i>23</i>	0,211	<i>35</i>	-0,051
<i>12</i>	0,117	<i>24</i>	0,264	<i>36</i>	-0,037




Figura D.1 – Função de Autocorrelação para a Série de Consumo para o Reservatório Penha (Estação Verão)

Tabela D.3 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,819	0,750	0,708

Tabela D.4 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Outono)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	440,92	32,12
<i>2</i>	397,75	27,12
<i>3</i>	374,58	28,37
<i>4</i>	367,43	27,71
<i>5</i>	358,02	26,89
<i>6</i>	382,85	25,62
<i>7</i>	462,08	60,49
<i>8</i>	555,93	69,21
<i>9</i>	668,92	71,35
<i>10</i>	746,40	57,34
<i>11</i>	792,72	43,22
<i>12</i>	804,05	46,09
<i>13</i>	772,88	44,02
<i>14</i>	744,48	41,50
<i>15</i>	715,80	43,79
<i>16</i>	678,53	33,38
<i>17</i>	672,22	42,75
<i>18</i>	662,85	38,51
<i>19</i>	653,03	36,84
<i>20</i>	618,50	33,63
<i>21</i>	595,25	35,49
<i>22</i>	558,12	30,79
<i>23</i>	540,82	36,39
<i>24</i>	490,68	33,13

Tabela D.5 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Penha (Estação Outono)

<i>K</i>	r_k	<i>k</i>	r_k	<i>k</i>	r_k
<i>1</i>	0,433	<i>13</i>	0,186	<i>25</i>	0,113
<i>2</i>	0,430	<i>14</i>	0,141	<i>26</i>	0,107
<i>3</i>	0,368	<i>15</i>	0,110	<i>27</i>	0,084
<i>4</i>	0,244	<i>16</i>	0,081	<i>28</i>	0,028
<i>5</i>	0,202	<i>17</i>	0,041	<i>29</i>	0,053
<i>6</i>	0,159	<i>18</i>	0,070	<i>30</i>	0,051
<i>7</i>	0,155	<i>19</i>	0,084	<i>31</i>	0,089
<i>8</i>	0,203	<i>20</i>	0,109	<i>32</i>	0,113
<i>9</i>	0,231	<i>21</i>	0,125	<i>33</i>	0,146
<i>10</i>	0,240	<i>22</i>	0,125	<i>34</i>	0,166
<i>11</i>	0,261	<i>23</i>	0,181	<i>35</i>	0,177
<i>12</i>	0,233	<i>24</i>	0,151	<i>36</i>	0,146




Figura D.2 – Função de Autocorrelação para a Série de Consumo para o Reservatório Penha (Estação Outono)

Tabela D.6 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,854	0,770	0,700

Tabela D.7 – Média e Desvio Padrão para a Série de Consumos do Reservatório Penha (Estação Primavera)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	411,68	68,67
<i>2</i>	358,37	30,33
<i>3</i>	337,70	29,95
<i>4</i>	328,73	29,75
<i>5</i>	320,60	29,85
<i>6</i>	341,03	26,04
<i>7</i>	403,05	44,96
<i>8</i>	481,10	73,52
<i>9</i>	576,62	75,46
<i>10</i>	675,22	74,13
<i>11</i>	728,20	65,31
<i>12</i>	743,05	74,06
<i>13</i>	726,70	69,47
<i>14</i>	701,20	60,99
<i>15</i>	670,10	58,20
<i>16</i>	633,43	49,83
<i>17</i>	610,08	53,41
<i>18</i>	629,12	180,85
<i>19</i>	594,67	55,34
<i>20</i>	572,57	54,17
<i>21</i>	543,00	43,55
<i>22</i>	510,32	36,54
<i>23</i>	484,22	44,77
<i>24</i>	451,82	53,12

Tabela D.8 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Penha (Estação Primavera)

<i>K</i>	r_k	<i>k</i>	r_k	<i>k</i>	r_k
<i>1</i>	0,470	<i>13</i>	0,212	<i>25</i>	0,252
<i>2</i>	0,438	<i>14</i>	0,183	<i>26</i>	0,209
<i>3</i>	0,337	<i>15</i>	0,194	<i>27</i>	0,172
<i>4</i>	0,234	<i>16</i>	0,157	<i>28</i>	0,146
<i>5</i>	0,165	<i>17</i>	0,152	<i>29</i>	0,118
<i>6</i>	0,168	<i>18</i>	0,148	<i>30</i>	0,126
<i>7</i>	0,164	<i>19</i>	0,120	<i>31</i>	0,172
<i>8</i>	0,212	<i>20</i>	0,144	<i>32</i>	0,190
<i>9</i>	0,188	<i>21</i>	0,170	<i>33</i>	0,154
<i>10</i>	0,222	<i>22</i>	0,197	<i>34</i>	0,174
<i>11</i>	0,202	<i>23</i>	0,229	<i>35</i>	0,153
<i>12</i>	0,189	<i>24</i>	0,295	<i>36</i>	0,147




Figura D.3 – Função de Autocorrelação para a Série de Consumo para o Reservatório Penha (Estação Primavera)

Tabela D.9 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,826	0,756	0,708

Tabela D.10 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Verão)

HORAS	MÉDIA	DESVIO PADRÃO
1	699,87	47,21
2	662,15	46,17
3	642,52	37,60
4	636,82	42,79
5	635,95	46,77
6	644,42	49,84
7	686,13	53,72
8	741,47	66,39
9	810,67	71,83
10	887,73	83,60
11	947,30	65,95
12	963,90	56,43
13	958,53	65,71
14	910,93	56,77
15	888,65	54,89
16	861,27	51,06
17	846,70	54,95
18	829,57	63,93
19	827,70	72,00
20	815,88	69,95
21	805,67	58,57
22	766,95	56,55
23	754,90	51,49
24	733,52	46,20

Tabela D.11 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Verão)

K	r_k	k	r_k	k	r_k
1	0,780	13	0,264	25	0,211
2	0,651	14	0,253	26	0,201
3	0,546	15	0,218	27	0,184
4	0,457	16	0,190	28	0,173
5	0,401	17	0,167	29	0,153
6	0,325	18	0,165	30	0,115
7	0,283	19	0,169	31	0,098
8	0,308	20	0,159	32	0,098
9	0,314	21	0,178	33	0,107
10	0,319	22	0,178	34	0,098
11	0,296	23	0,214	35	0,099
12	0,278	24	0,233	36	0,101




Figura D.4 – Função de Autocorrelação para a Série de Consumo para o Reservatório Edu Chaves (Estação Verão)

Tabela D.12 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,449	0,709	0,405

Tabela D.13 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Outono)

