

Janaina Veiga Carvalho

**Modelagem temporal das medidas de vazão de drenos
na Barragem de Funil (RJ)
utilizando redes neurais e métodos estatísticos.**

TESE DE DOUTORADO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil do Departamento de Engenharia Civil da PUC-Rio como parte dos requisitos parciais para obtenção do título de Doutor em Engenharia Civil. Área de Concentração: Geotecnia.

Orientador: Celso Romanel

Rio de Janeiro
Março de 2005

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.



Janaina Veiga Carvalho

**Modelagem temporal das medias de vazão de drenos
na Barragem de Funil (RJ)
utilizando redes neurais e métodos estatísticos**

Tese apresentada como requisito parcial para obtenção do título de Doutor pelo Programa de Pós-Graduação em Engenharia Civil da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Celso Romanel

Presidente/Orientador

Departamento de Engenharia Civil – PUC-Rio

Profa. Deane de Mesquita Roehl

Departamento de Engenharia Civil – PUC-Rio

Prof. Paulo Batista Gonçalves

Departamento de Engenharia Civil – PUC-Rio

Profa. Andréa Sell Dyminski

UFPR

Prof. Fernando Saboya Albuquerque Junior

UENF

Prof. Eduardo Parente Ribeiro

UFPR

Prof. José Eugenio Leal

Coordenador Setorial

do Centro Técnico Científico – PUC-Rio

Rio de Janeiro, 29 de março de 2005

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Janaina Veiga Carvalho

Graduou-se em Engenharia Civil na UFPa (Universidade Federal do Pará) em 1998. Fez o curso de Mestrado pelo Departamento de Engenharia Civil da PUC-Rio no período de 1998 a 2000.

Ficha catalográfica

Carvalho, Janaina Veiga

Modelagem temporal das medidas de vazão de drenos na Barragem de Funil (RJ) utilizando redes neurais e métodos estatísticos / Janaina Veiga Carvalho ; orientador: Celso Romanel. – Rio de Janeiro : PUC, Departamento de Engenharia Civil, 2005.

v. , 185 f. : IL. ; 29,7 cm;

Tese (doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Civil.

Inclui referências bibliográficas

1. Engenharia civil – Teses. 2. Barragem Funil. 3. Redes neurais temporais. 4. Intervalos de confiança. 5. Monitoramento de barragens. 6. Séries temporais. 7. Instrumentação. I. Romanel, Celso. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Civil . III. Título.

CDD: 624

Para meus pais, Agostinho e Ivone, e para
meu querido esposo Carlos Vitor.

Agradecimentos

A Deus, meu Criador e perene Inspiração.

Ao meu orientador, Celso Romanel, pela orientação, pelo incentivo constante, pela dedicação, pelos conhecimentos transmitidos durante os cursos de mestrado e doutorado, pela confiança depositada em meu trabalho e principalmente pela oportunidade de estudar e desenvolver esta tese.

Ao meu esposo Carlos Vitor pela compreensão, força, apoio, ajuda e incentivo durante todo o tempo.

Ao meu pai Agostinho Veiga e minha mãe Ivone Veiga a minha eterna gratidão pelo apoio e incentivo que me deram para desenvolver este trabalho e ao longo de toda a minha vida.

Ao Departamento de Engenharia Civil de Furnas Centrais Elétricas S.A. pelo apoio incondicional e por permitir total acesso aos dados instrumentais da barragem Funil apresentados neste trabalho.

A todos os professores do Departamento de Engenharia Civil pelos ensinamentos transmitidos.

Aos funcionários de Departamento de Engenharia Civil principalmente à Ana Roxo pelo apoio.

Aos colegas de curso da PUC-Rio, com os quais compartilhei inesquecíveis experiências acadêmicas e de vida.

À CAPES, à FAPERJ e à PUC-Rio, pelos auxílios concedidos, fundamentais para que este trabalho pudesse ser desenvolvido.

Resumo

Carvalho, Janaina Veiga; **Modelagem temporal das medidas de vazão de drenos na Barragem de Funil (RJ) utilizando redes neurais e métodos estatísticos.** Rio de Janeiro, 2005, 185p. Tese de Doutorado – Departamento de Engenharia Civil, Pontifícia Universidade Católica do Rio de Janeiro.

Em obras de maior porte e grande responsabilidade (portos, barragens, usinas nucleares, etc.), a quantidade de instrumentações pode se tornar suficiente para permitir a construção de modelos de variabilidade temporal das propriedades de interesse com base em redes neurais artificiais. No caso de barragens, o monitoramento através da instalação de um sistema de instrumentação desempenha um papel fundamental na avaliação do comportamento destas estruturas, tanto durante o período de construção quanto no período de operação. Neste trabalho empregou-se a técnica de redes neurais temporais (RNT) para análise, modelagem e previsão dos valores de vazão na barragem Funil, do sistema Furnas Centrais Elétricas, a partir dos dados de instrumentações disponíveis no período compreendido entre 02/09/1985 e 25/02/2002. As redes neurais temporais empregadas foram: RNT com arquitetura feedforward associada a técnica de janelamento, RNT recorrente Elman, RNT FIR e RNT Jordan. Adicionalmente, foram utilizadas duas técnicas para análise das séries temporais: os modelos de Box & Jenkins (1970) e métodos geoestatísticos, com a finalidade de comparar com o desempenho das RNT's. Nesta pesquisa estuda-se ainda a geração de intervalos de confiança para RNT e para métodos geoestatísticos. As previsões de vazão analisadas neste trabalho, envolvendo o comportamento da barragem Funil, apresentaram resultados satisfatórios tanto os obtidos pelos modelos de redes neurais temporais como pelos de Box & Jenkins e métodos geoestatísticos.

Palavras-chave

Barragem Funil, Redes neurais temporais, Intervalos de confiança, Monitoramento de barragem, Séries temporais, Instrumentação.

Abstract

Carvalho, Janaina Veiga; **Temporal modelling of the water discharges measurements on Funil Dam (RJ) using neural network and statistical methods.** Rio de Janeiro, 2005, 185p. D. Sc. Thesis – Civil Engineering Department, Pontificia Universidade Católica do Rio de Janeiro.

In works of great responsibility (ports, dams, nuclear power, etc.), the amount of instrumentation data may allow the construction of models for the temporary variability of the properties of interest based on neural network techniques. In case of dams, the monitoring through the installation of an instrumentation system plays a fundamental part in the evaluation of the behavior of these structures, during the construction period as well as in the operation period. In this work the technique of temporal neural networks (TNN) was used for analysis, modeling and forecast of the water discharges values in the Funil dam, from Furnas Centrais Elétricas system, starting from the data of available instrumentation in the period between 02/09/1985 and 25/02/2002. The temporal neural networks used in this research were the following: TNN with feedforward architecture and the *windowing* technique, recursive TNN Elman, TNN FIR and TNN Jordan. Two additional techniques (Box & Jenkins and geostatistical models) were employed for analysis of the time series with the purpose to compare the results obtained with neural networks. In this research the generation of confidence intervals for TNN and geostatistical methods were also investigated. The discharge values forecasts analyzed in this work for the Funil dam presented satisfactory results, with respect to the neural network, Box & Jenkins and geostatistical methods.

Keywords

Funil Dam, temporal neural network, confidence intervals, dam monitoring, time series, instrumentation.

Sumário

1	INTRODUÇÃO	22
1.1	Introdução	22
1.2	Instrumentação de barragens	22
1.2.1	Objetivos	22
1.2.2	Análise dos dados	24
1.2.3	Importância das instrumentações na segurança de barragens	24
1.3	Objetivos	26
1.4	Organização da Tese	27
2	ANÁLISE DE SÉRIES TEMPORAIS	29
2.1	Introdução	29
2.2	Séries Temporais	29
2.3	Modelos Arima de Box & Jenkins	30
2.4	Redes Neurais	32
2.4.1	O uso das redes neurais em engenharia geotécnica	34
2.4.2	Arquitetura de rede	42
2.4.3	O conjunto de dados	43
2.4.4	Treinamento e testes	43
2.4.5	O algoritmo de retro-propagação do erro	45
2.4.6	O algoritmo de Levenberg-Marquardt	52
2.4.7	O algoritmo de regularização bayseana	53
2.4.8	Redes neurais temporais (RNT's)	54
2.4.8.1	Redes neurais com atrasos no tempo	55
2.4.8.2	Redes neurais FIR	56
2.4.8.3	Redes neurais recorrentes	58
2.4.8.4	Redes neurais Elman	61
2.5	Métodos Geoestatísticos	62
2.5.1	Função Covariância	63
2.5.2	Função correlação ou correlograma	63
2.5.3	Variograma	64
2.5.4	Modelos Variográficos	66
2.5.5	Krigagem ordinária	67

3	INTERVALOS DE CONFIANÇA	71
3.1	Introdução	71
3.2	Técnicas para estimar intervalos de confiança para redes neurais	73
3.2.1	Saída de erro	75
3.2.2	Re-amostragem dos erros	76
3.3.	Técnicas para estimar intervalos de confiança para métodos geoestatísticos	77
4	METODOLOGIA	79
4.1	Introdução	79
4.2	Barragem de Funil	79
4.3	Análise e preparação dos dados	82
4.4	Análises realizadas	83
4.5	Técnicas empregadas	83
4.6	Métricas Adotadas	85
5	PREVISÃO DE SÉRIES TEMPORAIS DE VAZÃO DE DRENOS DA BARRAGEM DE FUNIL	87
5.1	Introdução	87
5.2	Análise com as séries com intervalo de tempo constante	87
5.2.1	Previsão obtida pelo método de Box & Jenkins (1970)	88
5.2.2	Previsão obtida pela técnica de rede neural temporal com janelamento	90
5.2.3	Previsão obtida pela técnica de rede neural temporal Elman	93
5.2.4	Previsão obtida pela técnica de rede neural temporal FIR	95
5.2.5	Previsão obtida pela técnica de rede neural temporal Jordan	98
5.2.6	Previsão obtida com o método geoestatístico	100
5.2.7	Análise dos Resultados	106
5.3	Análise com as séries com intervalo de tempo variável	108
5.3.1	Previsão obtida pela técnica de rede neural temporal com janelamento	108

5.3.2	Previsão obtida pela técnica de rede neural temporal Elman	114
5.3.3	Previsão obtida pela técnica de rede neural temporal FIR	118
5.3.4	Previsão obtida pela técnica de rede neural temporal Jordan	121
5.3.5	Previsão obtida com o método geoestatístico	126
5.3.6	Geração do intervalo de confiança utilizando os resultados da previsão obtida com o método geoestatístico	134
5.3.7	Geração do intervalo de confiança através da os erros de saída da rede utilizando os resultados da previsão obtida com a técnica de RNT com janelamento	137
5.3.8	Geração do intervalo de confiança através de re-amostragem dos erros utilizando os resultados da previsão obtida com a RNT com janelamento	139
5.3.9	Análise dos Resultados	141
6	CONCLUSÕES E SUGESTÕES	144
6.1	Conclusões	144
6.2	Sugestões	147
	REFERÊNCIAS BIBLIOGRÁFICAS	148
	APÊNDICE A	155
	APÊNDICE B	173
	APÊNDICE C	178
	APÊNDICE D	184

Lista de Figuras

Figura 2.1 Valores de série temporal com previsão e intervalo de confiança com probabilidade de 95%	30
Figura 2.2 Modelo de um neurônio artificial	33
Figura 2.3 Funções de ativação (a) degrau, (b) linear, (c) sigmoidal logística e (d) tangente hiperbólica.	34
Figura 2.4 Exemplo de rede neural multi-camadas feedforward, totalmente conectada.	42
Figura 2.5 Métodos adequados em função da quantidade de dados e complexidade do problema..	43
Figura 2.6 Ilustração do monitoramento do erro do método “early stopping”.	44
Figura 2.7 Fluxo de sinais dentro do neurônio de saída j	47
Figura 2.8 Fluxo de sinais dentro do neurônio de camada oculta j conectado ao neurônio de saída k.	49
Figura 2.9 Classificação das redes neurais temporais	55
Figura 2.10 Método de ‘janelamento’ para processamento temporal	55
Figura 2.11 Rede TDNN para processamento temporal	56
Figura 2.12 Modelo FIR do neurônio	57
Figura 2.13 Neurônio FIR numa rede multicamada	58
Figura 2.14 Esquema de processamento temporal utilizando redes neurais recorrentes	59
Figura 2.15 Rede de Elman	59
Figura 2.16 Rede de Williams-Zipser	60
Figura 2.17 Rede de Jordan	60
Figura 2.18 Rede completamente recorrente – Rede de Elman	61
Figura 2.19 Esquema de funções: (a) covariância, (b) correlograma e (c) variograma	65
Figura 2.20 Esquema básico de uma função variograma	66
Figura 3.1 O efeito de amostras adicionais na confiabilidade da estimativa. A estimativa de um valor desconhecido com um sinal da cruz no centro (a) deve tornar-se mais confiável com amostras adicionais. O arranjo espacial	

das amostras em (b) , entretanto, não melhorará a confiabilidade tanto quanto as amostras uniformemente distribuídas em (c)	72
Figura 3.2 Rede neural para a técnica erro de saída	75
Figura 3.3 Exemplo da técnica de re-amostragem dos erros	76
Figura 4.1 Arranjo geral da barragem Funil do tipo abóbada de dupla curvatura	79
Figura 4.2 Galeria no soco da barragem de Funil.	80
Figura 4.3 Quadro de controle dos extensômetros e do termômetro	80
Figura 4.4 Dreno “D191”.	81
Figura 4.5 Dreno “D192”.	81
Figura 4.6 Dreno “D193”.	81
Figura 5.1 Modelagem e previsão da vazão com o modelo AR(1) para o dreno “D191”.	89
Figura 5.2 Modelagem e previsão da vazão com o modelo AR(1) para o dreno “D192”.	90
Figura 5.3 Modelagem e previsão da vazão com o modelo AR(2) para o dreno “D193”.	90
Figura 5.4 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno “D191”.	92
Figura 5.5 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno “D192”.	92
Figura 5.6 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno “D193”.	93
Figura 5.7 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D191”.	94
Figura 5.8 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D192”.	94
Figura 5.9 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D193”.	95
Figura 5.10 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D191”.	96
Figura 5.11 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D192”.	97

Figura 5.12 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D193”.	97
Figura 5.13 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D191”.	99
Figura 5.14 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D192”.	99
Figura 5.15 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D193”.	100
Figura 5.16 Variogramas experimentais e teóricos para o dreno “D191”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.	101
Figura 5.17 Variogramas experimentais e teóricos para o dreno “D192”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.	102
Figura 5.18 Variogramas experimental e teórico para o dreno “D193”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.	103
Figura 5.19 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D191”.	104
Figura 5.20 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D192”.	105
Figura 5.21 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D193”.	105
Figura 5.22 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno “D191”.	111
Figura 5.23 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno “D192”.	112
Figura 5.24 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno “D193”.	113
Figura 5.25 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D191”.	115
Figura 5.26 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D192”.	116
Figura 5.27 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D193”.	117
Figura 5.28 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D191”.	119

Figura 5.29 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D192”.	120
Figura 5.30 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D193”.	121
Figura 5.31 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D191”.	124
Figura 5.32 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D192”.	125
Figura 5.33 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D193”.	126
Figura 5.34 Variogramas experimental e teórico para o dreno “D191”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.	127
Figura 5.35 Variogramas experimental e teórico para o dreno “D192”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.	128
Figura 5.36 Variogramas experimental e teórico para o dreno “D193”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.	129
Figura 5.37 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D191”.	131
Figura 5.38 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D192”.	132
Figura 5.39 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D193”.	133
Figura 5.40 Histograma dos erros da previsão do modelo geoestatístico do dreno “D191”.	134
Figura 5.41 Histograma dos erros da previsão do modelo geoestatístico do dreno “D192”.	134
Figura 5.42 Histograma dos erros da previsão do modelo geoestatístico do dreno “D193”.	135
Figura 5.43 Intervalo de Confiança gerado pela previsão do método geoestatístico para o dreno “D191”.	135
Figura 5.44 Intervalo de Confiança gerado pela previsão do método geoestatístico para o dreno “D192”.	136
Figura 5.45 Intervalo de Confiança gerado pela previsão do método geoestatístico para o dreno “D193”.	136

Figura 5.46 Intervalo de Confiança gerado pela técnica de saída do erro com a previsão obtida pela RNT com janelamento para o dreno “D191”.	137
Figura 5.47 Intervalo de Confiança gerado pela técnica de saída do erro com a previsão obtida pela RNT com janelamento para o dreno “D192”.	138
Figura 5.48 Intervalo de Confiança gerado pela técnica de saída do erro com a previsão obtida pela RNT com janelamento para o dreno “D193”.	138
Figura 5.49 Intervalo de Confiança gerado pela técnica de re-amostragem dos erros obtida com a previsão da RNT com janelamento para o dreno “D191”.	139
Figura 5.50 Intervalo de Confiança gerado pela técnica de re-amostragem dos erros obtida com a previsão da RNT com janelamento para o dreno “D192”.	140
Figura 5.51 Intervalo de Confiança gerado pela técnica de re-amostragem dos erros obtida com a previsão da RNT com janelamento para o dreno “D193”.	140
Figura A.1 Série de vazão para o conjunto de modelagem (200 primeiros valores da série histórica).	155
Figura A.2 Funções de autocorrelação simples e parcial da série de vazão do dreno “D191” (E-views 4.0).	156
Figura A.3 Representação gráfica das séries de vazão, do modelo ajustado AR(1) e dos resíduos para o dreno “D191”.	158
Figura A.4 Correlograma do quadrado dos resíduos obtidos pelo modelo AR(1) na modelagem da vazão para o dreno “D191”.	159
Figura A.5 Série de vazão para o conjunto de modelagem (250 primeiros valores da série histórica).	161
Figura A.6 Funções de autocorrelação simples e parcial da série de vazão do dreno “D192” (E-views 4.0).	162
Figura A.7 Representação gráfica das séries de vazão, do modelo ajustado AR(1) e dos resíduos para o dreno “D192”.	164
Figura A.8 Correlograma do quadrado dos resíduos obtidos pelo modelo AR(1) na modelagem da vazão para o dreno “D192”.	165