HORAS	MÉDIA	DESVIO PADRÃO
1	742,85	47,21
2	710,65	49,76
3	693,82	50,27
4	691,70	48,89
5	695,48	49,88
6	700,88	39,87
7	768,20	51,49
8	830,95	56,86
9	901,17	57,68
10	970,58	59,45
11	1000,42	50,81
12	1009,75	51,21
13	990,10	48,68
14	961,08	51,30
15	946,90	98,92
16	912,17	53,62
17	895,50	55,29
18	894,93	53,17
19	900,70	52,15
20	878,60	48,09
21	855,07	48,02
22	826,65	44,80
23	809,03	44,28
24	778,27	44,92

Tabela D.14 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Outono)

K	r_k	k	r_k	k	r_k
1	0,795	13	0,080	25	-0,110
2	0,707	14	0,031	26	-0,127
3	0,605	15	-0,014	27	-0,143
4	0,505	16	-0,059	28	-0,149
5	0,427	17	-0,088	29	-0,144
6	0,328	18	-0,112	30	-0,143
7	0,311	19	-0,130	31	-0,132
8	0,259	20	-0,137	32	-0,125
9	0,197	21	-0,139	33	-0,108
10	0,198	22	-0,133	34	-0,065
11	0,161	23	-0,113	35	-0,022
12	0,120	24	-0,103	36	0,008




Figura D.5 – Função de Autocorrelação para a Série de Consumo para o Reservatório Edu Chaves (Estação Outono)

Tabela D.15 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,486	0,874	0,474

Tabela D.16 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Inverno)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	726,67	25,88
<i>2</i>	700,25	19,14
<i>3</i>	687,38	26,97
<i>4</i>	677,05	34,48
<i>5</i>	674,43	36,40
<i>6</i>	693,60	35,10
<i>7</i>	734,75	44,28
<i>8</i>	804,48	56,11
<i>9</i>	887,07	55,80
<i>10</i>	954,42	49,89
<i>11</i>	1010,47	51,93
<i>12</i>	1016,57	45,58
<i>13</i>	985,40	39,63
<i>14</i>	967,43	39,28
<i>15</i>	938,57	35,84
<i>16</i>	917,80	70,61
<i>17</i>	901,30	73,95
<i>18</i>	884,88	38,88
<i>19</i>	881,62	36,20
<i>20</i>	857,17	38,34
<i>21</i>	838,48	35,05
<i>22</i>	805,18	31,09
<i>23</i>	788,20	31,13
<i>24</i>	753,12	27,36

Tabela D.17 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Inverno)

K	r_k	k	r_k	k	r_k
<i>1</i>	0,702	<i>13</i>	0,227	<i>25</i>	0,050
<i>2</i>	0,562	<i>14</i>	0,194	<i>26</i>	0,003
<i>3</i>	0,458	<i>15</i>	0,148	<i>27</i>	-0,029
<i>4</i>	0,396	<i>16</i>	0,104	<i>28</i>	-0,063
<i>5</i>	0,327	<i>17</i>	0,089	<i>29</i>	-0,090
<i>6</i>	0,271	<i>18</i>	0,088	<i>30</i>	-0,068
<i>7</i>	0,249	<i>19</i>	0,075	<i>31</i>	-0,064
<i>8</i>	0,226	<i>20</i>	0,082	<i>32</i>	-0,063
<i>9</i>	0,230	<i>21</i>	0,083	<i>33</i>	-0,059
<i>10</i>	0,231	<i>22</i>	0,059	<i>34</i>	-0,045
<i>11</i>	0,234	<i>23</i>	0,074	<i>35</i>	-0,043
<i>12</i>	0,240	<i>24</i>	0,074	<i>36</i>	-0,026




Figura D.6 – Função de Autocorrelação para a Série de Consumo para o Reservatório Edu Chaves (Estação inverno)

Tabela D.18 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,566	0,653	0,499

Tabela D.19 – Média e Desvio Padrão para a Série de Consumos do Reservatório Edu Chaves (Estação Primavera)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	675,22	39,53
<i>2</i>	645,00	52,29
<i>3</i>	622,08	59,21
<i>4</i>	618,17	50,58
<i>5</i>	614,80	48,31
<i>6</i>	628,50	45,89
<i>7</i>	685,25	50,16
<i>8</i>	745,60	47,02
<i>9</i>	826,15	53,22
<i>10</i>	882,27	55,00
<i>11</i>	927,68	53,76
<i>12</i>	934,62	59,36
<i>13</i>	918,32	67,38
<i>14</i>	896,35	50,07
<i>15</i>	872,95	47,04
<i>16</i>	844,82	45,41
<i>17</i>	833,55	44,17
<i>18</i>	829,27	39,30
<i>19</i>	838,38	79,06
<i>20</i>	818,03	33,55
<i>21</i>	802,32	32,46
<i>22</i>	769,65	29,29
<i>23</i>	741,17	33,98
<i>24</i>	714,48	37,64

Tabela D.20 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Edu Chaves (Estação Primavera)

K	r_k	k	r_k	k	r_k
<i>1</i>	0,709	<i>13</i>	0,018	<i>25</i>	0,191
<i>2</i>	0,609	<i>14</i>	0,006	<i>26</i>	0,177
<i>3</i>	0,493	<i>15</i>	0,023	<i>27</i>	0,142
<i>4</i>	0,364	<i>16</i>	0,051	<i>28</i>	0,106
<i>5</i>	0,263	<i>17</i>	0,094	<i>29</i>	0,053
<i>6</i>	0,231	<i>18</i>	0,133	<i>30</i>	0,023
<i>7</i>	0,181	<i>19</i>	0,169	<i>31</i>	-0,008
<i>8</i>	0,156	<i>20</i>	0,206	<i>32</i>	-0,022
<i>9</i>	0,121	<i>21</i>	0,200	<i>33</i>	-0,021
<i>10</i>	0,105	<i>22</i>	0,214	<i>34</i>	-0,015
<i>11</i>	0,053	<i>23</i>	0,219	<i>35</i>	-0,036
<i>12</i>	0,027	<i>24</i>	0,222	<i>36</i>	-0,039




Figura D.7 – Função de Autocorrelação para a Série de Consumo para o Reservatório Edu Chaves (Estação Primavera)

Tabela D.21 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,595	0,709	0,308

Tabela D.22 – Média e Desvio Padrão para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Verão)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	577,82	40,73
<i>2</i>	507,27	52,01
<i>3</i>	459,13	54,37
<i>4</i>	438,70	45,28
<i>5</i>	442,30	48,93
<i>6</i>	462,97	53,63
<i>7</i>	509,02	60,83
<i>8</i>	606,80	77,83
<i>9</i>	756,92	108,43
<i>10</i>	929,37	126,46
<i>11</i>	1024,03	103,13
<i>12</i>	1062,88	103,49
<i>13</i>	1047,85	104,90
<i>14</i>	970,50	95,70
<i>15</i>	942,17	117,78
<i>16</i>	864,03	83,14
<i>17</i>	853,75	110,83
<i>18</i>	844,85	88,81
<i>19</i>	842,10	116,02
<i>20</i>	829,27	82,78
<i>21</i>	770,25	78,58
<i>22</i>	749,48	90,72
<i>23</i>	681,15	91,37
<i>24</i>	637,80	68,98