Figura A.9 Série de vazão para o conjunto de modelagem (200 primeiros valores da série histórica).	167
Figura A.10 Funções de autocorrelação simples e parcial da série de vazão do dreno “D193” (E-views 4.0).	168
Figura A.11 Representação gráfica das séries de vazão, do modelo ajustado AR(2) e dos resíduos para o dreno “D193”.	170
Figura A.12 Correlograma do quadrado dos resíduos obtidos pelo modelo AR(2) na modelagem da vazão para o dreno “D193”.	171
Figura B.1 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT com janelamento para o dreno “D191”.	173
Figura B.2 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT Elman para o dreno “D191”.	174
Figura B.3 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT FIR para o dreno “D191”.	174
Figura B.4 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT Jordan para o dreno “D191”.	175
Figura B.5 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT com janelamento para o dreno “D191”.	176
Figura B.6 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT Elman para o dreno “D191”.	176
Figura B.7 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT FIR para o dreno “D191”.	177
Figura B.8 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT Jordan para o dreno “D191”.	177
Figura C.1 Comparação da previsão do modelo III da tabela C.2 com as previsões obtidas pelas RNT’s para o dreno “D191”.	181
Figura C.2 Comparação da previsão do modelo III da tabela C.3 com as previsões obtidas pelas RNT’s para o dreno “D192”.	182
Figura C.3 Comparação da previsão do modelo III da tabela C.4 com as previsões obtidas pelas RNT’s para o dreno “D193”.	183
Figura D.1 Diagrama de dispersão “D191” x nível do reservatório.	184
Figura D.2 Diagrama de dispersão “D192” x nível do reservatório.	185
Figura D.3 Diagrama de dispersão “D193” x nível do reservatório.	185

Lista de Tabelas

Tabela 5.1 Siglas adotadas	88
Tabela 5.2 Desempenho da previsão por Box & Jenkins para o dreno “D191”.	89
Tabela 5.3 Desempenho da previsão por Box & Jenkins para o dreno “D192”.	89
Tabela 5.4 Desempenho da previsão por Box & Jenkins para o dreno “D193”.	89
Tabela 5.5 Entradas e Saídas adotadas	91
Tabela 5.6 Desempenho da previsão por RNT com janelamento para o dreno “D191”.	91
Tabela 5.7 Desempenho da previsão por RNT com janelamento para o dreno “D192”.	91
Tabela 5.8 Desempenho da previsão por RNT com janelamento para o dreno “D193”.	92
Tabela 5.9 Desempenho da previsão por RNT Elman para o dreno “D191”.	93
Tabela 5.10 Desempenho da previsão por RNT Elman para o dreno “D192”.	93
Tabela 5.11 Desempenho da previsão por RNT Elman para o dreno “D193”.	94
Tabela 5.12 Desempenho da previsão por RNT FIR para o dreno “D191”.	96
Tabela 5.13 Desempenho da previsão por RNT FIR para o dreno “D192”.	96
Tabela 5.14 Desempenho da previsão por RNT FIR para o dreno “D193”.	96
Tabela 5.15 Entradas e Saídas adotadas.	98
Tabela 5.16 Desempenho da previsão por RNT Jordan para o dreno “D191”.	98
Tabela 5.17 Desempenho da previsão por RNT Jordan para o dreno “D192”.	98

Tabela 5.18 Desempenho da previsão por RNT Jordan para o dreno “D193”.	98
Tabela 5.19 Desempenho da previsão por krigagem ordinária para o dreno “D191”.	100
Tabela 5.20 Desempenho da previsão por krigagem ordinária para o dreno “D192”.	101
Tabela 5.21 Desempenho da previsão por krigagem ordinária para o dreno “D193”.	101
Tabela 5.22 Valores dos parâmetros do modelo teórico esférico para o dreno “D191”.	104
Tabela 5.23 Valores dos parâmetros do modelo teórico esférico para o dreno “D192”.	104
Tabela 5.24 Valores dos parâmetros do modelo teórico esférico para o dreno “D193”.	104
Tabela 5.25 Desempenho das previsões para o dreno “D191”.	107
Tabela 5.26 Desempenho das previsões para o dreno “D192”.	107
Tabela 5.27 Desempenho das previsões para o dreno “D193”.	107
Tabela 5.28 Desempenho das previsões para o dreno “D191” com a RNT com janelamento.	108
Tabela 5.29 Desempenho das previsões para o dreno “D191” com a RNT Elman.	108
Tabela 5.30 Desempenho das previsões para o dreno “D191” com a RNT FIR.	108
Tabela 5.31 Desempenho das previsões para o dreno “D191” com a RNT Jordan.	108
Tabela 5.32 Entradas e Saídas adotadas para o dreno “D191”.	109
Tabela 5.33 Entradas e Saídas adotadas para o dreno “D192”.	109
Tabela 5.34 Entradas e Saídas adotadas para o dreno “D193”.	109
Tabela 5.35 Desempenho da previsão por RNT com janelamento para o dreno “D191”.	110
Tabela 5.36 Desempenho da previsão por RNT com janelamento para o dreno “D192”.	110
Tabela 5.37 Desempenho da previsão por RNT com janelamento para o dreno “D193”.	110

Tabela 5.38 Desempenho da previsão por RNT Elman para o dreno “D191”.	114
Tabela 5.39 Desempenho da previsão por RNT Elman para o dreno “D192”.	114
Tabela 5.40 Desempenho da previsão por RNT Elman para o dreno “D193”.	114
Tabela 5.41 Desempenho da previsão por RNT FIR para o dreno “D191”.	118
Tabela 5.42 Desempenho da previsão por RNT FIR para o dreno “D192”.	118
Tabela 5.43 Desempenho da previsão por RNT FIR para o dreno “D193”.	118
Tabela 5.44 Entradas e Saídas adotadas para a rede neural temporal Jordan para o dreno “D191”.	122
Tabela 5.45 Entradas e Saídas adotadas para a rede neural temporal Jordan para o dreno “D192”.	122
Tabela 5.46 Entradas e Saídas adotadas para a rede neural temporal Jordan para o dreno “D193”.	122
Tabela 5.47 Desempenho da previsão por RNT Jordan temporal para o dreno “D191”.	123
Tabela 5.48 Desempenho da previsão por RNT Jordan para o dreno “D192”.	123
Tabela 5.49 Desempenho da previsão por RNT Jordan para o dreno “D193”.	123
Tabela 5.50 Desempenho da previsão por krigagem ordinária para o dreno “D191”.	130
Tabela 5.51 Desempenho da previsão por krigagem ordinária para o dreno “D192”.	130
Tabela 5.52 Desempenho da previsão por krigagem ordinária para o dreno “D193”.	130
Tabela 5.53 Valores dos parâmetros do modelo teórico esférico para o dreno “D191”.	130
Tabela 5.54 Valores dos parâmetros do modelo teórico esférico para o dreno “D192”.	130

Tabela 5.55 Valores dos parâmetros do modelo teórico esférico para o dreno “D193”.	130
Tabela 5.56 Desempenho do intervalo de confiança gerado pela previsão do método geoestatístico.	137
Tabela 5.57 Desempenho do intervalo de confiança gerado pela técnica do erro de saída da rede utilizando os resultados da previsão obtida com a técnica de RNT com janelamento.	139
Tabela 5.58 Desempenho do intervalo de confiança gerado pela técnica de re-amostragem dos erros utilizando os resultados da previsão obtida com a técnica de RNT com janelamento.	141
Tabela 5.59 Desempenho das previsões para o dreno “D191”.	142
Tabela 5.60 Desempenho das previsões para o dreno “D192”.	142
Tabela 5.61 Desempenho das previsões para o dreno “D193”.	142
Tabela A.1 Teste de Dickey–Fuller Ampliado (ADF test) para a série de vazão do dreno “D191” (E-views 4.0)	156
Tabela A.2 Teste de significância dos parâmetros para o modelo AR(1) na previsão da vazão para o dreno “D191”.	157
Tabela A.3 Teste de ARCH para avaliação da variância dos resíduos obtidos pelo ajuste do modelo AR(1) na previsão de vazão do dreno “D191”.	160
Tabela A.4 Teste de Dickey–Fuller Ampliado (ADF test) para a série de vazão do dreno “D192” (E-views 4.0).	162
Tabela A.5 Teste de significância dos parâmetros para o modelo AR(1) na previsão da vazão para o dreno “D192”.	163
Tabela A.6 Teste de ARCH para avaliação da variância dos resíduos obtidos pelo ajuste do modelo AR(1) na previsão de vazão do dreno “D192”.	166
Tabela A.7 Teste de Dickey–Fuller Ampliado (ADF test) para a série de vazão do dreno “D193” (E-views 4.0).	168
Tabela A.8 Teste de significância dos parâmetros para o modelo AR(2) na previsão da vazão para o dreno “D193”.	169
Tabela A.9 Teste de ARCH para avaliação da variância dos resíduos obtidos pelo ajuste do modelo AR(2) na previsão de vazão do dreno “D193”.	172

Tabela C.1 Entradas e Saídas adotadas para o dreno “D191” danificado.	178
Tabela C.2 Entradas e Saídas adotadas para o dreno “D192” danificado.	179
Tabela C.3 Entradas e Saídas adotadas para o dreno “D193” danificado.	179
Tabela C.4 Desempenho da previsão da vazão a partir das outras séries para o dreno “D191”.	180
Tabela C.5 Desempenho da previsão da vazão a partir das outras séries para o dreno “D192”.	180
Tabela C.6 Desempenho da previsão da vazão a partir das outras séries para o dreno “D193”.	180

1 INTRODUÇÃO

1.1 Introdução

Grandes obras de engenharia (portos, barragens, usinas nucleares, etc.) apresentam uma grande quantidade de ensaios e instrumentações tanto na etapa do projeto e como no processo de monitoramento da operação da obra.

No caso de barragens, o monitoramento hidráulico-mecânico através da instalação de um sistema de instrumentação desempenha um papel fundamental na avaliação do comportamento destas estruturas, tanto durante o período de construção quanto no período de operação.

Este capítulo faz uma revisão geral dos objetivos principais da instrumentação de barragens e a importância que um adequado monitoramento e interpretação dos dados de instrumentação desempenha no controle de segurança de barragens. Este capítulo trata ainda dos objetivos e da organização deste trabalho.

1.2 Instrumentação de barragens

1.2.1 Objetivos

Gutiérrez (2003) relata os principais objetivos da instrumentação geotécnica de barragens descritas no manual de instrumentação de barragens da U.S. Army Corps of Engineers de 1995. Estes objetivos podem ser agrupados em quatro categorias: avaliações analíticas, previsão do desempenho futuro, avaliações legais e desenvolvimento e verificação de futuros empreendimentos.

As avaliações analíticas englobam as análises dos dados obtidos a partir da instrumentação geotécnica para obter parâmetros de projeto, hipóteses de

modelagem e técnicas de construção, bem como estimar os efeitos de eventos adversos.

Previsões do desempenho futuro são as diferentes formas de tratamento dos dados de instrumentação, executando-se previsões que podem confirmar condições normais de operação ou indicar riscos potenciais para a barragem.

Os dados da instrumentação são úteis também no caso de avaliações legais e em litígios relacionados com a construção da barragem como, por exemplo, nas eventuais mudanças ocorridas nas condições de fluxo sub-superficial.

O desenvolvimento e verificação de futuros empreendimentos se refere à análise do desempenho de uma barragem tanto na etapa de construção quanto na fase de operação, com a finalidade de aperfeiçoar o estado-da-arte do projeto e da construção de barragens.

Gutiérrez (2003) apresenta os objetivos básicos da instrumentação estabelecidos pelo Comitê Brasileiro de Grandes Barragens em 1996. Os objetivos são agrupados de acordo com a etapa de desenvolvimento da barragem: construção, primeiro enchimento e operação.

Período de construção:

- Alertar sobre a ocorrência de possíveis anomalias no comportamento da barragem.
- Possibilitar soluções menos conservadoras, permitindo economia significativa para a obra.
- Fornecer informações, por retro-análise dos dados de instrumentação, a respeito dos valores dos parâmetros dos materiais que constituem a barragem e sua fundação.
- Possibilitar revisões do projeto durante o período construtivo.

Período de enchimento:

- Alertar sobre a ocorrência de possíveis anomalias que possam colocar em risco a segurança da estrutura.
- Possibilitar avaliação do desempenho estrutural, geotécnico e hidráulico da obra, em função das comparações entre grandezas medidas “*in-situ*” e aquelas previstas por modelos teóricos ou experimentais de análise.

- Verificar a adequação das simplificações introduzidas nas hipóteses de projeto.

Período de operação:

- Verificar se a barragem está apresentando um desempenho geral satisfatório, conforme previsto em projeto.
- Caracterizar o comportamento no tempo dos solos e/ou do maciço rochoso de fundação determinando o prazo necessário para a estabilização dos deslocamentos, tensões, sub-pressões, vazões, etc.
- Caracterizar o comportamento no tempo das estruturas da barragem, levando-se também em conta os efeitos das condições termo-ambientais.

1.2.2

Análises dos dados

Os dados gerados durante o período de construção são geralmente analisados através de métodos determinísticos, analíticos ou numéricos. Um modelo matemático da barragem é escolhido para análise. Este modelo deverá considerar relações constitutivas dos diferentes materiais, geometria do problema, condições iniciais, condições de contorno, etc. O grau de precisão das estimativas dependerá da qualidade dos dados disponíveis e da complexidade do modelo utilizado, variando desde simples formulações empíricas a sofisticadas simulações numéricas.

Já os dados gerados durante o período de operação da barragem são geralmente analisados através de métodos estatísticos e/ou probabilísticos. Estes métodos são escolhidos devido à quantidade considerável de dados, provenientes das leituras da instrumentação ao longo de grandes períodos de tempo.

1.2.3

Importância da instrumentação na segurança de barragens

A segurança de uma barragem está intimamente relacionada aos aspectos de projeto, construção, instrumentação/inspeção, operação e manutenção. É claro que, por melhores que tenham sido o projeto de uma barragem e a fiscalização de sua construção, só será possível exercer um eficiente controle das condições de

segurança da barragem se a mesma estiver sendo adequadamente inspecionada e monitorada através de instrumentação apropriada, operada por equipe treinada. Durante a vida útil da barragem, são necessárias obras periódicas de manutenção com a finalidade de preservar em bom estado das várias estruturas, assegurar superfícies hidráulicas satisfatórias e garantir a operacionalidade dos equipamentos eletromecânicos e dos instrumentos de auscultação.

As lições aprendidas com as rupturas de barragens têm revelado que um longo período de operação normal não é jamais garantia de condições futuras de segurança, uma vez que tem havido casos de ruptura brusca após 10 e 20 anos de operação normal. Gutiérrez (2003) relata o exemplo da barragem em arco de Zeuzier, na Suíça, com 156 metros de altura, operou durante 21 anos sem qualquer problema aparente, quando em novembro de 1978 as informações fornecidas pelos pêndulos direitos passaram a indicar deslocamentos que ultrapassavam os valores elásticos anteriormente observados. A crista da barragem começou a apresentar deslocamentos contínuos para montante, apesar do reservatório estar totalmente cheio, enquanto que as medições geodésicas indicavam movimentos de aproximação entre as ombreiras da barragem e recalques do maciço de fundação em toda a região da barragem. Fissuras no concreto, com abertura de 10mm, desenvolveram-se junto às ombreiras, exigindo um intenso tratamento através de injeção de resina epóxi. As investigações realizadas, auxiliadas pelos dados fornecidos pela instrumentação, vieram a indicar que os problemas observados estavam associados à escavação de um túnel rodoviário, afastado 1400 metros da barragem. A barragem encontra-se hoje em operação normal, após paralisação da construção do túnel e a execução das obras de reparo.

Em alguns empreendimentos, os medidores de vazão são instalados em um ou mais locais para monitorar a percolação através e sob a barragem. Tais medidores, devido a sua indiscutível importância, podem ser equipados com dispositivos sensores e transmissores de dados via rádio, micro-ondas ou cabos, encaminhando assim o fluxo de informações constantemente aos sistemas de aquisição de dados.

Em muitos casos, os valores de vazão constituem-se em importantes evidências da ocorrência de problemas no comportamento geotécnico de barragens, sendo muito natural, portanto, que a instalação destes medidores seja

uma prática de longa data na construção de barragens no Brasil e no exterior. Legislações de vários países, como Japão, Noruega e França, impõem a instalação de medidores de vazão como componente essencial de um projeto de instrumentação de barragens.

1.3 Objetivos

Neste trabalho, redes neurais temporais, método estatístico de Box & Jenkins (1970) e métodos geoestatísticos são utilizados na análise de dados de instrumentação de medidores de vazão da barragem de Funil do sistema Furnas Centrais Elétricas. O sistema de medição de vazão é composto por três drenos. O primeiro dreno capta a água percolada através da fundação, o segundo dreno capta a água drenada da margem direita e o terceiro dreno capta a água drenada da margem esquerda.

O programa de monitoramento é composto geralmente por uma série de instrumentações que fornecem dados que são acompanhados e analisados para verificar se o comportamento real da obra está consistente com o modelo teórico concebido em projeto. As instrumentações monitoram medições de deslocamento, pressão, percolação e drenagem junto com fatores ambientais que afetam o comportamento da obra como temperatura, nível de reservatório e precipitação.

Métodos geoestatísticos utilizam-se de variogramas que expressam o grau de correlação entre pares de dados experimentais localizados em diferentes tempos, permitindo a construção de modelos temporais que possibilitam a previsão de valores, com respectivas estimativas de erro, em datas não-amostradas.

Redes neurais artificiais (RNA's) são sistemas que, a exemplo do cérebro humano, possuem capacidade de aprendizagem e de generalização (inferência) sem a necessidade da definição prévia de um modelo determinístico. O processo de aprendizagem consiste na apresentação de conjuntos de entrada e saída de dados à rede que, gradualmente, identifica e simula as principais características do problema. Redes neurais temporais (RNT's) são redes dinâmicas que possuem propriedades de memória. Estas propriedades permitem-nas realizar tarefas de caráter temporal.

Para a análise, consideraram-se as séries históricas da vazão dos drenos, da temperatura e das flutuações do nível do reservatório a montante. O objetivo é fazer o monitoramento e previsão das séries de vazão dos drenos, com a finalidade de poder tomar medidas preventivas em relação à segurança da estrutura da barragem. Séries como as de vazão dos drenos e nível do reservatório a montante são denominadas séries temporais.

As medidas sistemáticas das vazões dos drenos permitem conhecer a vazão máxima captada pelo sistema de drenagem global e, qualquer acréscimo significativo dessa vazão pode indicar uma anomalia que deve ser pesquisada, por exemplo, uma físsura ou fratura do maciço podem ser identificadas com inspeções cuidadosas de superfície. Em muitos casos, valores das vazões de percolação através de barragens e fundações têm sido evidências das imperfeições dessas estruturas. É muito natural, portanto, que essa medição seja um indicador crítico do comportamento da barragem.

Os valores previstos para as vazões dos drenos podem auxiliar na tomada de decisões na operação da barragem, principalmente quando o fenômeno for difícil de ser investigado através de modelagem geomecânica e soluções numéricas envolvendo a necessidade de relações constitutivas, condições de contorno complexas, etc.

1.4 Organização da Tese

Este trabalho está dividido em seis capítulos, assim organizado:

No capítulo 1 descreve-se a importância da instrumentação geotécnica na análise do comportamento de barragens durante a construção, primeiro enchimento do reservatório e operação da instalação. É apresentado o objetivo da tese e descrita sua organização de capítulos.

No capítulo 2 apresenta conceitos sobre séries temporais, faz-se uma revisão bibliográfica dos modelos de Box & Jenkins (1970), faz-se uma descrição da técnica de redes neurais artificiais, redes neurais temporais e métodos geostatísticos utilizadas neste trabalho.

O capítulo 3 faz uma revisão bibliográfica das metodologias existentes para estimar intervalos de confiança para RNA's. dando maior ênfase aos métodos

adotados neste trabalho. Apresenta ainda a metodologia utilizada para estimar o intervalo de confiança para a krigagem ordinária.

No capítulo 4 apresentam-se as características da Barragem de Funil e do sistema de instrumentação utilizado nesta barragem. Apresenta-se ainda a metodologia adotada neste trabalho para a modelagem e previsão da vazão dos drenos.

No capítulo 5 faz a modelagem e previsão da vazão dos drenos de instrumentação da Barragem de Funil, localizada no estado do Rio de Janeiro.

O capítulo 6 apresenta as conclusões e sugestões para trabalhos futuros.

2 ANÁLISE DE SÉRIES TEMPORAIS

2.1 Introdução

Este capítulo trata de uma revisão teórica sobre séries temporais, métodos estatísticos baseados nos modelos, redes neurais artificiais (RNA's), redes neurais temporais (RNT's) e métodos geoestatísticos, com enfoque nos conceitos teóricos utilizados neste trabalho.

2.2 Séries Temporais

Série temporal é um conjunto de observações ordenadas no tempo, não obrigatoriamente igualmente espaçadas, que apresentam dependência entre instantes de tempo. Uma série temporal pode ser decomposta nas componentes de **tendência**, **ciclo** e **sazonalidade** (Gutiérrez, 2003).

A **tendência** indica o comportamento “de longo prazo” da série, ou seja, se a série aumenta, diminui ou permanece estável, e qual a velocidade destas mudanças.

Os **ciclos** indicam as oscilações de subida e de queda nas séries, de forma suave e repetida, ao longo da componente de tendência, como por exemplo, os ciclos meteorológicos.

A **sazonalidade** corresponde às oscilações de subida e de queda que ocorrem sempre em um mesmo período.

O estudo da série temporal pode considerar:

- a) investigação do mecanismo gerador da série temporal;
- b) descrição do comportamento da série;
- c) busca de periodicidades relevantes nos dados;
- d) previsões de valores futuros da série.

A previsão de valores futuros da série temporal é amplamente utilizado nas áreas de economia, planejamento de produção, controle e otimização de processos industriais, planejamento comerciais entre outros.

Como exemplo de metodologia de previsão de valores futuros da série temporal temos: uma série temporal discreta e com os valores espaçados igualmente no tempo, com intervalo semanal. Utilizando-se o valor da série s_t da semana atual t e os valores das semanas anteriores $s_{t-1}, s_{t-2}, s_{t-3}, \dots$ para previsão do valores futuros $\hat{s}_{t+1}, \hat{s}_{t+2}, \hat{s}_{t+3}, \dots, \hat{s}_{t+8}$ que representam os passos à frente $l = 1, 2, 3, \dots, 8$. Nosso objetivo é obter um modelo da série temporal que apresente o menor erro possível para cada passo previsto. Além da melhor previsão, podem-se calcular as incertezas associadas à previsão associando os valores previstos a limites de probabilidade (Box, Jenkins & Reinsel, 1994).

A figura 2.1 mostra uma série temporal composta de 28 valores e as previsões feitas a partir da origem t com 8 passos à frente, bem como o intervalo de confiança com probabilidade de 95%.




Figura 2.1 Valores de série temporal com previsão e intervalo de confiança com probabilidade de 95% (Box, Jenkins & Reinsel, 1994).

2.3 Modelos Arima de Box & Jenkins

Os modelos ARIMA são modelos estatísticos lineares para análise de séries temporais. A abreviação ARIMA em inglês significa “Auto-Regressive Integrated

Moving Average model”, ou seja, auto-regressivo, integrado e médias móveis. Os termos auto-regressivos correspondem a defasagens da série e as médias móveis são as defasagens dos erros aleatórios. Integrado é o processo de diferenciação da série original para torná-la estacionária.

Na série temporal estacionária não existe tendência de crescimento ou decrescimento dos dados, ou seja, os dados oscilam sobre uma média constante e com a variância das flutuações constante. Quando a série é estacionária, a distribuição de probabilidade conjunta associada com n observações $s_{t_1}, s_{t_2}, s_{t_3}, \dots, s_{t_n}$ observadas em qualquer conjunto de tempo $t_1, t_2, t_3, \dots, t_n$ é a mesma que a associada com outras n observações $s_{t_1+k}, s_{t_2+k}, s_{t_3+k}, \dots, s_{t_n+k}$ observadas nos tempos $t_1 + k, t_2 + k, t_3 + k, \dots, t_n + k$. A distribuição de probabilidade conjunta de qualquer conjunto de amostras não pode ser alterada pela modificação de todas as observações da série temporal para frente ou para trás por qualquer valor inteiro k (Box, Jenkins & Reinsel, 1994).

No processo de diferenciação, a série com comportamento não-estacionário é transformada em uma nova série estacionária. Já que os modelos ARIMA assumem estacionariedade da série. A equação 2.1 indica a primeira diferença.

$$s'_t = s_t - s_{t-1} \quad (2.1)$$

onde s_t é a série temporal não-estacionária com n valores

s'_t é a série nova estacionária que terá $n-1$ valores.

No modelo ARIMA, a série temporal é gerada por um processo estocástico cuja natureza pode ser representada através de um modelo. A notação utilizada para designar o modelo ARIMA é ARIMA (p, d, q) onde p é o número de termos auto-regressivos, d o número de diferenciações para que a série torne-se estacionária e q o número de termos de médias móveis. Os termos p, d e q são todos inteiros maiores ou iguais a zero.

São casos particulares: o modelo ARMA(p,q), o modelo auto-regressivo AR(p) e o modelo de médias móveis MA(q), sendo os três modelos utilizados para séries temporais estacionárias (d=0).

O modelo auto-regressivo AR(p) é definido por,

$$S(t) = \sum_{i=1}^p \alpha_i S(t-i) + \varepsilon(t) = \phi_L(S(t-1), \dots, S(t-p)) + \varepsilon(t) \quad (2.2)$$

onde a estimativa da série S no instante t depende de uma combinação linear de p termos da série, incluindo o termo aleatório $\varepsilon(t)$ de ruído branco. Os parâmetros α_i ponderam os valores da série temporal do instante anterior $t-1$ até o instante $t-p$. Estes parâmetros são determinados através de técnicas de minimização do erro.

O modelo de médias móveis MA(q) assume que a série modelada é gerada através de uma combinação linear de q sinais de ruídos $\varepsilon(t-i)$, aleatórios e independentes entre si,

$$S(t) = - \sum_{i=1}^q \theta_i \varepsilon(t-i) + \varepsilon(t) = \phi_L(\varepsilon(t-1), \dots, \varepsilon(t-q)) + \varepsilon(t) \quad (2.3)$$

O modelo ARMA(p, q) é uma combinação dos modelos AR(p) e MA(q), no qual

$$S(t) = \sum_{i=1}^p \alpha_i S(t-i) + \sum_{i=1}^q \theta_i \varepsilon(t-i) + \varepsilon(t) \quad (2.4)$$

ou

$$S(t) = \phi_L(S(t-1), \dots, S(t-p), \varepsilon(t-1), \dots, \varepsilon(t-q)) + \varepsilon(t) \quad (2.5)$$

2.4 Redes Neurais

Redes neurais artificiais (RNA's) são sistemas paralelos distribuídos formados por unidades de processamento simples (neurônios) que realizam funções matemáticas, geralmente não-linear. As RNA's tiveram sua origem na tentativa de gerar um modelo artificial que simule a estrutura do cérebro humano, mas atualmente podem ser definidas como uma metodologia estatística capaz de resolver com sucesso vários problemas de engenharia e de outras áreas (Dyminski, 2000).

Uma rede neural artificial é formada por diversos neurônios artificiais. A figura 2.2 representa um neurônio esquematicamente. Em um modelo de neurônio, podem ser identificados alguns elementos básicos:

- sinapses que são responsáveis pelas conexões, cada uma caracterizada por um peso sináptico w_{kj} , onde o índice k corresponde ao número do neurônio e j ao estímulo de entrada;
- um somatório dos sinais de entrada já multiplicados por seus respectivos pesos (combinação linear), resultando no valor u_k ;
- uma função de ativação φ que visa limitar os sinais de entrada a um determinado intervalo, normalmente entre 0 e 1 ou -1 e 1;
- o limiar ou *polarizador*, θ_k , que possui um efeito de diminuir ou aumentar o valor da combinação linear das entradas (u_k) na função de ativação.

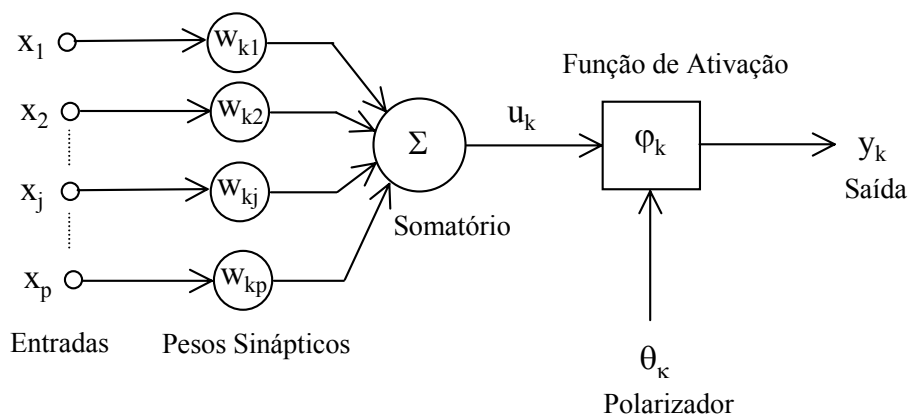


Figura 2.2 Modelo de um neurônio artificial. (Haykin, 1999)

O neurônio pode ser descrito através das seguintes equações:

$$u_k = \sum_{j=1}^p w_{kj} x_j \quad (2.6)$$

$$y_k = \varphi(u_k - \theta_k) \quad (2.7)$$

Ou

$$y_k = \varphi(v_k) \quad (2.8)$$

A função de ativação é capaz de assumir diversas formas, podendo ser em degrau, linear ou sigmoideal (logística ou tangente hiperbólica), conforme mostra a figura 2.3.




Figura 2.3 Funções de ativação (a) degrau, (b) linear, (c) sigmoidal logística e (d) tangente hiperbólica. (Haykin, 1999)

2.4.1

O uso das redes neurais em engenharia geotécnica

Redes neurais artificiais apresentam diversas aplicações na área de engenharia geotécnica. Encontram-se aplicações de RNA's em caracterização e classificação de solos e rochas, potencial de liquefação de depósitos de areias, modelos constitutivos com RNA's, fundações, escavações, estabilidade de taludes, reforço de solos, água subterrânea, mineração e outras. São apresentados a seguir alguns relevantes trabalhos sucintamente descritos.

Toll (1996) apresenta uma revisão de sistemas de inteligência artificial (IA) que foram desenvolvidas para aplicações geotécnicas. A revisão abrange sistemas especialistas e redes neurais. A revisão trata de trabalhos que envolvem uma grande quantidade de sistemas desenvolvidos para caracterização de sítios, classificação de solos e rochas, fundações, estruturas de retenção de terra, taludes, túneis e aberturas de escavações, minas, liquefação, geotêxteis entre outras aplicações. As técnicas de IA tem sido eficientes para resolver diversos problemas de engenharias. Ghaboussi (1992) apresenta uma revisão sobre a técnica de rede neural, sobre algoritmos de treinamento, sobre as técnicas de aprendizado e

apresenta uma revisão sobre a utilização de rede neurais em aplicações geotécnicas.

Veiga et al. (2002) investiga a distribuição espacial dos valores do número de golpes N dos ensaios SPT no subsolo da usina nuclear de Angra II através de redes neurais e métodos geoestatísticos. Na comparação das duas técnicas, os métodos geoestatísticos apresentaram resultados ligeiramente melhores, mas ambas as técnicas apresentaram resultados satisfatórios.

Gangopadhyay et al. (1999) associaram RNA's e GIS (Sistema de Informação Geográfica) para desenvolver um método para caracterização de subsuperfície. Dados de monitoramento da distribuição de materiais do aquífero e logs litológicos são utilizados para treinar uma rede perceptron multicamada. A RNA faz a previsão dos materiais de formação da subsuperfície para cada ponto de um *grid* discretizado da área modelo. GIS é então usado para desenvolver perfis da subsuperfície dos dados gerados pela rede neural. Esses perfis de subsuperfície são então comparados com seções geológicas avaliadas para verificar a eficiência dos perfis gerados RNA-GIS. Esta metodologia é aplicada para determinar aquíferos extensos e calcular parâmetros dos aquíferos para entrada de modelos solo-água para um sistema multi-aquífero existente na cidade de Bangkok, Tailândia. A metodologia RNA-GIS mostrou-se uma poderosa ferramenta para caracterização de geometria de aquífero complexa, e para calcular parâmetros de aquíferos para modelagem de fluxo solo-água.

Juang & Jiang (2001) utilizaram ensaios CPT de um depósito de areia como parâmetros para geração de um modelo neural do sítio analisado. No artigo é utilizado rede neural de regressão generalizada (GRNN). Esta rede é composta de três camadas: camada de entrada, camada oculta e camada de saída. Na camada oculta é realizado o mapeamento local não linear. Esta camada é composta de neurônios de base radial que utilizam função de transferência gaussiana. O autor utiliza as GRNN para dois tipos de caracterização do sítio: a análise unidimensional (caracterização do sítio somente na direção vertical) e a análise bidimensional (caracterização do sítio em que a coordenada z é fixada para analisar um plano xy).