Tabela D.23 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Verão)

K	r_k	k	r_k	k	r_k
<i>1</i>	0,277	<i>13</i>	0,093	<i>25</i>	0,052
<i>2</i>	0,329	<i>14</i>	0,057	<i>26</i>	0,069
<i>3</i>	0,240	<i>15</i>	0,052	<i>27</i>	0,029
<i>4</i>	0,164	<i>16</i>	0,016	<i>28</i>	0,051
<i>5</i>	0,125	<i>17</i>	0,037	<i>29</i>	0,026
<i>6</i>	0,150	<i>18</i>	0,041	<i>30</i>	0,018
<i>7</i>	0,088	<i>19</i>	0,043	<i>31</i>	0,035
<i>8</i>	0,085	<i>20</i>	0,064	<i>32</i>	0,046
<i>9</i>	0,094	<i>21</i>	0,046	<i>33</i>	0,021
<i>10</i>	0,063	<i>22</i>	0,086	<i>34</i>	0,025
<i>11</i>	0,119	<i>23</i>	0,076	<i>35</i>	0,038
<i>12</i>	0,082	<i>24</i>	0,133	<i>36</i>	0,004




Figura D.8 – Função de Autocorrelação para a Série de Consumo para o Reservatório Ermelino Matarazzo (Estação Verão)

Tabela D.24 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,929	0,850	0,821

Tabela D.25 – Média e Desvio Padrão para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Outono)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	557,53	75,87
<i>2</i>	494,30	87,23
<i>3</i>	467,27	74,69
<i>4</i>	457,55	54,79
<i>5</i>	458,87	73,04
<i>6</i>	504,22	81,64
<i>7</i>	577,03	113,23
<i>8</i>	702,27	95,41
<i>9</i>	890,65	100,90
<i>10</i>	1000,11	141,06
<i>11</i>	1094,08	98,09
<i>12</i>	1103,57	109,76
<i>13</i>	1064,20	85,91
<i>14</i>	983,12	90,25
<i>15</i>	950,62	95,88
<i>16</i>	895,88	98,40
<i>17</i>	898,38	85,36
<i>18</i>	900,02	65,94
<i>19</i>	882,77	85,16
<i>20</i>	847,07	167,93
<i>21</i>	793,00	270,85
<i>22</i>	708,05	90,27
<i>23</i>	663,62	84,16
<i>24</i>	597,28	82,16

Tabela D.26 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Outono)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,398	<i>13</i>	0,057	<i>25</i>	0,045
<i>2</i>	0,269	<i>14</i>	0,053	<i>26</i>	0,007
<i>3</i>	0,125	<i>15</i>	0,047	<i>27</i>	-0,011
<i>4</i>	0,042	<i>16</i>	0,007	<i>28</i>	-0,013
<i>5</i>	0,026	<i>17</i>	-0,017	<i>29</i>	0,008
<i>6</i>	0,016	<i>18</i>	-0,023	<i>30</i>	0,020
<i>7</i>	-0,008	<i>19</i>	-0,029	<i>31</i>	0,035
<i>8</i>	-0,011	<i>20</i>	-0,017	<i>32</i>	0,038
<i>9</i>	0,031	<i>21</i>	0,007	<i>33</i>	0,055
<i>10</i>	0,028	<i>22</i>	0,037	<i>34</i>	0,051
<i>11</i>	0,027	<i>23</i>	0,103	<i>35</i>	0,050
<i>12</i>	0,033	<i>24</i>	0,089	<i>36</i>	0,022




Figura D.9 – Função de Autocorrelação para a Série de Consumo para o Reservatório Ermelino Matarazzo (Estação Outono)

Tabela D.27 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,842	0,817	0,819

Tabela D.28 – Média e Desvio Padrão para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Inverno)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	502,15	75,48
<i>2</i>	460,73	68,12
<i>3</i>	433,37	56,09
<i>4</i>	439,72	87,66
<i>5</i>	426,00	57,80
<i>6</i>	454,23	63,95
<i>7</i>	494,43	60,37
<i>8</i>	603,50	80,54
<i>9</i>	739,50	89,73
<i>10</i>	880,33	126,37
<i>11</i>	999,45	139,10
<i>12</i>	1041,12	89,22
<i>13</i>	998,12	95,80
<i>14</i>	942,15	97,36
<i>15</i>	892,68	91,29
<i>16</i>	853,68	89,16
<i>17</i>	795,37	109,38
<i>18</i>	790,30	138,59
<i>19</i>	776,10	101,80
<i>20</i>	754,93	73,53
<i>21</i>	668,57	94,39
<i>22</i>	629,72	72,89
<i>23</i>	603,95	75,26
<i>24</i>	567,60	57,97

Tabela D.29 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Inverno)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,369	<i>13</i>	0,081	<i>25</i>	0,056
<i>2</i>	0,243	<i>14</i>	0,035	<i>26</i>	0,059
<i>3</i>	0,165	<i>15</i>	-0,010	<i>27</i>	0,005
<i>4</i>	0,140	<i>16</i>	-0,031	<i>28</i>	-0,070
<i>5</i>	0,034	<i>17</i>	-0,024	<i>29</i>	-0,054
<i>6</i>	-0,039	<i>18</i>	-0,005	<i>30</i>	-0,081
<i>7</i>	-0,043	<i>19</i>	-0,042	<i>31</i>	-0,064
<i>8</i>	0,027	<i>20</i>	-0,024	<i>32</i>	-0,040
<i>9</i>	0,024	<i>21</i>	-0,012	<i>33</i>	-0,061
<i>10</i>	-0,001	<i>22</i>	0,070	<i>34</i>	-0,046
<i>11</i>	-0,036	<i>23</i>	0,094	<i>35</i>	-0,035
<i>12</i>	0,061	<i>24</i>	0,099	<i>36</i>	0,023




Figura D.10 – Função de Autocorrelação para a Série de Consumo para o Reservatório Ermelino Matarazzo (Estação inverno)

Tabela D.30 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,866	0,843	0,833

Tabela D.31 – Média e Desvio Padrão para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Primavera)

HORAS	MÉDIA	DESVIO PADRÃO
1	515,22	52,28
2	449,87	63,95
3	433,92	54,40
4	415,18	54,36
5	429,50	52,59
6	443,22	49,64
7	523,68	60,22
8	614,87	83,98
9	764,85	88,62
10	908,78	88,52
11	989,18	100,00
12	1024,03	98,00
13	993,48	103,45
14	945,17	94,09
15	875,12	95,54
16	839,30	92,69
17	805,08	94,26
18	805,57	99,69
19	803,40	80,81
20	777,32	71,07
21	721,10	77,14
22	660,03	66,74
23	621,68	54,86
24	592,80	60,25