Oulapour & Dadfar (2002) utilizaram resultados de ensaios geotécnicos (profundidade da amostra, índice de vazios, peso específico, grau de saturação, percentagem de solos finos que passam na peneira #200, limite de liquidez, limite

de plasticidade e umidade) para gerar um modelo neural que forneça parâmetros de resistência cisalhamento consolidado drenado, resistência cisalhamento consolidado não-drenado, resistência cisalhamento não-consolidado não-drenado e coeficiente de permeabilidade. A rede neural multi-camada perceptron é utilizada. Quatro algoritmos de treinamento são testados: *Quasi-Newton backpropagation (BFG)*, *resilient backpropagation (RP)*, *Levenberg-Marquardt backpropagation (LM)* e *Gradient Descent with momentum and adaptative learning rule (GDX)*. Os resultados obtidos indicam que as melhores previsões dos parâmetros de resistência são obtidas utilizando o algoritmo *RP* e as melhores previsões do coeficiente de permeabilidade são obtidas pelo algoritmo *GDX*.

Potencial de liquefação de depósitos de areia foram analisados por Goh (1994) utilizando resultados de SPT e parâmetros do solo (teor de finos, dimensão do grão média (D_{50}), tensão cisalhante dinâmica equivalente (τ_{av} / σ'_0), tensão total (σ_0), tensão efetiva (σ'_0), magnitude de terremoto (M) e aceleração horizontal máxima na superfície do solo). Uma rede neural *feedforward* é utilizada associada ao algoritmo de treinamento *backpropagation*. Os autores observaram através de um estudo paramétrico que o teor de finos e SPT são os parâmetros de entrada mais importantes. Goh (1996) prevê o potencial de liquefação de depósitos de areia com o mesmo procedimento de Goh (1994), porém utilizando resultados de ensaios CPT.

Ghaboussi et al. (1991) discutem a utilização de RNA's na modelagem de materiais e aplicam na modelagem de concreto. Este artigo indica que a principal vantagem das RNA's na geração de modelos constitutivos é que todo o comportamento pode ser representado dentro de um ambiente unificado de uma rede neural e que a rede é construída diretamente de dados experimentais que usam a capacidade auto-organizadora da rede neural, a rede é apresentada aos dados experimentais e “aprende” as relações entre tensões e deformações. Uma rede neural multi-camada perceptron é utilizada associada ao algoritmo de treinamento *backpropagation* para modelar o comportamento do concreto submetido a um estado plano de tensões sob um carregamento biaxial monotônico e submetido a um carregamento cíclico uniaxial compressivo.

Ellis et al. (1995) aplicaram RNA's na modelagem das relações tensões - deformações da areia com variação da distribuição de tamanho dos grãos e da

história de tensões. Os autores constataram que RNA's com *feedback* são mais eficientes que RNA's sem *feedback* para modelagem das relações tensões – deformações. O artigo também demonstra a habilidade da rede neural para simular ciclos de carregamento e descarregamento das características tensões-deformações do solo.

Najjar & Ali (1999) utilizaram uma rede neural recorrente (R –CNN) para modelar o comportamento da areia de Nevada submetida ao estado monotônico triaxial consolidado não-drenado e modelar a resposta de um solo fino submetido ao estado cíclico uniaxial.

Na área de modelos constitutivos existem diversos trabalhos que utilizam redes neurais artificiais associados a método dos elementos finitos (MEF), como por exemplo, Ghaboussi et al. (1994) associaram redes neurais artificiais e MEF na geração de modelos constitutivos; Sidarta & Ghaboussi (1997) modelaram materiais submetidos a ensaios com distribuição não-uniforme de deformação dentro da amostra; Ghaboussi & Sidarta (1997) desenvolveram uma nova metodologia de modelagem de materiais utilizando redes neurais artificiais; Pande & Shin (2002) analisam problemas de valor de contorno com o auxílio de MEF e RNA's para prever o modelo constitutivo; Wu (1997) utilizou um algoritmo híbrido elementos finitos-redes neurais na modelagem de materiais e Shin & Pande (2002) utilizaram redes neurais e MEF para modelar geomateriais.

Chow et al. (1995) analisaram provas de carga dinâmica para fazer a previsão da capacidade de carga com auxílio de RNA. Para formulação do problema adotaram um modelo de equação de onda desenvolvida por Chow et al. (1988) que utiliza os seguintes parâmetros: número de elementos da estaca (i), força aplicada na cabeça da estaca $F(t)$, velocidade aplicada na cabeça da estaca $V(t)$, densidade da estaca (ρ_p), módulo de Young da estaca (E_p), comprimento da estaca (L), seção transversal da estaca (A_p), resistência estática do solo associada ao i elemento (R_u^i), coeficiente de rigidez por unidade de comprimento associado ao i elemento (k_s^i), coeficiente de amortecimento por unidade de comprimento associado ao i elemento (c_s^i), coeficientes do efeito da velocidade no eixo da estaca (J_s^i, N_s^i), resistência estática do solo na ponta da estaca (R_u^t), coeficiente de rigidez na ponta da estaca (k_s^t), coeficiente de amortecimento na ponta da estaca

(c_s^t) e coeficientes do efeito da velocidade na ponta da estaca (J^t, N^t). RNA's *feedforward* são utilizadas associada ao algoritmo de treinamento *backpropagation* para previsão da capacidade de carga de testes dinâmicos de estacas escavadas e para previsão da capacidade de carga de testes dinâmicos de estacas de aço perfil H cravadas. Apresentado bons resultados para ambas as previsões quando comparados com métodos tradicionais.

Teh et al. (1997) utilizam modelos RNA's multi-camada perceptron associadas ao algoritmo de treinamento *backpropagation* para previsão da capacidade de carga de teste dinâmicos de estacas de concreto reforçado (RC). Análises distintas são realizadas com três modelos de rede: a primeira rede faz a previsão da capacidade estática, a segunda rede prevê a resistência distribuída e a terceira prevê resistência, amortecimento e *quake*. Os melhores resultados são obtidos com a terceira análise, apresentado as duas primeiras análises resultados razoáveis. Um teste de generalização com conjunto de teste com estacas não RC é realizado indicando a capacidade de generalização da rede. As previsões são comparadas com soluções CAPWAP que utilizam como parâmetros: resistência última do solo (R_u), fator de quake (Q), fator de amortecimento (J), força medida na cabeça da estaca (F) e velocidade medida na cabeça da estaca (V).

Liu et al. (1997) utilizam os resultados obtidos do método Case para alimentar um RNA's multi-camada perceptron associadas ao algoritmo de treinamento *backpropagation* para fazer a previsão da capacidade de carga da estaca. O método Case é um sistema econômico e portátil que calcula a capacidade de carga da estaca de medições de força aplicada na estaca e velocidade de propagação de onda durante a cravação da estaca.

Kiefa (1998) utiliza redes neurais de regressão geral (GRNN) para previsão de capacidade de carga de estacas cravadas em solos de baixa coesão. São utilizadas três redes neurais GRNN para previsão: a primeira prevê a capacidade de carga total, a segunda prevê a capacidade de carga do topo e a terceira a capacidade de carga lateral. Os parâmetros de entrada das redes são: tangente do ângulo de atrito médio do solo ao longo da lateral da estaca ($\tan(\phi_L)$), tangente do ângulo de atrito do solo na ponta da estaca ($\tan(\phi_B)$), tensão efetiva vertical do solo na ponta da estaca, SPT na lateral do solo ($\sigma'_{V(B)}$), comprimento da estaca (L), seção transversal da estaca (A) e diâmetro da estaca (D). Os resultados obtidos

pelos redes são comparados com quatro diferentes métodos empíricos e com valores medidos. O modelos da GRNN foram melhores que os métodos empíricos quando comparados com os valores medidos.

Musso et al. (2002) utilizaram um sistema de inferência adaptativo baseado em lógica fuzzy e redes neurais (ANFIS) para prever a evolução do deslocamento de sapatas. Testes de sapatas submetidas a cargas excêntricas verticais são analisados. A rede é treinada com resultados experimentais de uma série de testes de carga em condições normais e de gravidade incrementada. Os resultados obtidos pelas sistema são comparadas favoravelmente com os testes de laboratórios correspondentes. Os autores sugerem que novas curvas de carga-recalque podem ser simulados para obter diagramas de interação de colapso que são frequentemente utilizados em modelos matemáticos para previsão da evolução do deslocamento de uma sapata rasa.

Rahman & Wang (2002) utilizaram um sistema de inferência adaptativo baseado em lógica fuzzy e redes neurais (ANFIS) para analisar provas de carga dinâmica e a capacidade de arrancamento de caixões succionados. Os resultados obtidos indicam previsões bastante razoáveis e que a metodologia pode ser utilizada com sucesso em outros problemas geotécnicos.

Dyminski (2000) apresenta a análise de três diferentes problemas em geotecnia utilizando RNA's *feedforward* treinadas com o algoritmo de Levenberg-Marquardt (LM). A primeira aplicação simula resultados de provas de carga dinâmica, analisadas pelo método CAPWAP, através de RNA, sendo assim viabilizada a realização de uma pré-análise do comportamento da estaca ainda em campo, o que geralmente não acontece quando se trata da análise CAPWAP tradicional. A segunda aplicação análise o comportamento mecânico de dois tipos de solo: a areia de Ipanema e o solo residual gnáissico do Rio de Janeiro. Nesta modelagem, foram utilizados resultados de ensaios de cisalhamento direto, submersos e não submersos, e ensaios de compressão triaxial, drenados e não drenados. A terceira aplicação simula as características do subsolo do sítio da Usina Nuclear Angra 2, localizada no litoral do estado do Rio de Janeiro. Foram utilizadas para a modelagem, as informações disponíveis em boletins de sondagens do tipo SPT. Foram realizadas simulações envolvendo a disposição das camadas dos diferentes tipos de solo que poderiam existir no local, o nível de água

subterrâneo, a resistência à penetração do solo e a topografia do terreno. O trabalho obteve resultados bastante satisfatórios nos três diferentes problemas.

King & Signer (1994) avaliaram características mecânicas e movimentos de paredes de minas de carvão com o auxílio de redes neurais artificiais. O sistema desenvolvido utiliza RNA com treinamento não-supervisionado para coletar resultados de instrumentação e identificar feições geológicas com os padrões de razão de penetração, empuxo, torque, posição e razão de rotação. Os resultados obtidos da RNA com aprendizado não supervisionado foram utilizados para treinar duas RNA's supervisionadas utilizando o algoritmo de treinamento *backpropagation*. Os resultados obtidos mostram que o sistema apresenta um grande potencial para identificação das características das camadas. O artigo sugere ainda que os resultados podem ser utilizados como entrada de um sistema especialista para localizar regiões de risco e recomendar atitudes preventivas que evitem a ruptura das paredes.

Millar & Calderbank (1995) analisaram a deformabilidade de rochas utilizando RNA's. Uma RNA perceptron multicamada é introduzida em um sistema denominado FLAC. A RNA é responsável no sistema por calcular as relações tensões-deformações. Os resultados obtidos demonstram sucesso na utilização de RNA como ferramenta de projetos de engenharia em rocha.

Zettler et al. (1997) analisaram o controle do processo de injeção considerando análise de pressão transiente (TPA) com o auxílio de RNA e lógica fuzzy. O processo de controle é chamado Pressão sensível de injeção (PSG) que envolve a pressão de injeção, pressão residual, razão pressão-volume de injeção e o comportamento dependente do tempo. O sistema combina conhecimento especialista, experiências físicas e investigações numéricas e ajusta regras para dados de treinamento para controlar o processo de injeção. A RNA é aplicada para encontrar as melhores regras esperadas para o conjunto de dados entrada-saída conhecido para o algoritmo de controle lógica fuzzy.

Tan & Hui (2001) aplicaram RNA's para gerar um modelo neural para maciços de rocha. Uma rede neural que utiliza como função de transferência a função de base radial. O algoritmo de treinamento é o *backpropagation*. Os dados utilizados para testar o modelo neural são curvas tensão-deformação obtidas de ensaios com mármore. Os resultados obtidos indicam que o método fornece curvas

tensões-deformações com precisão e que o método é valioso para mecânica das rochas computacional.

Bandyopadhyay et al. (1995) utilizaram RNA's no estudo da durabilidade da rocha calcária que compõe a famosa esfinge do Cairo. Distribuição do tamanho dos poros determinadas experimentalmente e fatores de durabilidade (DF) determinados com base no estado com o passar do tempo da Esfinge do Cairo são usados como padrões de entrada e saída respectivamente para uma RNA perceptron multicamada treinada com o *backpropagation*. Uma parte da camada da rocha calcária da Esfinge é utilizada para gerar os dados utilizados no treinamento. O modelo neural gerado é usado no cálculo do DF da camada restante da Esfinge. Os resultados obtidos combinam excelentemente com as condições observadas das camadas e com a durabilidade indicada pela constituição litológica.

Parâmetros de compactação do solo são previstos utilizando RNA's por Basheer & Najjar (1995). O teor de umidade ótimo e a densidade seca máxima são dois parâmetros de compactação que caracterizam e ajudam a controlar a construção e qualidade de uma grande quantidade de projetos de trabalhos com solo. No artigo, estes dois parâmetros são previstos utilizando RNA multicamada perceptron associada ao algoritmo de treinamento *backpropagation*. São gerados dois modelos neurais: o primeiro modelo tem como entradas limite de liquidez, limite de plasticidade e densidade específica do solo e a segunda rede tem apenas como entrada limite de liquidez. Os resultados obtidos são comparados com o valores experimentais e com valores obtidos com outros métodos de previsão. Apresentando o modelo neural valores similares aos obtidos experimentalmente.

Previsões de deslocamento em sistemas de suporte de escavação são analisadas com o auxílio de RNA's por Gao et al. (2001). Uma rede neural feedforward treinada com o algoritmo *backpropagation* é utilizado para previsão do deslocamento horizontal. O deslocamento horizontal é medido ao longo do tempo gerando séries temporais. O modelo neural utiliza como entradas cinco medições sequenciais de deslocamento e a saída é o valor da previsão do deslocamento. A RNA consegue prever com sucesso os deslocamentos horizontais.

2.4.2 Arquitetura de rede

A arquitetura de rede define como as unidades de processamento simples são dispostas, ou seja, como os diversos neurônios são conectados entre si.

O tipo de rede neural artificial mais utilizado em aplicações em engenharia é chamado de “multi-camadas *feedforward*”, caracterizando-se por apresentar neurônios organizados em camadas. O neurônio pode estar total ou parcialmente conectado por sinapses (pesos). As entradas alimentam a rede e são processadas até alcançarem a camada de saída, sem realimentação. Por isso são denominadas como *feedforward* (alimentação e propagação para frente).

A figura 2.4 mostra uma rede neural totalmente conectada, com 4 entradas e 2 saídas e que possui uma camada oculta com 5 neurônios, localizada entre os nós de entrada e a camada de saída. Redes neurais artificiais, de uma ou duas camadas ocultas apenas, conseguem resolver a maior parte dos problemas de engenharia (Haykin, 1999).




Figura 2.4 Exemplo de rede neural multi-camadas *feedforward*, totalmente conectada.

A complexidade do modelo pretendido irá definir a quantidade de pesos (parâmetros) e de camadas da arquitetura da rede. O número de neurônios não deve ser muito pequeno se o problema a ser resolvido apresentar grande complexidade e nem grande demais, a ponto de se prejudicar a capacidade de generalização da rede, gerando o problema conhecido como *overfitting* (ajuste excessivo) (Dyminski, 2000).

2.4.3 O conjunto de dados

Como em qualquer método estatístico o conjunto de dados deverá cobrir todo o domínio de interesse do problema a ser solucionado. O conjunto deverá ter amostras suficientes para que a rede aprenda sobre o problema. A figura 2.5 ilustra uma relação entre métodos, volume de dados e grau de conhecimento da realidade.

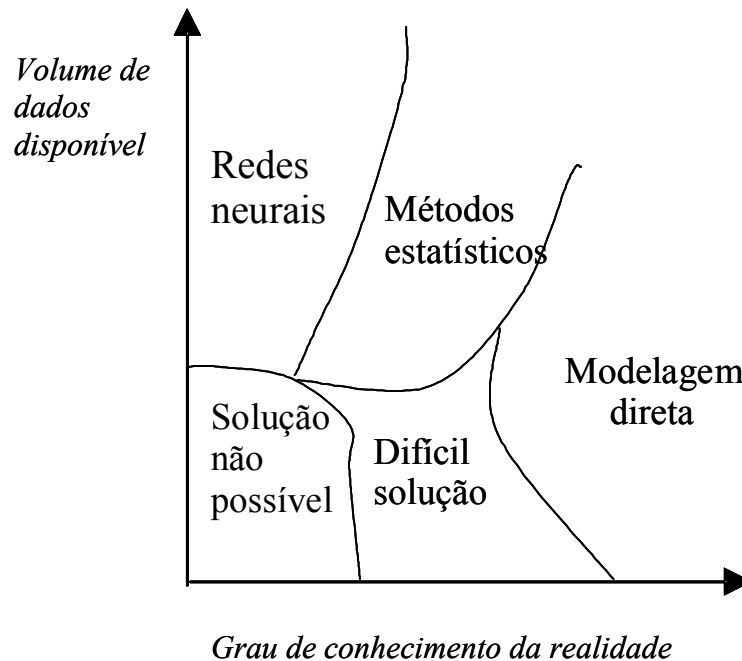


Figura 2.5 Métodos adequados em função da quantidade de dados e complexidade do problema. (Pedreira, 2001)

2.4.4 Treinamento e testes

Para iniciar o treinamento devem estar definidos:

- a) o tipo e a arquitetura da rede;
- b) o conjunto de amostras referentes ao fenômeno a ser modelado;
- c) os parâmetros que servirão de entrada à rede;
- d) as saídas que se quer obter.

Um método simples de treinamento consiste em dividir o conjunto de amostras em três subconjuntos: conjunto de treinamento, conjunto de teste 1 e conjunto de teste 2.

O conjunto de treinamento será composto de exemplos que serão utilizados na fase de treinamento da rede neural artificial. O conjunto de teste 1 será

composto de exemplos que serão utilizados na tarefa de se testar a capacidade de generalização da rede neural. O conjunto de teste 2 serve para comparar modelos diferentes. Cabe salientar que os exemplos de um subconjunto não deverão ter sido utilizados no outros subconjuntos, ou seja, os subconjuntos são formados por exemplos distintos entre si.

O treinamento consiste na apresentação das amostras do conjunto de treinamento à rede que processará os parâmetros de entrada relativos a estas amostras através da multiplicação dos mesmos pelos pesos sinápticos e da posterior aplicação destes valores às funções de ativação dos neurônios, fornecendo então as respostas (saídas da rede) a este estímulo. Estas saídas da RNA deverão ser comparadas com os valores reais dos parâmetros de saída correspondentes aos exemplos do conjunto de treinamento, e desta comparação será obtido um valor de erro da fase de treinamento. Procura-se então ajustar os valores dos pesos sinápticos, através de um algoritmo matemático, visando a diminuição do erro de treinamento. Durante a etapa de treinamento o erro do conjunto de teste 1 é monitorado para garantir a capacidade de generalização da rede. Quando o erro do conjunto de teste 1 começa a aumentar o processo de treinamento termina. Este método chama-se “*early stopping*”. A figura 2.6 mostra o monitoramento dos erros de treinamento e de generalização.




Figura 2.6 Ilustração do monitoramento do erro do método “*early stopping*”. (Haykin, 1999).

Quando a quantidade de amostras for pequena não se deve dividir o conjunto de amostras em subconjuntos. O teste pode ser feito retirando uma amostra aleatoriamente para verificar a generalização e utilizando o restante das amostras para o conjunto de treinamento. Este procedimento deve ser repetido até a média do erro ficar constante. Este método é denominado “*leave-one-out*”.

Assim, tem-se como objetivo da fase de treinamento ajustar da melhor maneira possível os valores dos parâmetros da rede, procurando fazer com que as saídas fornecidas pela RNA estejam bastante próximas dos valores reais de saída correspondentes a cada um das amostras apresentadas, sem que se perca sua capacidade de generalização.

Existem diversos algoritmos para se treinar RNA's. A seguir serão citados os algoritmos: retro-propagação do erro; Levenberg-Marquardt e regularização bayesiana.

2.4.5 **O algoritmo de retro-propagação do erro**

O algoritmo de retro-propagação do erro consiste dos seguintes passos (Dyminski, 2000):

- a) as entradas das amostras do conjunto de treinamento são apresentadas à rede neural;
- b) estes dados são processados pela rede: em cada camada, através da multiplicação pelos pesos sinápticos, posterior somatório e aplicação da função de ativação, são fornecidas as saídas relacionadas às entradas apresentadas;
- c) as saídas fornecidas pela rede são comparadas com os valores reais obtidos dos experimentos e, desta variação, é calculado o erro;
- d) com o valor do erro, o ajuste para os pesos da última camada é calculado (conforme desenvolvimento a seguir). O erro é então “retro-propagado” na rede, corrigindo os pesos sinápticos das camadas ocultas, visando um melhor ajuste da RNA ao fenômeno a ser modelado.

Este processo iterativo deverá acontecer até que o erro seja aceitável, ou seja, que a rede tenha aprendido a tarefa a ser realizada.

O erro de um neurônio de saída j na interação n , pode ser calculado por:

$$e_j(n) = d_j(n) - y_j(n) \quad (2.9)$$

onde $d_j(n)$ é o valor real de saída do neurônio j e $y_j(n)$ é o valor estimado pela rede na interação n .

O valor instantâneo do erro quadrático para o neurônio j é definido como $\frac{1}{2}e_j^2(n)$. O somatório $\frac{1}{2}e_j^2(n)$ de todos neurônios da camada de saída define o valor instantâneo $E(n)$ como na equação 2.10.

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.10)$$

C é o conjunto de neurônios da camada de saída. O erro médio quadrático é obtido somando-se os $E(n)$ e dividindo-se por N , como mostra a equação 2.11, onde N é a quantidade de amostras do conjunto de treinamento.

$$E_{av} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (2.11)$$

O erro instantâneo $E(n)$ e o erro médio quadrático E_{av} são funções dos parâmetros livres (pesos sinápticos e bias) da rede. O erro médio quadrático E_{av} é a função de custo da etapa de treinamento. O objetivo da etapa de treinamento é ajustar os parâmetros livres para minimizar E_{av} .

A figura 2.7 mostra, o neurônio j sendo alimentado, pelas saídas da camada a sua esquerda. O campo local induzido $v_j(n)$ produzido na entrada da função de ativação do neurônio j é mostrada na equação 2.12.

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (2.12)$$

m é o número total de saídas (excluindo a bias) aplicada ao neurônio j . O peso sináptico w_{j0} (com entrada $y_0 = +1$) é igual ao polarizador aplicado ao neurônio j . A função $y_j(n)$ na saída do neurônio j na interação n , é dada pela equação 2.13.

$$y_j(n) = \varphi_j(v_j(n)) \quad (2.13)$$

O algoritmo de retro-propagação do erro aplicará uma correção $\Delta w_{ji}(n)$ para o peso sináptico $w_{ji}(n)$, que será proporcional à derivada parcial $\partial E(n)/\partial w_{ji}(n)$. Aplicando a regra da cadeia, a derivada parcial pode ser expressa pela equação 2.14.

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (2.14)$$

A equação 2.14 é o fator de sensibilidade, determinando a direção de busca no espaço dos pesos para o peso sináptico w_{ji} .




Figura 2.7 Fluxo de sinais dentro do neurônio de saída j (Haykin, 1999).

Diferenciando a equação 2.10 em relação $e_j(n)$, tem-se a equação 2.15.

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \quad (2.15)$$

Diferenciando a equação 2.9 em relação $y_j(n)$, tem-se a equação 2.16.

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (2.16)$$

Diferenciando a equação 2.13 em relação $v_j(n)$, tem-se a equação 2.17.

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (2.17)$$

A “linha” do lado direito da equação significa diferenciação em relação ao argumento.

Diferenciando a equação 2.12 em relação $w_{ji}(n)$, tem-se a equação 2.18.

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (2.18)$$

Substituindo as equações 2.15 à 2.18 na equação 2.14, tem-se a equação 2.19.

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n)\varphi'_j(v_j(n))y_i(n) \quad (2.19)$$

A correção de $\Delta w_{ji}(n)$ aplicada em $w_{ji}(n)$ é denominada “regra delta” como mostra a equação 2.20.

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (2.20)$$

onde η é a taxa de aprendizado do algoritmo de retro-propagação do erro. O sinal negativo indica gradiente descendente no espaço dos pesos. Substituindo a equação 2.19 na equação 2.20.

$$\Delta w_{ji}(n) = -\eta \delta_j(n) y_i(n) \quad (2.21)$$

onde o gradiente local $\delta_j(n)$ é definido pela equação 2.22.

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n)) \quad (2.22)$$

A taxa de aprendizado η regulará a velocidade de aprendizado da rede.

Quando o neurônio j , figura 2.8, está situado em uma camada oculta o procedimento de ajuste seguirá a metodologia abaixo:




Figura 2.8 Fluxo de sinais dentro do neurônio de camada oculta j conectada ao neurônio de saída k . (Haykin, 1999).

Definindo o gradiente local $\delta_j(n)$ para o neurônio j , tem-se a equação 2.23.

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \quad (2.23)$$

Diferenciando a equação 2.10 em relação a $y_j(n)$, tem-se a equação 2.24, onde k representa o neurônio na camada de saída.

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (2.24)$$

Aplicando a regra da cadeia na derivada parcial $\partial e_k(n)/\partial y_j(n)$, tem-se a equação 2.25.

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (2.25)$$

Escrevendo as equações 2.9 e 2.12 utilizando o índice k para o neurônio de saída, têm-se as equações 2.26 e 2.27.

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - \varphi_k(v_k(n)) \quad (2.26)$$

$$v_k(n) = \sum_{i=0}^m w_{kj}(n) y_j(n) \quad (2.27)$$

Diferenciando a equação 2.26 em relação $v_k(n)$, tem-se a equação 2.28.

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (2.28)$$

Diferenciando a equação 2.27 em relação $y_j(n)$, tem-se a equação 2.29.

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (2.29)$$

Diferenciando a equação 2.13 em relação $v_j(n)$, tem-se a equação 2.30

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (2.30)$$

Substituindo as equações 2.28 e 2.29 na equação 2.25, tem-se a equação 2.31.

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) \quad (2.31)$$

Substituindo as equações 2.30 e 2.31 na equação 2.23, tem-se o gradiente local dado pela equação 2.32.

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) \quad (2.32)$$

A correção de $\Delta w_{ji}(n)$ aplicada em $w_{ji}(n)$ é definida pela equação 2.33.

$$\Delta w_{ji}(n) = -\eta \varphi'_j(v_j(n)) \sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) y_i(n) \quad (2.33)$$

Resumindo o algoritmo de retro-propagação pode ser descrito pelas equações 2.34 a 2.36.

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (2.34)$$

$$\Delta w_{ji}^l(n) = -\eta \delta_j^l(n) \cdot a_i^{l-1}(n) \quad (2.35)$$

Onde o sobrescrito l indica a camada que o neurônio pertence e $a_i^{l-1}(n)$ é a entrada que o neurônio recebe.

$$\delta_j^l(n) = \begin{cases} e_j(n) \varphi'_j(v_j(n)) & l = L \\ \varphi'_j(v_j(n)) \sum_k \delta_k^{l+1}(n) w_{kj}(n) & 1 \leq l \leq L-1 \end{cases} \quad (2.36)$$

L é o símbolo adotado para a camada de saída

2.4.6 O algoritmo de Levenberg-Marquardt

O algoritmo de retro-propagação do erro descrito no item 2.4.5 foi baseado no método de otimização do gradiente descendente que utiliza apenas as primeiras derivadas para minimizar o erro. Entretanto existem outras técnicas de otimização que tornam a convergência mais rápida, por exemplo, algoritmos de otimização que utilizam as segundas derivadas. Esses algoritmos são do tipo “quase Newton” sendo mais eficientes, porém precisam armazenar a matriz Hessiana (matriz com as segundas derivadas).

O método Levenberg-Marquardt (LM) é do tipo “quase Newton” utilizado para mínimos quadrados não lineares e foi incorporado ao algoritmo de retro-propagação do erro para resolver problemas de otimização que aparecem no treinamento de redes multi-camadas. O processo do método LM é descrito em Bishop (1995).

A função objetivo para o algoritmo LM é:

$$E = \frac{1}{2} \|\varepsilon(w_{velho}) + Z(w_{novo} - w_{velho})\|^2 + \lambda \|w_{novo} - w_{velho}\|^2 \quad (2.37)$$

Onde $\varepsilon(w_{velho})$ é o vetor com os erros do conjunto de treinamento, w_{velho} é o peso sináptico utilizado no passo atual, w_{novo} é o peso sináptico calculado e λ é um parâmetro que governa o tamanho do passo.

A atualização dos pesos utiliza a equação 2.38.

$$w_{novo} = w_{velho} - (H + \lambda I)^{-1} Z^T \varepsilon(w_{velho}) \quad (2.38)$$

Onde

$$(Z)_{ni} = \frac{\partial \varepsilon^n}{\partial w_i} \quad (2.39)$$

$$H = Z^T Z \quad (2.40)$$

2.4.7

O algoritmo de regularização bayseana

O algoritmo de treinamento utilizando regularização bayseana é uma técnica mais recente para treinar o modelo neural. Nesta técnica, a quantidade de neurônios da camada oculta não será estimada por um processo de tentativa e erro. Na regularização bayseana o processo de treinamento faz com que os parâmetros (pesos sinápticos) dos neurônios ocultos desnecessários fiquem com valor próximo a zero. O objetivo principal é encontrar um equilíbrio entre a quantidade de parâmetros e a complexidade do modelo neural exigida pelo problema. A função objetivo utilizada no algoritmo de retropropagação do erro, equação (2.41), é modificada adicionando-se um termo de regularização ($E_W = \frac{1}{2} \sum_i w_i^2$) e parâmetros de regularização ($\beta, \alpha > 0$) modificando a função objetivo para a equação (2.42).

$$E_D(w) = \frac{1}{N} \frac{1}{2} \sum_n \sum_j (d_j^{(n)} - y_j^{(n)}(x^{(n)}; w))^2 \quad (2.41)$$

$$M(w) = \beta \cdot E_D + \alpha \cdot E_W \quad (2.42)$$

Os valores dos parâmetros da função objetivo devem ser calculados. Para encontrar valores ótimos para esses parâmetros. Pode-se utilizar a técnica “*bayesian framework*”, onde os parâmetros da rede neural são assumidos como sendo variáveis randômicas com distribuição conhecida. Os parâmetros da função objetivo são relacionados com variáveis desconhecidas associadas com essas distribuições e são estimados com técnicas estatísticas. Medeiros & Pedreira (2001) descrevem o processo de otimização dos parâmetros de regularização aplicando a regra de Bayes e o algoritmo proposto por Foresee e Hagan em 1997

para otimização Bayseana dos parâmetros de regularização, com aproximação por Gauss-Newton para a matriz Hessiana em combinação com o algoritmo LM.

O algoritmo proposto por Foresee e Hagan apresenta os seguintes passos:

1. Inicializar β , α e os parâmetros da rede neural. Depois do primeiro passo de estimação, os parâmetros da função objetivo recuperarão o cenário inicial.
2. Levar um passo do algoritmo de LM para minimizar a função objetivo $M(w) = \beta \cdot E_D + \alpha \cdot E_w$.
3. Calcular o número efetivo de parâmetros $\gamma = N - 2\alpha \text{trace}(H)^{-1}$ utilizando a aproximação Gauss-Newton para a matriz Hessiana avaliada pelo algoritmo de otimização de LM $H = \nabla^2 M(w) \approx 2\beta J^T J + 2\alpha I_N$, onde J é a matriz Jacobiana do conjunto de erros estimados.
4. Calcular os novos valores para os parâmetros da função objetivo.
5. Repetir do passo 1 até o passo 3 até convergir.

O algoritmo de treinamento regularização bayseana utilizado para treinamento das RNA's deste trabalho já está implementado no pacote de redes neurais do programa MATLAB.

2.4.8 **Redes neurais temporais (RNT's)**

As redes neurais temporais são redes dinâmicas que possuem propriedades de memória. Estas propriedades permitem-nas realizar tarefas de caráter temporal. A maneira como a memória é representada determina o tipo de rede neural temporal (Gutiérrez, 2003). A figura 2.9 mostra duas maneiras de se incluir habilidades de memória na rede neural:

- a) Rede considerando entradas atrasadas no tempo;
- b) Rede com laços de realimentação.

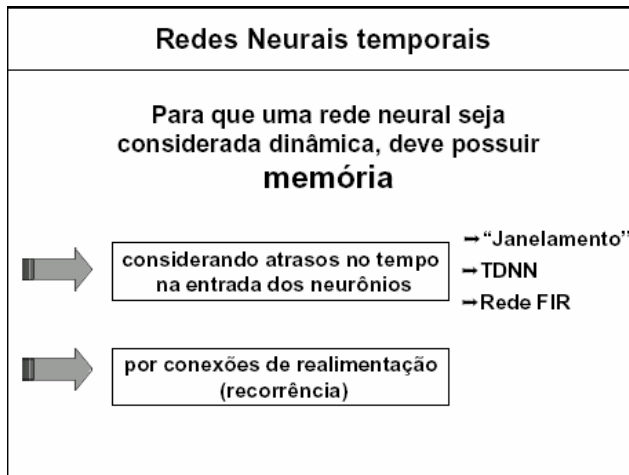


Figura 2.9 Classificação das redes neurais temporais (Gutiérrez, 2003).

2.4.8.1 Redes neurais com atrasos no tempo

Durante muito tempo, modelos de redes neurais com atraso no tempo foram os mais utilizados em problemas que envolviam processamento temporal (Soto, 1999). A memória era introduzida na rede, proporcionando aos neurônios os valores de entradas atuais e valores temporalmente anteriores. No método de “janelamento” somente os neurônios da primeira camada possuem memória. A Figura 2.10 mostra o método de “janelamento”, que fornece à rede uma memória de ordem 2 na primeira camada oculta. Já que além da entrada atual $x(k)$, estes neurônios recebem também como entrada dois valores anteriores $x(k-1)$ e $x(k-2)$ criando, portanto, sinapses novas.




Figura 2.10 Método de “janelamento” para processamento temporal (Soto, 1999).