Tabela D.32 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Ermelino Matarazzo (Estação Primavera)

k	r_k	k	r_k	k	r_k
1	0,217	13	0,060	25	0,090
2	0,353	14	0,052	26	0,046
3	0,201	15	-0,001	27	0,037
4	0,177	16	-0,017	28	0,003
5	0,137	17	-0,018	29	-0,013
6	0,110	18	-0,017	30	-0,043
7	0,101	19	-0,035	31	-0,004
8	0,082	20	0,032	32	-0,048
9	0,108	21	0,020	33	-0,005
10	0,091	22	0,067	34	0,006
11	0,080	23	0,063	35	0,019
12	0,115	24	0,051	36	0,000




Figura D.11 – Função de Autocorrelação para a Série de Consumo para o Reservatório Ermelino Matarazzo (Estação Primavera)

Tabela D.33 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,952	0,848	0,829

Tabela D.34 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Verão)

HORAS	MÉDIA	DESVIO PADRÃO
1	387,93	66,49
2	340,68	68,00
3	269,22	96,14
4	280,35	89,44
5	273,78	89,27
6	296,98	84,97
7	352,02	84,15
8	438,38	82,50
9	564,35	100,65
10	694,18	91,17
11	807,47	125,22
12	841,28	125,22
13	816,97	132,66
14	746,87	118,54
15	697,38	95,08
16	646,92	78,51
17	623,40	80,38
18	632,12	64,38
19	623,37	67,14
20	611,47	63,49
21	586,62	80,32
22	523,75	84,44
23	494,37	72,25
24	445,50	60,97

Tabela D.35 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Verão)

<i>K</i>	r_k	<i>k</i>	r_k	<i>k</i>	r_k
1	0,670	13	0,044	25	0,153
2	0,615	14	0,040	26	0,140
3	0,460	15	0,031	27	0,120
4	0,384	16	0,045	28	0,115
5	0,265	17	0,061	29	0,090
6	0,215	18	0,097	30	0,082
7	0,157	19	0,117	31	0,076
8	0,143	20	0,130	32	0,052
9	0,103	21	0,163	33	0,057
10	0,096	22	0,174	34	0,033
11	0,064	23	0,174	35	0,040
12	0,063	24	0,186	36	0,044




Figura D.12 – Função de Autocorrelação para a Série de Consumo para o Reservatório Cangaíba (Estação Verão)

Tabela D.36 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,674	0,739	0,592

Tabela D.37 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Outono)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	406,75	57,84
<i>2</i>	347,13	75,93
<i>3</i>	303,22	62,78
<i>4</i>	311,50	84,54
<i>5</i>	315,33	81,13
<i>6</i>	338,77	62,39
<i>7</i>	424,47	86,29
<i>8</i>	542,65	77,74
<i>9</i>	667,72	74,77
<i>10</i>	775,02	65,78
<i>11</i>	851,08	90,79
<i>12</i>	854,42	107,09
<i>13</i>	881,20	216,78
<i>14</i>	762,55	52,32
<i>15</i>	727,75	57,97
<i>16</i>	681,50	68,53
<i>17</i>	662,42	50,37
<i>18</i>	664,25	48,64
<i>19</i>	672,48	52,01
<i>20</i>	616,23	45,94
<i>21</i>	570,42	50,89
<i>22</i>	527,48	55,02
<i>23</i>	491,65	60,53
<i>24</i>	453,50	69,10

Tabela D.38 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Outono)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,453	<i>13</i>	0,042	<i>25</i>	0,220
<i>2</i>	0,467	<i>14</i>	0,041	<i>26</i>	0,188
<i>3</i>	0,295	<i>15</i>	0,026	<i>27</i>	0,162
<i>4</i>	0,182	<i>16</i>	0,039	<i>28</i>	0,133
<i>5</i>	0,146	<i>17</i>	0,069	<i>29</i>	0,124
<i>6</i>	0,088	<i>18</i>	0,073	<i>30</i>	0,102
<i>7</i>	0,077	<i>19</i>	0,148	<i>31</i>	0,074
<i>8</i>	0,088	<i>20</i>	0,151	<i>32</i>	0,086
<i>9</i>	0,090	<i>21</i>	0,191	<i>33</i>	0,078
<i>10</i>	0,128	<i>22</i>	0,237	<i>34</i>	0,056
<i>11</i>	0,117	<i>23</i>	0,245	<i>35</i>	0,056
<i>12</i>	0,083	<i>24</i>	0,237	<i>36</i>	0,057




Figura D.13 – Função de Autocorrelação para a Série de Consumo para o Reservatório Cangaíba (Estação Outono)

Tabela D.39 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,848	0,755	0,731

Tabela D.40 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Inverno)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	324,28	46,31
<i>2</i>	291,42	40,21
<i>3</i>	267,50	33,41
<i>4</i>	237,98	37,56
<i>5</i>	241,75	37,80
<i>6</i>	273,38	37,91
<i>7</i>	339,67	49,09
<i>8</i>	421,10	65,54
<i>9</i>	566,07	70,44
<i>10</i>	687,33	65,92
<i>11</i>	815,48	87,20
<i>12</i>	829,57	83,38
<i>13</i>	826,03	99,04
<i>14</i>	742,67	74,32
<i>15</i>	705,02	69,65
<i>16</i>	632,13	89,12
<i>17</i>	612,42	74,38
<i>18</i>	605,23	64,89
<i>19</i>	579,95	69,13
<i>20</i>	547,75	64,36
<i>21</i>	497,37	50,27
<i>22</i>	455,60	48,82
<i>23</i>	428,47	39,20
<i>24</i>	372,35	35,56

Tabela D.41 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Inverno)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,284	<i>13</i>	0,083	<i>25</i>	0,083
<i>2</i>	0,279	<i>14</i>	0,040	<i>26</i>	0,021
<i>3</i>	0,122	<i>15</i>	0,039	<i>27</i>	-0,006
<i>4</i>	0,089	<i>16</i>	-0,014	<i>28</i>	-0,016
<i>5</i>	0,002	<i>17</i>	-0,014	<i>29</i>	-0,077
<i>6</i>	0,000	<i>18</i>	-0,008	<i>30</i>	-0,035
<i>7</i>	0,028	<i>19</i>	-0,017	<i>31</i>	-0,031
<i>8</i>	0,050	<i>20</i>	-0,003	<i>32</i>	-0,034
<i>9</i>	0,075	<i>21</i>	0,009	<i>33</i>	0,017
<i>10</i>	0,107	<i>22</i>	0,086	<i>34</i>	0,033
<i>11</i>	0,091	<i>23</i>	0,105	<i>35</i>	0,028
<i>12</i>	0,084	<i>24</i>	0,096	<i>36</i>	0,051




Figura D.14 – Função de Autocorrelação para a Série de Consumo para o Reservatório Cangaíba (Estação inverno)

Tabela D.42 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,921	0,869	0,868

Tabela D.43 – Média e Desvio Padrão para a Série de Consumos do Reservatório Cangaíba (Estação Primavera)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	339,03	51,21
<i>2</i>	286,17	43,19
<i>3</i>	234,00	50,49
<i>4</i>	254,57	48,66
<i>5</i>	232,33	60,49
<i>6</i>	276,52	51,26
<i>7</i>	345,62	65,25
<i>8</i>	450,38	66,37
<i>9</i>	573,25	79,95
<i>10</i>	684,77	71,40
<i>11</i>	780,70	93,08
<i>12</i>	807,67	72,85
<i>13</i>	781,53	93,40
<i>14</i>	719,73	67,09
<i>15</i>	676,83	73,15
<i>16</i>	616,98	74,05
<i>17</i>	583,88	90,87
<i>18</i>	579,32	83,93
<i>19</i>	584,00	83,28
<i>20</i>	552,53	86,25
<i>21</i>	539,33	78,23
<i>22</i>	465,35	82,79
<i>23</i>	436,85	69,58
<i>24</i>	384,20	60,88

Tabela D.44 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Cangaíba (Estação Primavera)

<i>K</i>	r_k	<i>k</i>	r_k	<i>k</i>	r_k
<i>1</i>	0,478	<i>13</i>	0,038	<i>25</i>	0,083
<i>2</i>	0,494	<i>14</i>	0,049	<i>26</i>	0,070
<i>3</i>	0,248	<i>15</i>	0,044	<i>27</i>	0,028
<i>4</i>	0,187	<i>16</i>	0,049	<i>28</i>	0,002
<i>5</i>	0,054	<i>17</i>	0,071	<i>29</i>	-0,019
<i>6</i>	0,006	<i>18</i>	0,037	<i>30</i>	-0,014
<i>7</i>	-0,044	<i>19</i>	0,066	<i>31</i>	-0,037
<i>8</i>	-0,011	<i>20</i>	0,074	<i>32</i>	-0,010
<i>9</i>	-0,040	<i>21</i>	0,077	<i>33</i>	0,005
<i>10</i>	-0,003	<i>22</i>	0,092	<i>34</i>	0,027
<i>11</i>	0,015	<i>23</i>	0,083	<i>35</i>	0,035
<i>12</i>	0,012	<i>24</i>	0,115	<i>36</i>	0,044




Figura D.15 – Função de Autocorrelação para a Série de Consumo para o Reservatório Cangaíba (Estação Primavera)

Tabela D.45 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,836	0,743	0,742

Tabela D.46 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopoúva (Estação Verão)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	2190,27	283,56
<i>2</i>	2116,47	374,93
<i>3</i>	1949,65	343,31
<i>4</i>	1907,83	323,78
<i>5</i>	1905,10	327,47
<i>6</i>	1906,92	336,31
<i>7</i>	2056,88	287,32
<i>8</i>	2291,33	264,42
<i>9</i>	2426,40	293,38
<i>10</i>	2545,23	314,58
<i>11</i>	2634,65	298,38
<i>12</i>	2623,83	371,24
<i>13</i>	2639,52	344,51
<i>14</i>	2593,37	342,26
<i>15</i>	2552,23	325,66
<i>16</i>	2508,15	267,77
<i>17</i>	2453,32	305,90
<i>18</i>	2408,62	293,54
<i>19</i>	2446,63	291,75
<i>20</i>	2436,10	328,14
<i>21</i>	2355,48	317,20
<i>22</i>	2374,72	302,48
<i>23</i>	2363,55	461,41
<i>24</i>	2211,40	337,74

Tabela D.47 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopoúva (Estação Verão)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,546	<i>13</i>	-0,019	<i>25</i>	0,066
<i>2</i>	0,158	<i>14</i>	-0,030	<i>26</i>	0,040
<i>3</i>	-0,005	<i>15</i>	-0,079	<i>27</i>	0,040
<i>4</i>	-0,056	<i>16</i>	-0,077	<i>28</i>	0,024
<i>5</i>	-0,053	<i>17</i>	-0,014	<i>29</i>	-0,017
<i>6</i>	-0,053	<i>18</i>	0,045	<i>30</i>	-0,057
<i>7</i>	-0,044	<i>19</i>	0,069	<i>31</i>	-0,046
<i>8</i>	-0,036	<i>20</i>	0,055	<i>32</i>	-0,068
<i>9</i>	-0,040	<i>21</i>	0,039	<i>33</i>	-0,088
<i>10</i>	-0,057	<i>22</i>	0,079	<i>34</i>	-0,042
<i>11</i>	-0,058	<i>23</i>	0,111	<i>35</i>	-0,014
<i>12</i>	-0,047	<i>24</i>	0,109	<i>36</i>	0,000




Figura D.16 – Função de Autocorrelação para a Série de Consumo para o Reservatório de Gopóuva (Estação Verão)

Tabela D.48 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,632	0,655	0,654

Tabela D.49 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopouva (Estação Outono)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	2178,17	304,56
<i>2</i>	2071,12	281,46
<i>3</i>	1959,03	293,40
<i>4</i>	1898,17	312,52
<i>5</i>	1929,32	319,36
<i>6</i>	1990,55	254,79
<i>7</i>	2188,57	188,75
<i>8</i>	2257,38	277,03
<i>9</i>	2378,92	330,15
<i>10</i>	2386,96	295,51
<i>11</i>	2377,97	304,21
<i>12</i>	2364,28	316,42
<i>13</i>	2317,50	357,44
<i>14</i>	2296,62	332,49
<i>15</i>	2222,07	336,36
<i>16</i>	2166,62	368,41
<i>17</i>	2068,63	450,86
<i>18</i>	2069,32	408,70
<i>19</i>	2207,77	325,18
<i>20</i>	2400,82	336,22
<i>21</i>	2453,27	342,07
<i>22</i>	2491,47	314,26
<i>23</i>	2489,48	238,10
<i>24</i>	2346,08	289,56

Tabela E.50– Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopouva (Estação Outono)

K	r_k	k	r_k	k	r_k
<i>1</i>	0,577	<i>13</i>	-0,030	<i>25</i>	0,057
<i>2</i>	0,119	<i>14</i>	-0,021	<i>26</i>	0,050
<i>3</i>	-0,124	<i>15</i>	-0,008	<i>27</i>	0,017
<i>4</i>	-0,196	<i>16</i>	-0,011	<i>28</i>	0,014
<i>5</i>	-0,181	<i>17</i>	-0,012	<i>29</i>	0,007
<i>6</i>	-0,144	<i>18</i>	0,003	<i>30</i>	-0,045
<i>7</i>	-0,095	<i>19</i>	-0,030	<i>31</i>	-0,086
<i>8</i>	-0,048	<i>20</i>	-0,073	<i>32</i>	-0,054
<i>9</i>	-0,011	<i>21</i>	-0,074	<i>33</i>	-0,007
<i>10</i>	0,004	<i>22</i>	-0,028	<i>34</i>	0,027
<i>11</i>	-0,012	<i>23</i>	0,009	<i>35</i>	0,048
<i>12</i>	-0,036	<i>24</i>	0,052	<i>36</i>	0,056