A Figura 2.11 mostra uma rede que fornece memória a todos os neurônios das camadas ocultas e da camada de saída. Esta rede é denominada rede TDNN (*Time Delay Neural Network*).




Figura 2.11 Rede TDNN para processamento temporal (Soto, 1999).

Nesta rede, existem sinapses novas, mas a rede final formada não conduz à forma da rede estática padrão, totalmente interconectada, pois os neurônios novos na camada oculta não estão conectados aos elementos de entrada. Este fato faz a rede TDNN perder certa "simetria" no processo da exploração "feedforward" e de retropropagação, tornando-a mais complexa (Soto, 1999).

A rede neural com atraso no tempo utilizada neste trabalho é a denominada rede neural FIR (*Finite Response Impulse*) onde cada sinapse é formada por um filtro FIR linear que representa a natureza temporal do problema. Pode-se dizer que este tipo de rede engloba todos os outros métodos de sua classe. Na seção seguinte será detalhada.

2.4.8.2 Redes neurais FIR

Nas redes neurais FIR as sinapses são modeladas por um filtro linear invariante no tempo. Nesta modelagem que considera memória em todos os neurônios a "simetria" da rede é mantida, pois utiliza um modelo fundamentado na técnica de processamento de sinais.

Soto (1999) mostra a formulação de uma rede neural FIR detalhadamente, considerando para o modelo filtros sinápticos de tempo contínuo. A figura 2.12 ilustra o modelo FIR do neurônio com N entradas.




Figura 2.12 Modelo FIR do neurônio (Soto, 1999).

Onde:

$x_1(k)$, $x_2(k)$ e $x_N(k)$ são as entradas do neurônio,

w_{ji} é o vetor de pesos da sinapse do neurônio j ,

$s_{ji}(k)$ é o potencial sináptico do neurônio j ,

$s_j(k)$ é a soma dos potenciais sinápticos do neurônio j ,

w_b é o bias,

$y_j(k)$ é a saída do neurônio após passar pela função de ativação do neurônio j .

Neste modelo o potencial sináptico $s_{ji}(k)$ é a resposta de um filtro FIR de ordem M , onde M representa o número total de atrasos unitários considerados no desenho do filtro FIR. Este potencial sináptico $s_{ji}(k)$ é definida pela equação 2.43, onde k representa o tempo discreto.

$$s_{ji}(k) = \sum_{n=0}^M w_{ji}(n)x_i(k-n) + w_b \quad (2.43)$$

Então a soma dos potenciais sinápticos, é definido por:

$$s_j(k) = \sum_{i=1}^N \sum_{n=0}^M w_{ji}(n)x_i(k-n) + w_b \quad (2.44)$$

Na expressão acima, o comportamento temporal é representado pelo somatório interno e o comportamento espacial pelo somatório externo.

A figura 2.13 mostra à esquerda uma rede FIR com 4 camadas: a camada de entrada (camada 0, $l=0$), duas camadas ocultas (camadas $l=1$ e $l=2$) e a camada de saída (camada 3, $l=3$). A direita tem-se a ampliação das sinapses entre os neurônios da camada $l=1$ e o neurônio do meio da camada $l=2$.




Figura 2.13 Neurônio FIR numa rede multicamada (Soto, 1999).

Para treinamento da rede FIR, utiliza-se o algoritmo de retro-propagação temporal (Wan, 1994).

O algoritmo de retro-propagação temporal pode ser definido pelas equações (2.45), (2.46) e (2.47).

$$w_{ji}(k+1) = w_{ji}(k) + \Delta w_{ji}(k) \quad (2.45)$$

$$\Delta w_{ji}^{L-n}(k) = \eta \delta_j^{L-n}(k - nM) \cdot a_i^{L-1-n}(k - nM) \quad (2.46)$$

$$\delta_j^{L-n}(k - nM) = \begin{cases} 2e_j(k) \varphi'(s_j^L(k)) & n = 0 \\ \varphi'(s_j^{L-n}(k - nM)) \cdot \sum_m \delta_m^{L+1-n}(k - nM) \cdot w_{jm}^{L+1-n} & 1 \leq l \leq L-1 \end{cases} \quad (2.47)$$

2.4.8.3 Redes neurais recorrentes

Nestas redes o comportamento dinâmico é simulado por conexões de realimentação, como ilustra a figura 2.14. A realimentação pode ser de dois tipos: a) local que é situada ao nível de neurônio; b) global que envolve alguma(s) camada(s) completa(s). As redes recorrentes podem ser utilizadas de duas maneiras: a) memórias associativas; b) mapeamento entrada-saída; sendo a segunda maneira utilizada para o processamento de séries temporais.




Figura 2.14 Esquema de processamento temporal utilizando redes neurais recorrentes (Soto 1999).

Um tipo de rede neural temporal com realimentação global é rede de Elman. Nesta rede cada um dos neurônios da camada oculta tem realimentação para as unidades de contexto, como ilustra a figura 2.15. Esta é a rede neural recorrente utilizada neste trabalho, na próxima seção é apresentada a sua formulação.

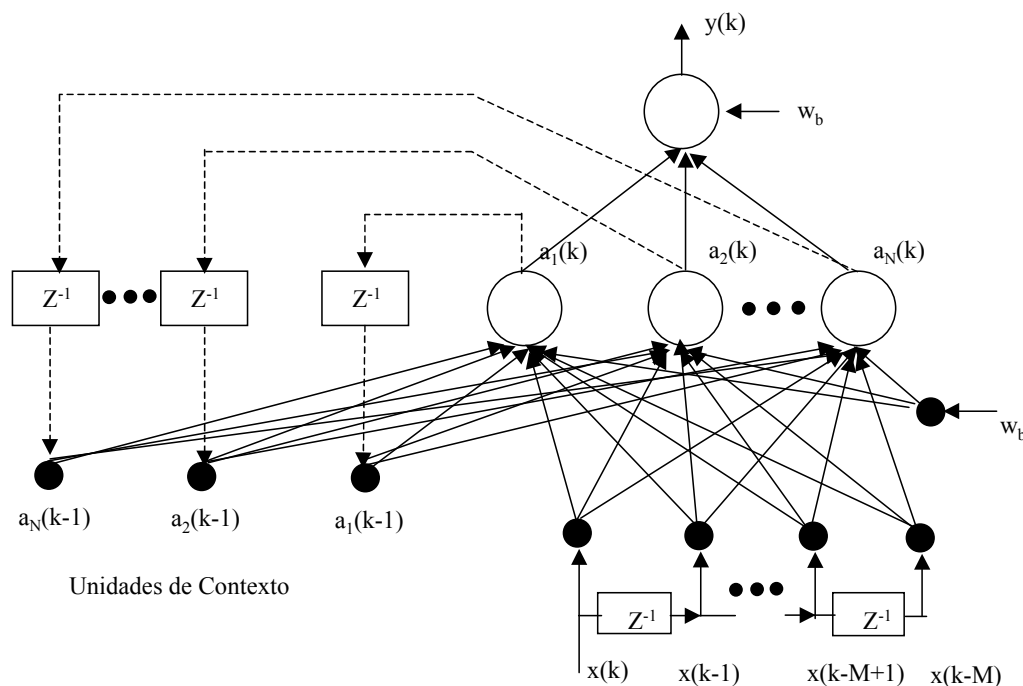


Figura 2.15 Rede de Elman (Soto, 1999).

Na rede de Williams-Zipser a(s) camada(s) oculta(s) possuem unidades de contexto e um laço de realimentação da saída da rede para as unidades escondidas (Figura 2.16).

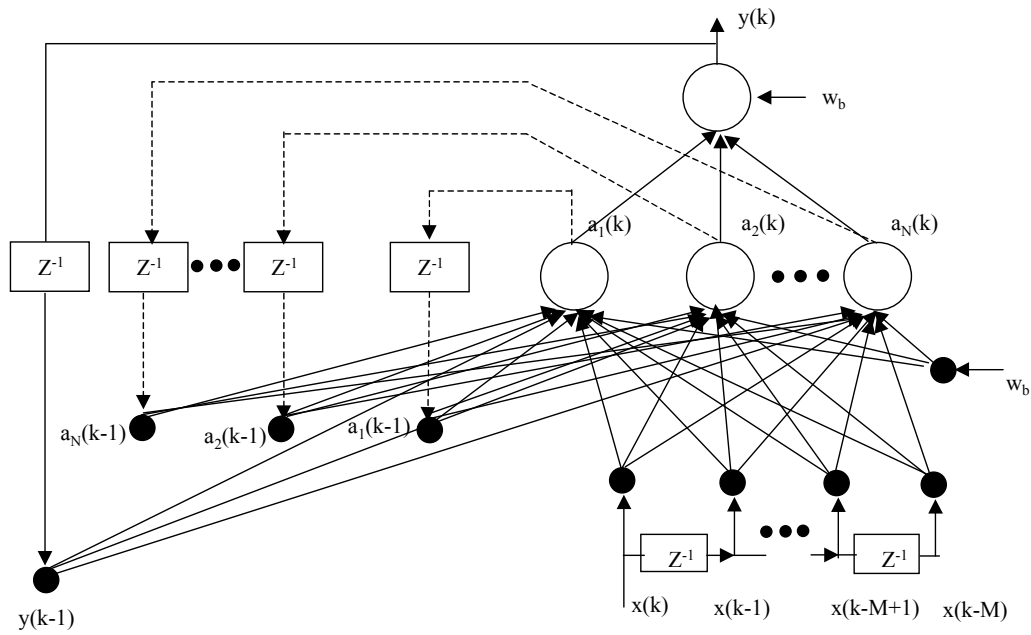


Figura 2.16 Rede de Williams-Zipser (Soto, 1999).

Na rede tipo Jordan considera-se somente realimentação dos valores de ativação de saída para as unidades de contexto (figura 2.17).

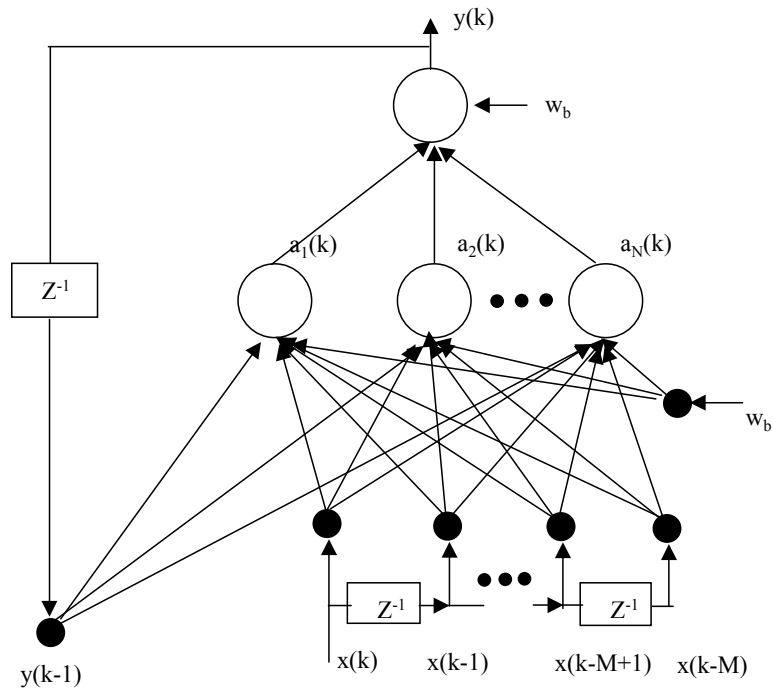


Figura 2.17 Rede de Jordan (Soto, 1999).

2.4.8.4 Redes neurais Elman

Na rede neural Elman ou rede completamente recorrente (Figura 2.18), a saída de cada neurônio da camada oculta realimenta todos os neurônios da camada oculta. Neste tipo de arquitetura que utiliza o conceito de realimentação global, cada neurônio da camada oculta está completamente conectado ao vetor de estados $a(k-1)$.




Figura 2.18 Rede completamente recorrente – Rede de Elman. (Soto, 1999).

onde

$x(k)$ é a entrada externa no tempo discreto k ,

$a(k)$ é o vetor contendo as saídas dos N neurônios da camada oculta no tempo discreto k ,

$z^h(k)$ é o conjunto de entradas dos neurônios da camada oculta, denominado vetor de estados,

$y(k)$ é a saída da rede no tempo discreto k .

A seguir, são mostradas as equações para uma rede neural Elman com uma entrada e uma saída (Figura 2.18). As entradas da camada oculta são definidas por:

$$z_i^h(k) = \begin{cases} x_i(k) & , \quad i \in l \\ a_i(k-1) & , \quad i \in H \end{cases} \quad (2.48)$$

onde

I representa uma camada externa,

H representa o conjunto de saídas dos neurônios da camada oculta.

A saída do j -ésimo neurônio da camada oculta é:

$$a_j(k) = \varphi\left(\sum_{i \in I} w_{ji} x_i(k) + \sum_{i \in H} w_{ji} a_i(k-1) + w_{jb}\right), \quad j \in H \quad (2.49)$$

onde

$\varphi()$ é a função de ativação não-linear,

w_{jb} é o peso do bias.

Para o neurônio da camada de saída, a saída $y(k)$ é representada pela equação 2.50, onde “ o ” representa camada de saída.

$$y(k) = f\left(\sum_{i \in H} w_{oi} a_i(k) + w_{bo}\right) \quad (2.50)$$

O algoritmo de treinamento da rede neural Elman é o algoritmo de regularização bayseana. É importante notar que a quantidade de pesos sinápticos aumenta, já que as entradas da camada oculta são as entradas externas e os valores de saídas da camada oculta no tempo anterior.

Deve-se tomar o cuidado de considerar valores iniciais das saídas dos neurônios ocultos e de saída no tempo ($k=0$). Este cuidado permite que as saídas no tempo $k=0$ não influenciem a saída da rede na primeira interação. Adotam-se como valores iniciais:

$$\begin{aligned} a_j(0) &= 0 \\ y(0) &= 0 \end{aligned}, \quad j \in H \quad (2.51)$$

2.5 Métodos Geoestatísticos

Métodos geoestatísticos foram desenvolvidos na década de 60 pelo engenheiro francês Matheron (1962, 1970) para o estudo de variáveis regionalizadas. As variáveis regionalizadas apresentam uma característica importante que é a sua continuidade, cuja avaliação está fundamentada nos

princípios da regressão linear que, na estatística, investiga a dependência entre variáveis de um fenômeno.

Na geoestatística, baseada na teoria das funções aleatórias, procura-se avaliar a dependência da variável com ela própria, avaliada em diferentes posições separadas por um vetor \vec{h} . A continuidade da variável pode ser descrita através de 3 parâmetros inter-relacionados: a função de covariância $C(h)$, o correlograma $\rho(h)$ e o variograma $\gamma(h)$.

2.5.1 Função Covariância

Neste trabalho adotaremos o símbolo \sim (til) para referenciar os parâmetros do modelo e o símbolo $\hat{}$ (acento circunflexo) para os valores estimados. Então \tilde{m} corresponde à média dos valores idealizados como realizações de uma função aleatória, m significa a média aritmética entre valores observados.

A função covariância, como o nome indica, representa a variação entre variáveis separadas pela distância h .

$$\tilde{C}_v(h) = Cov\{V(x).V(x+h)\} \quad (2.52)$$

$$\tilde{C}_v(h) = E\{V(x).V(x+h)\} - E\{V(x)\}.E\{V(x+h)\} \quad (2.53)$$

Onde o valor esperado da variável aleatória $E\{V(x)\}$ denota a sua média \tilde{m} . Para funções aleatórias estacionárias, $E\{V(x)\} = E\{V(x+h)\}$, resultando:

$$\tilde{C}_v(h) = E\{V(x).V(x+h)\} - E\{V(x)\}^2 \quad (2.54)$$

2.5.2 Função correlação ou correlograma

É expressa pela normalização da função covariância em relação aos desvios padrões.

$$\tilde{\rho}_V(h) = \frac{Cov\{V(x) \cdot V(x+h)\}}{\sqrt{Var\{V(x)\} \cdot Var\{V(x+h)\}}} \quad (2.55)$$

Como a covariância entre variáveis na mesma posição é a variância da função aleatória,

$$\tilde{C}_V(0) = Cov\{V(x) \cdot V(x)\} = Var\{V(x)\} \quad (2.56)$$

$$\tilde{C}_V(0) = E\{V^2(x)\} - E\{V(x)\}^2 \quad (2.57)$$

Então

$$\tilde{\rho}_V(h) = \frac{\tilde{C}_V(h)}{\tilde{C}_V(0)} \quad (2.58)$$

2.5.3 Variograma

O variograma é expresso matematicamente como a metade do quadrado das diferenças esperado entre variáveis aleatórias distanciadas de h,

$$\tilde{\gamma}_v(h) = \frac{1}{2} E\{[V(x) - V(x+h)]^2\} \quad (2.59)$$

$$\tilde{\gamma}_v(h) = \frac{1}{2} E\{V^2(x)\} - E\{V(x) \cdot V(x+h)\} + \frac{1}{2} E\{V^2(x+h)\} \quad (2.60)$$

Considerando que para funções aleatórias estacionárias $E\{V^2(x)\} = E\{V^2(x+h)\}$, a expressão acima pode ser escrita como

$$\tilde{\gamma}_v(h) = E\{V^2(x)\} - E\{V(x) \cdot V(x+h)\} \quad (2.61)$$

Adicionando e subtraindo $E\{V(x)\}^2$ ao segundo termo da equação acima,

$$\tilde{\gamma}_v(h) = E\{V^2(x)\} - E\{V(x)\}^2 - \{E[V(x) \cdot V(x+h)] - E\{V(x)\}^2\} \quad (2.62)$$

Com auxílio das equações (2.54), (2.56) e (2.61) obtemos,

$$\tilde{\gamma}_v(h) = \tilde{C}_v(0) - \tilde{C}_v(h) \quad (2.63)$$

A equação (2.54) pode ser escrita como

$$\tilde{C}_v(h) = \tilde{C}_v(0) - \tilde{\gamma}_v(h) \quad (2.64)$$

$$\tilde{C}_v(h) = \tilde{\gamma}_v(\infty) - \tilde{\gamma}_v(h) \quad (2.65)$$

As funções covariância, correlograma e variograma fornecem as mesmas informações de maneira ligeiramente diferente, como mostra a figura 2.19. O correlograma inicia com o valor 1, tendendo a zero com o crescimento de h , enquanto que a função covariância decresce de forma similar a partir do valor inicial $\tilde{C}(0) = \tilde{\sigma}^2$. O variograma inicia em 0 aumentando até o valor máximo $\tilde{\gamma}^2(\infty) = \tilde{\sigma}^2$, referenciando como patamar (“*Sill*”).




Figura 2.19 Esquema de funções: (a) covariância, (b) correlograma e (c) variograma (Xavier, 1999).

Na figura 2.20 são descritas as principais características da função variograma $\tilde{\gamma}(h)$:

- Alcance a (“*range*”): distância a partir da qual os valores do variograma permanecem essencialmente constantes.
- Patamar $C + C_0$ (“*sill*”): valor máximo do variograma para distâncias muito grandes $\tilde{\gamma}(\infty)$. Expressa a variância $\tilde{\sigma}^2$ da variável aleatória.
- Efeito pepita C_0 : representa descontinuidades na origem causada por diversos fatores, como por exemplo erros de amostragem.




Figura 2.20 Esquema básico de uma função variograma (Xavier, 1999).

2.5.4 Modelos Variográficos

Os modelos variográficos são utilizados para se obter valores de $\gamma(h)$ em distâncias e direções para as quais não se dispõem de observações experimentais. Já que no método de krigagem ordinária, estes valores $\gamma(h)$ serão necessários.

Como os resultados das estimativas devem existir e serem únicos, o sistema de equações lineares gerados pela krigagem ordinária necessita possuir uma matriz positivo-definida que, por sua vez, impõe a condição de que modelos variográficos sejam construídos com auxílio de funções positivo-definidas. Dentre estes principais modelos podem ser citados (Xavier, 1999):

- Modelo esférico

Modelo variográfico mais frequentemente usado, expresso por:

$$\gamma(h) = \begin{cases} C \cdot \left[1.5 \cdot \left(\frac{h}{a} \right) - 0.5 \cdot \left(\frac{h}{a} \right)^3 \right] & \text{para } h \leq a \\ C & \text{para } h > a \end{cases} \quad (2.66)$$

b) Modelo exponencial:

$$\gamma(h) = C \left(1 - e^{-\frac{3h}{a}} \right) \quad (2.67)$$

c) Modelo Gaussiano:

Modelo variográfico freqüentemente usado para fenômenos naturais com elevada continuidade.

$$\gamma(h) = C \left(1 - e^{-\frac{3h^2}{a^2}} \right) \quad (2.68)$$

O efeito pepita pode ser considerado somado-se ao modelo variográfico como uma constante C_0 .

2.5.5 Krigagem ordinária

O método de krigagem ordinária é associado na língua inglesa, a sigla B.L.U.E significando “*the best linear unbiased estimator*”. Linear porque suas estimativas são feitas por combinações lineares, “*unbiased*” (sem viés) porque o erro de estimação esperado no modelo é nulo ($m_R = 0$) e “*best*” porque seu objetivo é minimizar a variância dos erros $\tilde{\sigma}_R^2$.

O erro de estimação é expresso por

$$R(x_0) = \hat{V}(x_0) - V(x_0) \quad (2.69)$$

e sua variância pode ser definida como:

$$\text{Var}\{R(x_0)\} = \text{Var}\{\hat{V}(x_0) - V(x_0)\} \quad (2.70)$$

$$\text{Var}\{R(x_0)\} = \text{Cov}\{\hat{V}(x_0) \cdot \hat{V}(x_0)\} - 2 \cdot \text{Cov}\{\hat{V}(x_0) \cdot V(x_0)\} + \text{Cov}\{V(x_0) \cdot V(x_0)\} \quad (2.71)$$

O termo $\text{Cov}\{\hat{V}(x_0) \cdot \hat{V}(x_0)\}$ representa a própria variância de $\hat{V}(x_0)$, ou seja

$$\text{Cov}\{\hat{V}(x_0) \cdot \hat{V}(x_0)\} = \text{Var}\{\hat{V}(x_0)\} \quad (2.72)$$

Sabendo que a estimativa $\hat{V}(x_0)$ é expressa pela combinação linear de $V(x_i)$ para $i = 1, 2, \dots, n$

$$\hat{V}(x_0) = \sum_{i=1}^n w_i \cdot V(x_i) \quad (2.73)$$

Resulta

$$\text{Cov}\{\hat{V}(x_0) \cdot \hat{V}(x_0)\} = \text{Var}\left\{\sum_{i=1}^n w_i \cdot V(x_i)\right\} \quad (2.74)$$

$$\text{Cov}\{\hat{V}(x_0) \cdot \hat{V}(x_0)\} = \sum_{i=1}^n \sum_{j=1}^n w_i \cdot w_j \cdot \text{Cov}\{V(x_i) \cdot V(x_j)\} \quad (2.75)$$

$$\text{Cov}\{\hat{V}(x_0) \cdot \hat{V}(x_0)\} = \sum_{i=1}^n \sum_{j=1}^n w_i \cdot w_j \cdot \tilde{C}_{ij} \quad (2.76)$$

O termo $2 \cdot \text{Cov}\{\hat{V}(x_0) \cdot V(x_0)\}$ pode ser escrito como

$$2 \cdot \text{Cov}\{\hat{V}(x_0) \cdot V(x_0)\} = 2 \cdot \text{Cov}\left\{\left(\sum_{i=1}^n w_i \cdot V(x_i)\right) \cdot V(x_0)\right\} \quad (2.77)$$

$$2 \cdot \text{Cov}\{\hat{V}(x_0) \cdot V(x_0)\} = 2 \cdot E\left\{\sum_{i=1}^n w_i \cdot V(x_i) \cdot V(x_0)\right\} - 2 \cdot E\left\{\sum_{i=1}^n w_i \cdot V(x_i)\right\} \cdot E\{V(x_0)\} \quad (2.78)$$

$$2 \cdot \text{Cov}\{\hat{V}(x_0) \cdot V(x_0)\} = 2 \cdot \sum_{i=1}^n w_i \cdot \{E\{V(x_i) \cdot V(x_0)\} - E\{V(x_i)\} \cdot E\{V(x_0)\}\} \quad (2.79)$$

$$2 \cdot Cov\{\hat{V}(x_0) \cdot V(x_0)\} = 2 \cdot \sum_{i=1}^n w_i \cdot \tilde{C}_{i0} \quad (2.80)$$

O termo $Cov\{V(x_0) \cdot V(x_0)\}$ pode ser expresso como

$$Cov\{V(x_0) \cdot V(x_0)\} = Var\{V(x_0)\} \quad (2.81)$$

$$Cov\{V(x_0) \cdot V(x_0)\} = \tilde{\sigma}^2 \quad (2.82)$$

Assim, a equação (2.71) pode ser então finalmente escrita como

$$\tilde{\sigma}_R^2 = \tilde{\sigma}^2 + \sum_{i=1}^n \sum_{j=1}^n w_i \cdot w_j \cdot \tilde{C}_{ij} - 2 \cdot \sum_{i=1}^n w_i \cdot \tilde{C}_{i0} \quad (2.83)$$

Uma vez selecionado o modelo do variograma (ou da função covariância) é possível determinar-se $\tilde{\sigma}^2$ e todas as covariâncias \tilde{C}_{ij} .

A minimização da função a n variáveis produz então um sistema de n equações a n incógnitas que pode ser resolvido por qualquer método da álgebra linear para solução de um sistema de equações lineares.

Para garantir que a condição de não viés seja automaticamente satisfeita é acrescentado à equação (2.83) a condição de restrição $\left(\sum_{i=1}^n w_i = 1 \right)$, resultando em um problema de minimização com restrição. Então este problema de minimização com restrição deve ser resolvido pelo método do multiplicador de Lagrange (2.84).

$$\tilde{\sigma}_R^2 = \tilde{\sigma}^2 + \sum_{i=1}^n \sum_{j=1}^n w_i \cdot w_j \cdot \tilde{C}_{ij} - 2 \cdot \sum_{i=1}^n w_i \cdot \tilde{C}_{i0} + 2 \cdot \mu \cdot \left(\sum_{i=1}^n w_i - 1 \right) \quad (2.84)$$

O multiplicador de Lagrange μ introduz uma nova incógnita no problema, agora expresso sem restrição já que a condição de não viés é automaticamente satisfeita por (2.84).

$$\frac{\partial \tilde{\sigma}_R^2}{\partial w_i} = 0 \quad \text{para } i = 1, \dots, n \quad (2.85)$$

$$\frac{\partial \tilde{\sigma}_R^2}{\partial \mu} = 0 \quad (2.86)$$

produz um sistema de (n+1) equações que pode ser expresso sob forma matricial da seguinte maneira:

$$\begin{bmatrix} \tilde{C}_{11} & \dots & \tilde{C}_{1n} & 1 \\ \tilde{C}_{21} & \dots & \tilde{C}_{2n} & 1 \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \tilde{C}_{n1} & \dots & \tilde{C}_{nm} & 1 \\ 1 & \dots & 1 & 0 \end{bmatrix} \cdot \begin{Bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ \cdot \\ w_n \\ \mu \end{Bmatrix} = \begin{Bmatrix} \tilde{C}_{10} \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ \tilde{C}_{n0} \\ 1 \end{Bmatrix} \quad (2.87)$$

ou,

$$[C] \cdot \{W\} = \{D\} \quad (2.88)$$

possibilitando que as incógnitas w_1, \dots, w_n sejam obtidas sem maiores dificuldades através do método de eliminação de Gauss, por exemplo:

O valor da variância do erro minimizada pode enfim ser calculada como:

$$\tilde{\sigma}_R^2 = \tilde{\sigma}^2 - \{W\}^T \cdot \{D\} \quad (2.89)$$

3 INTERVALOS DE CONFIANÇA

3.1 Introdução

A estimativa de intervalos de confiança é utilizada para se obter medidas de incerteza dos dados analisados. A análise da incerteza de uma previsão, por exemplo, permite analisar melhor o erro envolvido no problema.

Isaaks & Srivastava (1989) descrevem os principais fatores que influenciam nos erros de uma estimativa:

- a) Quantidade de amostras vizinhas: quanto maior a quantidade de amostras vizinhas do ponto a ser estimado melhor será a previsão;
- b) Proximidades das amostras do ponto a ser estimado: quanto mais próximo as amostras estiverem do ponto que esta tentando se estimar maior será a confiança no valor estimado;
- c) Arranjo espacial das amostras: indica que a localização espacial das amostras em relação ao ponto estimado influencia na confiabilidade da previsão (Figura 3.1);
- d) Natureza do fenômeno a ser estudado: está associado ao tipo de problema analisado. Variáveis bem comportadas e com variações extremamente suaves devem gerar estimativas mais confiáveis do que problemas que envolvem variáveis muito irregulares.




Figura 3.1 O efeito de amostras adicionais na confiabilidade da estimativa. A estimativa de um valor desconhecido com um sinal da cruz no centro (a) deve tornar-se mais confiável com amostras adicionais. O arranjo espacial das amostras em (b), entretanto, não melhorará a confiabilidade tanto quanto as amostras uniformemente distribuídas em (c) (Isaaks & Srivastava (1989)).

Esses fatores interagem e o grau de importância de cada fator depende do problema analisado. Por exemplo, para a previsão de uma variável bem comportada e com variações extremamente suaves, a proximidade das amostras deve ser mais importante que o número de amostras. Neste caso, será melhor ter uma amostra muito próxima do ponto a ser estimado do que várias amostras distantes. Enquanto que na previsão de uma variável muito irregular é preferível ter várias amostras com uma certa distância do que uma única amostra vizinha.

Então quando for utilizado um método para caracterizar as incertezas das nossas estimativas, deve-se lembrar sempre destes quatro fatores: número e proximidade das amostras, arranjo espacial das amostras e continuidade do fenômeno, para analisar quais fatores o método empregado é capaz de considerar.

Intervalos de confiança é o modo mais familiar de responder por esta inabilidade para fixar um valor desconhecido exatamente. Então, ao invés de fornecer-se um valor exato, informa-se um intervalo e a probabilidade que o valor desconhecido esteja dentro deste intervalo. Por exemplo, quando se diz que um

intervalo de confiança $\pm 3\%$ com probabilidade de 90% significa dizer que se forem olhadas todas as estimativas do conjunto, o valor estará dentro dos 3% nas estimativas correspondentes em aproximadamente 90% das amostras do conjunto.

A idéia aplicada na estimativa dos intervalos de confiança é que embora não se possa calcular a magnitude atual de um erro individual, possamos agrupar várias estimativas de localizações diferentes e possamos tentar fazer algumas declarações sobre a distribuição destes erros.

Este capítulo trata da definição de intervalos de confiança para as previsões geradas por redes neurais artificiais e pelos métodos geoestatísticos.

3.2

Técnicas para estimar intervalos de confiança para redes neurais

Redes neurais artificiais (RNA's) são sistemas paralelos distribuídos formados por unidades de processamento simples (neurônios) que calculam funções matemáticas, geralmente não-linear. São utilizadas principalmente em problemas de previsão e classificação de padrões em diferentes áreas, como por exemplo, industrial, médica ou financeira.

Problemas de previsão são complexos já que as informações disponíveis do problema podem ser limitadas e o sistema pode ser incerto. A grande questão é qual a precisão da previsão. Isto é importante devido o resultado da previsão ser normalmente utilizado na tomada de decisão. A precisão da previsão permite aos usuários da rede neural determinar a confiança da saída da rede neural. Também permite incluir a saída estimada da rede como parte de um esquema de estimação global.

O conjunto de dados de entrada utilizado na previsão geralmente é disperso e com erros de medição. Estes dados utilizados como entradas do modelo neural geram incertezas denominadas incertezas na entrada. Existe ainda o erro na saída da rede originado por ruídos na saída e pela escolha de modelos de rede imperfeitos (definição dos pesos sinápticos inadequados). Estes erros são responsáveis pelas incertezas dos pesos. A incerteza total da previsão é a combinação das incertezas na entrada com a incerteza nos pesos.

Então a estimativa de intervalos de confiança associada à previsão aumentam a confiabilidade na rede neural. Diversos métodos para estimar os intervalos de confiança têm sido apresentados na literatura.

Chryssolouris et al. (1996) desenvolveram um método para estimar intervalos de confiança baseado em um modelo para prever intervalos de confiança que considera uma distribuição normal para os erros (usando a distribuição t-student) em lugar de covariância para as saídas. Este método difere de outros métodos existentes devido não ser necessário informações sobre as segundas derivadas da saída da rede neural.

Rivals & Personnaz (2000) apresentam resultados teóricos da construção de intervalos de confiança para uma regressão não linear, baseado na estimação do mínimo quadrado e utilizando a expansão linear de Taylor da correspondente saída do modelo não linear. Eles aplicam a metodologia desenvolvida em um modelo de rede neural. Um problema real é analisado e simulado. Os trabalhos mostram ainda que a expansão linear de Taylor não fornece somente um intervalo de confiança em qualquer ponto de interesse, mas também fornece uma ferramenta para detectar *overfitting*.

Townsend & Taransenko (1999) analisam o problema de estimativa de precisão das saídas da rede neural através de um modelo de perturbação. Neste trabalho, as fontes de ruídos modelados inicialmente estão no vetor de entrada e nos pesos. O modelo de perturbação é aplicado a redes de bases de funções radiais.

Papadopoulus et al. (2001) comparam três métodos de estimativa de intervalos de confiança. Os três métodos são probabilidade máxima, aproximação bayesiana e técnica bootstrap. Os métodos são testados com problemas artificiais e problemas reais.

Alves da Silva & Moulin (1999) e Alves da Silva & Moulin (2000) utilizam três técnicas para cálculo de intervalos de confiança. As técnicas são: saída de erro, *re-amostragem dos erros* e regressão multilinear adaptada para redes neurais. O problema analisado é previsão de cargas de curto tempo. A previsão das cargas é obtida com o auxílio de redes perceptrons multi-camadas.