Figura D.17 – Função de Autocorrelação para a Série de Consumo para o Reservatório Gopóuva (Estação Outono)

Tabela D.51 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,552	0,577	0,559

Tabela D.52 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopouva (Estação Inverno)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	2005,32	335,97
<i>2</i>	1923,67	364,29
<i>3</i>	1875,28	371,32
<i>4</i>	1886,28	339,01
<i>5</i>	1847,82	349,36
<i>6</i>	1875,68	355,36
<i>7</i>	1953,60	299,24
<i>8</i>	2128,62	353,78
<i>9</i>	2458,28	329,34
<i>10</i>	2623,68	326,86
<i>11</i>	2697,33	272,40
<i>12</i>	2720,15	296,04
<i>13</i>	2643,03	285,61
<i>14</i>	2645,18	434,82
<i>15</i>	2458,90	290,42
<i>16</i>	2345,73	357,14
<i>17</i>	2312,55	408,31
<i>18</i>	2198,00	493,44
<i>19</i>	2228,55	340,69
<i>20</i>	2265,90	311,48
<i>21</i>	2316,20	252,94
<i>22</i>	2259,97	236,72
<i>23</i>	2166,62	286,38
<i>24</i>	2067,17	337,21

Tabela D.53 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopouva (Estação Inverno)

<i>K</i>	r_k	<i>k</i>	r_k	<i>k</i>	r_k
<i>1</i>	0,519	<i>13</i>	-0,023	<i>25</i>	0,043
<i>2</i>	0,083	<i>14</i>	0,009	<i>26</i>	0,015
<i>3</i>	-0,116	<i>15</i>	0,053	<i>27</i>	0,011
<i>4</i>	-0,167	<i>16</i>	0,048	<i>28</i>	-0,011
<i>5</i>	-0,097	<i>17</i>	0,004	<i>29</i>	-0,021
<i>6</i>	-0,023	<i>18</i>	-0,031	<i>30</i>	-0,021
<i>7</i>	0,007	<i>19</i>	-0,003	<i>31</i>	-0,017
<i>8</i>	-0,006	<i>20</i>	-0,003	<i>32</i>	-0,035
<i>9</i>	-0,079	<i>21</i>	-0,006	<i>33</i>	-0,036
<i>10</i>	-0,103	<i>22</i>	0,003	<i>34</i>	-0,003
<i>11</i>	-0,069	<i>23</i>	0,052	<i>35</i>	-0,004
<i>12</i>	-0,054	<i>24</i>	0,085	<i>36</i>	-0,004




Figura D.18 – Função de Autocorrelação para a Série de Consumo para o Reservatório Gopóuva (Estação Inverno)

Tabela D.54 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,651	0,667	0,654

Tabela D.55 – Média e Desvio Padrão para a Série de Consumos do Reservatório Gopouva (Estação Primavera)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	2009,80	372,79
<i>2</i>	1904,78	358,67
<i>3</i>	1867,05	319,67
<i>4</i>	1841,32	354,49
<i>5</i>	1801,63	348,24
<i>6</i>	1784,43	354,13
<i>7</i>	1990,28	335,47
<i>8</i>	2283,02	361,26
<i>9</i>	2542,83	356,85
<i>10</i>	2647,70	393,62
<i>11</i>	2787,12	366,86
<i>12</i>	2847,77	288,72
<i>13</i>	2795,33	367,67
<i>14</i>	2779,93	352,83
<i>15</i>	2719,62	283,79
<i>16</i>	2672,88	255,68
<i>17</i>	2540,53	329,11
<i>18</i>	2529,63	341,53
<i>19</i>	2475,53	360,86
<i>20</i>	2458,87	316,36
<i>21</i>	2321,78	350,60
<i>22</i>	2252,72	329,64
<i>23</i>	2207,78	310,34
<i>24</i>	2116,33	326,15

Tabela D.56 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Gopouva (Estação Primavera)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,445	<i>13</i>	0,001	<i>25</i>	0,039
<i>2</i>	-0,077	<i>14</i>	0,026	<i>26</i>	0,079
<i>3</i>	-0,239	<i>15</i>	0,030	<i>27</i>	0,098
<i>4</i>	-0,193	<i>16</i>	0,020	<i>28</i>	0,007
<i>5</i>	-0,048	<i>17</i>	0,007	<i>29</i>	-0,070
<i>6</i>	0,060	<i>18</i>	0,009	<i>30</i>	-0,068
<i>7</i>	0,093	<i>19</i>	0,016	<i>31</i>	-0,041
<i>8</i>	0,079	<i>20</i>	0,037	<i>32</i>	0,003
<i>9</i>	0,021	<i>21</i>	0,041	<i>33</i>	0,044
<i>10</i>	-0,042	<i>22</i>	0,032	<i>34</i>	0,062
<i>11</i>	-0,064	<i>23</i>	0,008	<i>35</i>	0,050
<i>12</i>	-0,050	<i>24</i>	0,018	<i>36</i>	-0,007




Figura D.19 – Função de Autocorrelação para a Série de Consumo para o Reservatório Gopóuva (Estação Primavera)

Tabela D.57 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,722	0,701	0,678

Tabela D.58 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Verão)

HORAS	MÉDIA	DESVIO PADRÃO
1	524,77	43,04
2	456,90	35,41
3	416,55	29,55
4	394,78	31,14
5	390,37	31,56
6	408,88	36,17
7	485,18	54,48
8	606,40	91,47
9	758,38	109,38
10	867,33	98,09
11	944,58	80,19
12	958,20	68,09
13	934,10	77,13
14	884,98	64,16
15	851,00	65,87
16	809,60	65,25
17	782,82	66,21
18	769,53	65,93
19	769,48	62,97
20	743,57	65,86
21	730,48	72,06
22	676,05	47,91
23	641,37	58,13
24	585,63	40,96

Tabela D.59 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Verão)

k	r_k	k	r_k	k	r_k
1	0,438	13	0,178	25	0,041
2	0,258	14	0,125	26	0,070
3	0,322	15	0,079	27	0,037
4	0,384	16	0,099	28	0,077
5	0,246	17	0,114	29	0,095
6	0,155	18	0,081	30	0,057
7	0,227	19	0,034	31	0,042
8	0,282	20	0,088	32	0,110
9	0,242	21	0,163	33	0,113
10	0,212	22	0,139	34	0,096
11	0,217	23	0,096	35	0,054
12	0,209	24	0,141	36	0,058




Figura D.20 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jaçanã (Estação Verão)

Tabela D.60 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,810	0,797	0,720

Tabela D.61 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Outono)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	521,82	33,69
<i>2</i>	469,00	39,83
<i>3</i>	429,08	28,39
<i>4</i>	416,65	26,60
<i>5</i>	420,85	34,77
<i>6</i>	441,42	32,31
<i>7</i>	585,43	79,76
<i>8</i>	703,67	124,98
<i>9</i>	856,25	79,49
<i>10</i>	940,80	75,86
<i>11</i>	991,15	54,00
<i>12</i>	994,77	45,51
<i>13</i>	954,62	51,09
<i>14</i>	909,82	70,85
<i>15</i>	871,42	105,22
<i>16</i>	828,00	103,04
<i>17</i>	812,32	90,37
<i>18</i>	803,07	77,55
<i>19</i>	789,77	48,95
<i>20</i>	761,72	59,70
<i>21</i>	715,18	44,38
<i>22</i>	672,10	38,35
<i>23</i>	635,85	38,95
<i>24</i>	592,15	31,13

Tabela D.62 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Outono)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,535	<i>13</i>	0,001	<i>25</i>	0,021
<i>2</i>	0,413	<i>14</i>	-0,030	<i>26</i>	-0,016
<i>3</i>	0,334	<i>15</i>	-0,027	<i>27</i>	-0,001
<i>4</i>	0,202	<i>16</i>	-0,053	<i>28</i>	-0,034
<i>5</i>	0,098	<i>17</i>	-0,047	<i>29</i>	-0,059
<i>6</i>	0,022	<i>18</i>	-0,034	<i>30</i>	-0,035
<i>7</i>	0,007	<i>19</i>	-0,039	<i>31</i>	-0,014
<i>8</i>	-0,015	<i>20</i>	-0,029	<i>32</i>	0,044
<i>9</i>	0,017	<i>21</i>	-0,039	<i>33</i>	0,052
<i>10</i>	0,020	<i>22</i>	0,003	<i>34</i>	0,067
<i>11</i>	0,005	<i>23</i>	0,075	<i>35</i>	0,080
<i>12</i>	0,010	<i>24</i>	0,081	<i>36</i>	0,074




Figura D.21 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jaçanã (Estação Outono)

Tabela D.63 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,745	0,718	0,667

Tabela D.64 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Inverno)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	478,88	49,09
<i>2</i>	417,83	55,48
<i>3</i>	393,23	36,65
<i>4</i>	385,80	40,28
<i>5</i>	384,17	46,52
<i>6</i>	414,22	45,21
<i>7</i>	489,52	57,94
<i>8</i>	604,05	94,15
<i>9</i>	739,20	100,44
<i>10</i>	839,22	94,51
<i>11</i>	907,72	91,54
<i>12</i>	917,80	82,52
<i>13</i>	884,15	76,07
<i>14</i>	851,00	72,71
<i>15</i>	807,73	83,74
<i>16</i>	765,27	90,13
<i>17</i>	718,53	86,44
<i>18</i>	714,73	84,74
<i>19</i>	706,33	102,38
<i>20</i>	684,58	94,60
<i>21</i>	648,55	58,71
<i>22</i>	605,27	51,62
<i>23</i>	580,37	49,40
<i>24</i>	546,33	44,49

Tabela D.65 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Inverno)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,480	<i>13</i>	0,096	<i>25</i>	0,026
<i>2</i>	0,261	<i>14</i>	0,081	<i>26</i>	0,041
<i>3</i>	0,400	<i>15</i>	0,051	<i>27</i>	0,007
<i>4</i>	0,323	<i>16</i>	0,063	<i>28</i>	-0,059
<i>5</i>	0,175	<i>17</i>	0,046	<i>29</i>	-0,010
<i>6</i>	0,147	<i>18</i>	0,000	<i>30</i>	0,017
<i>7</i>	0,113	<i>19</i>	0,031	<i>31</i>	-0,023
<i>8</i>	0,098	<i>20</i>	0,077	<i>32</i>	-0,001
<i>9</i>	0,112	<i>21</i>	0,055	<i>33</i>	0,035
<i>10</i>	0,122	<i>22</i>	0,060	<i>34</i>	0,033
<i>11</i>	0,085	<i>23</i>	0,112	<i>35</i>	0,021
<i>12</i>	0,083	<i>24</i>	0,090	<i>36</i>	0,007




Figura D.22 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jaçanã (Estação Inverno)

Tabela D.66 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,766	0,762	0,623

Tabela D.67 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jaçanã (Estação Primavera)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	475,52	41,69
<i>2</i>	411,08	49,57
<i>3</i>	378,63	37,85
<i>4</i>	369,18	32,47
<i>5</i>	360,70	29,85
<i>6</i>	388,18	36,18
<i>7</i>	517,05	76,90
<i>8</i>	635,92	100,20
<i>9</i>	764,63	92,52
<i>10</i>	856,88	101,44
<i>11</i>	917,45	81,40
<i>12</i>	936,17	64,15
<i>13</i>	894,38	74,64
<i>14</i>	848,80	63,11
<i>15</i>	816,23	70,08
<i>16</i>	770,28	63,16
<i>17</i>	734,07	63,82
<i>18</i>	717,73	72,72
<i>19</i>	715,10	67,99
<i>20</i>	696,55	58,29
<i>21</i>	661,00	58,11
<i>22</i>	611,82	54,86
<i>23</i>	581,02	54,61
<i>24</i>	532,37	39,47

Tabela D.68 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jaçanã (Estação Primavera)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,395	<i>13</i>	0,143	<i>25</i>	0,115
<i>2</i>	0,160	<i>14</i>	0,088	<i>26</i>	0,123
<i>3</i>	0,304	<i>15</i>	0,079	<i>27</i>	0,079
<i>4</i>	0,423	<i>16</i>	0,088	<i>28</i>	0,040
<i>5</i>	0,212	<i>17</i>	0,073	<i>29</i>	0,033
<i>6</i>	0,049	<i>18</i>	0,060	<i>30</i>	0,062
<i>7</i>	0,169	<i>19</i>	0,074	<i>31</i>	0,047
<i>8</i>	0,218	<i>20</i>	0,088	<i>32</i>	0,016
<i>9</i>	0,153	<i>21</i>	0,098	<i>33</i>	0,066
<i>10</i>	0,110	<i>22</i>	0,157	<i>34</i>	0,062
<i>11</i>	0,182	<i>23</i>	0,160	<i>35</i>	0,057
<i>12</i>	0,204	<i>24</i>	0,113	<i>36</i>	0,034




Figura D.23 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jaçanã (Estação Primavera)

Tabela D.69 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,983	0,831	0,745

Tabela D.70 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Verão)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	217,37	32,54
<i>2</i>	200,92	17,15
<i>3</i>	171,88	37,96
<i>4</i>	147,72	36,75
<i>5</i>	165,37	33,93
<i>6</i>	148,92	40,69
<i>7</i>	184,75	26,61
<i>8</i>	227,55	66,97
<i>9</i>	297,57	57,78
<i>10</i>	369,67	54,75
<i>11</i>	433,90	68,72
<i>12</i>	462,43	61,67
<i>13</i>	458,40	64,09
<i>14</i>	413,02	64,98
<i>15</i>	399,22	57,30
<i>16</i>	367,72	45,85
<i>17</i>	350,35	46,15
<i>18</i>	346,63	49,40
<i>19</i>	350,90	41,32
<i>20</i>	333,77	49,83
<i>21</i>	325,50	44,47
<i>22</i>	294,80	37,85
<i>23</i>	278,77	34,32
<i>24</i>	261,10	40,66

Tabela D.71 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Verão)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,235	<i>13</i>	0,170	<i>25</i>	0,153
<i>2</i>	0,371	<i>14</i>	0,197	<i>26</i>	0,164
<i>3</i>	0,300	<i>15</i>	0,137	<i>27</i>	0,122
<i>4</i>	0,229	<i>16</i>	0,183	<i>28</i>	0,121
<i>5</i>	0,213	<i>17</i>	0,169	<i>29</i>	0,113
<i>6</i>	0,197	<i>18</i>	0,161	<i>30</i>	0,132
<i>7</i>	0,184	<i>19</i>	0,170	<i>31</i>	0,103
<i>8</i>	0,202	<i>20</i>	0,126	<i>32</i>	0,117
<i>9</i>	0,206	<i>21</i>	0,176	<i>33</i>	0,182
<i>10</i>	0,185	<i>22</i>	0,185	<i>34</i>	0,114
<i>11</i>	0,215	<i>23</i>	0,189	<i>35</i>	0,204
<i>12</i>	0,217	<i>24</i>	0,196	<i>36</i>	0,128




Figura D.24 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jardim Popular (Estação Verão)

Tabela D.72 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,947	0,835	0,776

Tabela D.73 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Outono)

HORAS	MÉDIA	DESVIO PADRÃO
1	219,03	40,32
2	204,45	38,76
3	171,25	54,63
4	168,42	52,77
5	166,45	49,06
6	174,87	52,23
7	218,12	44,61
8	265,73	55,90
9	346,73	47,55
10	402,27	49,94
11	464,83	66,41
12	461,63	69,15
13	447,12	47,18
14	428,25	49,03
15	411,32	41,29
16	370,88	34,50
17	362,23	32,07
18	353,32	36,59
19	355,33	33,79
20	335,03	38,17
21	314,32	33,88
22	290,55	38,84
23	266,72	37,56
24	251,97	41,00

Tabela D.74 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Outono)

k	r_k	k	r_k	k	r_k
1	0,362	13	0,169	25	0,203
2	0,470	14	0,136	26	0,193
3	0,325	15	0,116	27	0,156
4	0,299	16	0,138	28	0,127
5	0,239	17	0,108	29	0,099
6	0,205	18	0,125	30	0,111
7	0,192	19	0,171	31	0,086
8	0,179	20	0,176	32	0,103
9	0,186	21	0,179	33	0,116
10	0,188	22	0,225	34	0,105
11	0,208	23	0,232	35	0,100
12	0,159	24	0,258	36	0,078




Figura D.25 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jardim Popular (Estação Outono)

Tabela D.75 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,898	0,760	0,714

Tabela D.76 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Inverno)

HORAS	MÉDIA	DESVIO PADRÃO
1	204,98	11,60
2	151,75	41,55
3	146,72	47,01
4	152,93	40,88
5	136,27	40,31
6	169,52	39,16
7	172,38	41,77
8	241,00	41,01
9	299,63	48,72
10	378,67	44,23
11	438,55	44,76
12	457,83	53,25
13	450,23	34,67
14	422,48	34,95
15	397,87	27,72
16	369,47	40,72
17	338,28	42,19
18	337,37	33,08
19	328,08	44,55
20	307,20	29,29
21	282,07	38,01
22	257,58	28,60
23	240,22	29,03
24	223,37	17,11

Tabela D.77 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Inverno)

k	r_k	k	r_k	k	r_k
1	-0,060	13	0,043	25	0,015
2	0,420	14	0,008	26	0,029
3	0,087	15	0,039	27	-0,027
4	0,170	16	0,005	28	-0,075
5	0,112	17	0,006	29	0,001
6	0,039	18	-0,013	30	-0,084
7	0,093	19	0,001	31	0,002
8	0,040	20	0,015	32	-0,058
9	0,084	21	0,006	33	0,016
10	0,041	22	0,079	34	-0,042
11	0,092	23	-0,001	35	0,007
12	0,011	24	0,089	36	0,015




Figura D.26 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jardim Popular (Estação Inverno)

Tabela D.78 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,981	0,810	0,796

Tabela D.79 – Média e Desvio Padrão para a Série de Consumos do Reservatório Jardim Popular (Estação Primavera)

HORAS	MÉDIA	DESVIO PADRÃO
<i>1</i>	201,60	13,83
<i>2</i>	183,73	47,11
<i>3</i>	131,58	53,56
<i>4</i>	156,60	35,76
<i>5</i>	121,73	43,16
<i>6</i>	153,65	40,60
<i>7</i>	186,35	43,81
<i>8</i>	225,00	43,73
<i>9</i>	298,05	51,39
<i>10</i>	358,12	50,04
<i>11</i>	405,97	50,64
<i>12</i>	430,77	53,86
<i>13</i>	425,87	60,62
<i>14</i>	393,88	45,30
<i>15</i>	386,47	74,10
<i>16</i>	341,52	47,05
<i>17</i>	32,73	41,54
<i>18</i>	322,73	37,46
<i>19</i>	325,80	37,01
<i>20</i>	311,90	32,42
<i>21</i>	291,20	32,53
<i>22</i>	260,90	32,93
<i>23</i>	239,45	34,08
<i>24</i>	226,12	26,69

Tabela D.80 – Estimativas da Função de Autocorrelação para a Série de Consumos do Reservatório Jardim Popular (Estação Primavera)

<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>	<i>k</i>	<i>r_k</i>
<i>1</i>	0,210	<i>13</i>	0,156	<i>25</i>	0,141
<i>2</i>	0,410	<i>14</i>	0,077	<i>26</i>	0,080
<i>3</i>	0,292	<i>15</i>	0,104	<i>27</i>	0,080
<i>4</i>	0,167	<i>16</i>	0,079	<i>28</i>	0,036
<i>5</i>	0,126	<i>17</i>	0,067	<i>29</i>	0,014
<i>6</i>	0,112	<i>18</i>	0,031	<i>30</i>	0,022
<i>7</i>	0,111	<i>19</i>	0,081	<i>31</i>	0,033
<i>8</i>	0,074	<i>20</i>	0,043	<i>32</i>	0,056
<i>9</i>	0,120	<i>21</i>	0,098	<i>33</i>	0,055
<i>10</i>	0,165	<i>22</i>	0,122	<i>34</i>	0,079
<i>11</i>	0,108	<i>23</i>	0,123	<i>35</i>	0,073
<i>12</i>	0,148	<i>24</i>	0,103	<i>36</i>	0,043




Figura D.27 – Função de Autocorrelação para a Série de Consumo para o Reservatório Jardim Popular (Estação Primavera)

Tabela D.81 – Variância dos Resíduos para Diferentes Modelos AR

Variância	AR(1)	AR(2)	AR(3)
σ_a^2	0,957	0,813	0,756