Zhang & Luh (2001) e Zhang et al. (2003) estudam intervalos de confiança para a previsão gerada por uma rede neural em cascata utilizando *bayesian inference framework*. Este método considera ruídos nos pesos, ruídos dos dados de entrada medidos e ruídos de entradas gerados no processo de previsão. Neste método a distribuição de saída é aproximada para uma distribuição gaussiana. A variância da saída pode ser calculada pelo método metrópole ou por um método

memoryless Quasi-Newton. O método *memoryless Quasi-Newton* é rápido e com boas características computacionais.

Neste trabalho, os intervalos de confiança serão gerados utilizando as técnicas: saída de erro e *re-amostragem dos erros*. . Nas seções seguintes serão apresentadas estas técnicas.

3.2.1 Saída de Erro

Na técnica de saída de erro, a rede neural possui duas saídas. A primeira saída corresponde a previsão da vazão e a outra saída ao erro de previsão da vazão. Deste modo, os intervalos de confiança são gerados durante o processo de previsão. A ideia proposta por Alves da Silva & Moulin (2000) é que seja possível capturar possíveis padrões existentes na previsão do erro, assim como é possível também na previsão da vazão. A figura 3.2 mostra um exemplo de rede neural para a técnica de erro de saída.




Figura 3.2 Rede neural para a técnica erro de saída (Alves da Silva & Moulin (2000)).

O treinamento da rede neural consiste em se calcular a cada época de treinamento os padrões para o neurônio de saída do erro de previsão. Então para cada par entrada-saída conhecido utilizado para treinar a rede, o erro da previsão da vazão obtido com a rede é calculado. Deste modo, em cada época um padrão de treinamento diferente será usado para a previsão do erro.

O processo de treinamento deve convergir para um conjunto de pesos sinápticos com erros de previsão de vazão baixo. É esperado que os erros da saída de erro sejam baixos também. Isto acontece porque os padrões de treinamento para a saída de erro tornam-se mais estável ao longo das interações. Caso contrário, o processo de treinamento divergiria.

Durante o processo de treinamento o erro de porcentagem absoluto da previsão de vazão é utilizado como padrão de treinamento para o neurônio do erro de saída. Este erro é usado no lugar do erro relativo devido ser mais fácil de ser aprendido. Depois do treinamento da rede neural, o erro de saída, é somado e subtraído da previsão da vazão, para gerar um intervalo de confiança simétrico.

Nesta técnica, o grau de confiança do intervalo de confiança não é pré-definido. Deve ser calculado verificando o sucesso da estimação do intervalo de confiança para o conjunto de teste.

3.2.2 Re-amostragem dos erros

A técnica de *re-amostragem dos erros* dos erros de previsão para cada previsão um passo a frente pode ser feita do modo descrito por Alves da Silva & Moulin (2000). O conjunto utilizado para *re-amostragem dos erros* deve ser representativo das vazões futuras. Considera-se ainda, que erros das amostras são independentes um dos outros, embora a distribuição de probabilidade seja desconhecida.

Figura 3.3 representa o conjunto de dados de teste disponíveis. O processo recursivo de previsão, considerando dois *lags* de entrada para a previsão três passos a frente, é considerado. O valor da vazão conhecida para os tempos 1 e 2 são utilizados para a previsão da vazão para o tempo 3. Como o valor da vazão verdadeiro para o tempo 4 é conhecido, o erro de previsão para este um passo a frente pode ser calculado. Em seguida, usando o valor conhecido para 2, e a previsão prévia para o tempo 3, o valor dois passos à frente é encontrado, permitindo o cálculo do erro de previsão correspondente. Os valores previstos para o tempo 3 e 4 são usados para encontrar a previsão da vazão para o tempo 5, e assim por diante. Medidas de previsão do erro para cada tempo foram obtidas, uma vez que a distância de previsão máxima desejada, instante 5, é encontrada.




Figura 3.3 Exemplo da técnica de *re-amostragem dos erros* (Alves da Silva & Moulin)

(2000)).

O procedimento descrito anteriormente é repetido para coleccionar mais amostras para cada tempo, com os valores de vazão conhecidos dos tempos 2 a 6 (linha pontilhada superior). Este processo é repetido até, para uma certa janela, a distância máxima desejada de predição alcance o fim da série conhecida.

Em seguida, os n erros são organizados em ordem (considerando os sinais) e são representados por $z_{(1)}, z_{(2)}, \dots, z_{(n)}$, a função de distribuição cumulativa dos erros de previsão das amostras pode ser calculada como mostrado a seguir:

$$S_n(z) = \begin{cases} 0 & , \quad z < z_{(1)} \\ \frac{r}{n} & , \quad z_{(r)} \leq z < z_{(r+1)} \\ 1 & , \quad z_{(n)} \leq z \end{cases} \quad (3.1)$$

$S_n(z)$ é a fração do conjunto de erros menor ou igual a z . Quando n é grande o suficiente, $S_n(z)$ é uma boa aproximação da distribuição de probabilidade cumulativa $F(z)$. Então, o intervalo de confiança pode ser calculado mantendo os $z(r)$'s valores intermediários e eliminando as extremidades, a quantidade de valores das extremidades descartados depende do grau de confiança desejado. O intervalo de confiança é calculado para ser simétrico em probabilidade (geralmente não simétrico em z). O número de casos para eliminar em cada extremidade da distribuição de erro da previsão é np onde p é a probabilidade em cada extremidade. Considerando que np geralmente é um número fracionário, é truncado de modo conservador, e $(np-1)$ é levado como o número de casos para eliminar em cada extremidade.

Z_p denotando tal que $F(Z_p)$ é igual a p , isto é, há uma probabilidade p que um erro seja menor ou igual a Z_p , indica que Z_p é o intervalo de confiança inferior para os erros de previsão futuras. Então, Z_{1-p} é o limite superior do intervalo de confiança e há um $(1-2p)$ intervalo de confiança para erros futuros.

3.3

Técnicas para estimar intervalos de confiança para métodos geoestatísticos

Em problemas em que o erro da krigagem apresente uma distribuição gaussiana, ou seja, a distribuição pode ser representada pela sua média igual a

zero e pela sua variância ($\tilde{\sigma}_R^2$). Considerando que o variograma é conhecido, a variância da krigagem é determinada sem erro, sendo possível afirmar que:

$$\Pr(|\hat{V}(x_0) - V(x_0)| > 2\tilde{\sigma}_R) \cong 0.05 \quad (3.2)$$

Conduzindo ao intervalo de confiança de 95 % para $V(x_0)$

$$[\hat{V}(x_0) - 2\tilde{\sigma}_R, \hat{V}(x_0) + 2\tilde{\sigma}_R] \quad (3.3)$$

Nos casos em que a distribuição do erro não é gaussiana, mas a distribuição do erro é contínua e unimodal, pode-se utilizar a desigualdade proposta por Vysochanskii-Petunin em 1980 e abordada em Chilès & Delfiner (1999) para determinação do intervalo que compreenda 95% de probabilidade.

A desigualdade considera que se X é uma variável randômica com uma densidade de probabilidade f , que é não decrescente até o modo ν e não crescente depois, e se $d^2 = E(X - \alpha)^2$ é o desvio quadrado esperado em um ponto arbitrário α , então

$$\begin{aligned} \Pr(|X - \alpha| \geq td) &\leq \frac{4}{9t^2} && \forall t \geq \sqrt{\frac{8}{3}} \\ &\leq \frac{4}{3t^2} - \frac{1}{3} && \forall t \leq \sqrt{\frac{8}{3}} \end{aligned} \quad (3.4)$$

Onde X é o erro da krigagem, $t = 3$ e $\alpha = 0$, então $d^2 = \tilde{\sigma}_R^2$ e

$$\begin{aligned} \Pr(|\hat{V}(x_0) - V(x_0)| > 3\tilde{\sigma}_R) &\leq \frac{4}{9(3)^2} \\ &\leq 0.05 \end{aligned} \quad (3.5)$$

Então o intervalo de confiança de 95 % para $V(x_0)$ é:

$$[\hat{V}(x_0) - 3\tilde{\sigma}_R, \hat{V}(x_0) + 3\tilde{\sigma}_R] \quad (3.6)$$

4 METODOLOGIA

4.1 Introdução

Neste capítulo descreve-se as características principais da barragem de Funil e das instrumentações de vazões analisadas neste trabalho. Trata-se ainda, da metodologia adotada para utilização das técnicas empregadas neste trabalho.

4.2 Barragem de Funil

A barragem de Funil (Figura 4.1), situada próxima da cidade de Resende no Estado do Rio de Janeiro, é uma barragem do tipo abóbada de dupla curvatura com altura máxima de 85 m e comprimento máximo de 385 m. A casca tem uma espessura de 12 m na base e 3,6 m no topo. O volume total de concreto é de 286.000 m³. A capacidade de produção de energia é de 216 MW.



Figura 4.1 Arranjo geral da barragem Funil do tipo abóbada de dupla curvatura.

O sistema de medição monitora as seguintes grandezas:

- a) Temperatura é medida no interior da casca, do soco e do encosto. A figura 4.3 mostra o quadro de controle dos extensômetros e dos termômetros;
- b) Deformações são medidas utilizando extensômetros;
- c) Três drenos captam água. O dreno “D191” (figura 4.4) capta a água drenada da fundação da barragem. O dreno “D192” (figura 4.5) capta a água drenada da margem direita. O dreno “D193” (figura 4.6) capta a água drenada da margem esquerda;
- d) Deslocamentos das juntas de dilatação;
- e) Piezômetros medem a pressão hidrostática;
- f) Deslocamentos horizontais, tangenciais e radiais são medidos em ambas as margens com cordinômetros;
- g) Deslocamento vertical da barragem.

As medições das grandezas são feitas ao longo de galerias no interior da barragem (Figura 4.2).



Figura 4.2 Galeria no soco da barragem de Funil.



Figura 4.3 Quadro de controle dos extensômetros e do termômetro.



Figura 4.4 Dreno "D191".



Figura 4.5 Dreno "D192".



Figura 4.6 Dreno "D193".

As medidas de vazão ao longo da barragem e sob a barragem são importantes indicadores do bom funcionamento da barragem durante o período de operação. Caso algum problema ocorra no comportamento geotécnico da barragem, os valores anormais serão captados pelo sistema de aquisição de dados de vazões. Então a geração de modelos de previsão, que forneçam valores futuros

das medidas de vazão, é uma ferramenta importante para o sistema de segurança da barragem.

4.3 Análise e preparação dos dados

Os dados considerados são as séries temporais das leituras de vazão dos drenos “D191”, “D192”, “D193”, o nível do reservatório e a temperatura. As séries foram amostradas a partir de 02/09/1985 a 25/02/2002, totalizando 737 amostras.

O grau de correlação existente entre as séries temporais de vazão dos drenos “D191”, “D192” e “D193” e a série das cotas do nível d’água do reservatório e a série das leituras de temperatura foi analisado. Determinou-se nesta análise que o coeficiente de correlação entre as medidas de vazão do dreno “D191” e as cotas do nível d’água é de 58%, entre as medidas de vazão do dreno “D192” e as cotas do nível d’água é de 65% e entre as medidas de vazão do dreno “D193” e as cotas do nível d’água é de 63%. Constatou-se ainda, nesta análise que o coeficiente de correlação entre as medidas de vazão do dreno “D191” e as medidas de temperatura é de -30%, entre as medidas de vazão do dreno “D192” e as medidas de temperatura é de -15% e entre as medidas de vazão do dreno “D193” e as medidas de temperatura é de -4%. As correlações encontradas para a série da cota do nível d’água justificam a inclusão desta série como variável explicativa em alguns modelos de previsão por redes neurais temporais. Apesar das correlações baixas encontradas para a série de temperatura, esta foi também considerada como variável explicativa, com o intuito de analisar se o grau de correlação é realmente um mecanismo eficiente de seleção de variáveis de entrada para a rede neural temporal.

O grau de correlação existente entre as séries temporais de vazão dos drenos “D191”, “D192” e “D193” foi analisado. Nesta análise observou-se que o coeficiente de correlação entre as medidas de vazão do dreno “D191” e as medidas de vazão do dreno “D192” é de 53%, entre as medidas de vazão do dreno “D191” e as medidas de vazão do dreno “D193” é de 57% e entre as medidas de vazão do dreno “D192” e as medidas de vazão do dreno “D193” é de 83%. Apesar de somente a correlação entre os drenos “D192” e “D193” ser alta, todas as

medidas de vazões serão consideradas como variáveis explicativas, pelo mesmo motivo apresentado para a consideração da temperatura como variável explicativa.

As séries passaram por uma etapa de pré-processamento de dados para completar dados faltantes e substituir leituras aberrantes por valores obtidos por interpolação utilizando *splines cúbicas*. A normalização dos valores entre 0 e 1 torna a etapa de treinamento das redes mais eficiente.

4.4 Análises realizadas

Serão realizadas duas análises. A primeira considera as séries com intervalo de tempo constante, ou seja, o tempo decorrido entre duas amostras será sempre o mesmo. Enquanto que na segunda análise as séries apresentam intervalo de tempo variável, ou seja, o intervalo de tempo entre as amostras é diferente ao longo das séries.

Na análise com intervalo de tempo constante, as séries foram alteradas, com a inclusão de novos dados, para ficarem com intervalo de tempo igual. Nesta etapa, as séries apresentam frequência semanal. Estas séries são compostas por 455 amostras, das 737 amostras originais. A redução do conjunto original de amostras ocorre devido o intervalo de tempo entre a amostra na data 16/05/1994 e a amostra sucessiva (26/09/94) ser muito grande. Inviabilizando a utilização das *splines* cúbicas para inclusão destes novos dados, já que os erros da interpolação seriam elevados. Então as séries utilizadas para a análise com intervalo de tempo constante possuem apenas 455 amostras, compreendidas entre as datas 09/09/1985 e 16/05/1994.

Na análise com intervalo de tempo variável, a data da amostra foi considerada como variável explicativa. Para considerar o aspecto temporal das séries utiliza-se uma função seno para representar a data, indicada na equação (4.1). Nesta análise, foram consideradas todas as 737 amostras.

$$entrada = \text{sen}\left(\frac{2\pi(data - data_origem)}{365}\right) \quad (4.1)$$

4.5 Técnicas empregadas

As técnicas de redes neurais temporais, método estatístico de Box & Jenkins (1970) e métodos geoestatísticos são empregados na previsão da vazão dos drenos subterrâneos “D191”, “D192” e “D193”.

Os tipos de redes utilizadas foram:

- RNT com arquitetura *feedforward* associada a técnica de janelamento;
- RNT recorrente Elman.
- RNT FIR
- RNT Jordan

No treinamento das RNT's com arquitetura *feedforward* associada à técnica de janelamento, recorrente Elman e Jordan foi utilizado o algoritmo de regularização bayseana associado ao método leave-one-out. Enquanto que na RNA FIR, o algoritmo de treinamento utilizado é o de retropropagação temporal associado ao método de validação cruzada. No treinamento das redes neurais temporais foram considerados os seguintes parâmetros.

Taxa de aprendizado (η)	0,001
Termo de momento (constante)	0,50
Gradiente mínimo	1E-12

A função de ativação utilizada na camada oculta foi a função de ativação logística não linear e na camada de saída foi a função linear.

No processo de modelagem, com a finalidade de evitar erros mínimos locais, as RNT's com arquitetura *feedforward* associada à técnica de janelamento, recorrente Elman e Jordan tiveram seus programas reinicializados randomicamente 100 vezes para cada caso analisado, adotando-se como melhor topologia aquela que tivesse os valores de erros mais próximos das médias dos erros obtidas. Enquanto que na RNT FIR, os programas foram reinicializados randomicamente apenas 5 vezes. Este número menor de reinicializações ocorre devido o tempo de processamento do programa para a RNT FIR ser extremamente longo. Em todas as redes, tomou-se o cuidado de não considerar as previsões com erros acima de um valor considerado alto pelo analista do problema. Este cuidado evita que a média seja alterada por estas previsões ruins.

Métodos geoestatísticos baseados em variogramas são chamados normalmente de krigagem e, dentre estes, o mais usualmente empregado é o método da krigagem ordinária. A krigagem ordinária foi escolhida para estimar a

previsão, devido às séries analisadas serem estacionárias, característica necessária para utilização deste método.

Para a análise com intervalo de tempo constante foi utilizado o método de Box & Jenkins (1970), as quatro redes neurais temporais e a krigagem ordinária. Nesta etapa, considerou-se uma única série histórica para geração do modelo, ou seja, a previsão da vazão do dreno era realizada considerando como variável explicativa somente a sua própria série histórica. Este critério foi adotado para poder utilizar o método univariado de Box & Jenkins. A análise foi feita considerando apenas o conjunto de aprendizado com 455 amostras.

Na análise com intervalo de tempo variável foram utilizadas as quatro redes neurais temporais e a krigagem ordinária. Os modelos testados para as redes neurais temporais podem utilizar como variáveis explicativas: a data, o nível do reservatório à montante, a temperatura e as séries históricas de vazões dos drenos. Já a krigagem ordinária utilizou somente a vazão do dreno como variável explicativa. No treinamento com o algoritmo de regularização bayseana e de retropropagação temporal foram utilizados dois subconjuntos denominados, aprendizado (588 amostras) e teste (148 amostras). Na krigagem ordinária foram utilizados dois subconjuntos denominados, aprendizado (587 amostras) e teste (150 amostras).

4.6 Métricas Adotadas

As métricas de comparação usadas correspondem ao erro percentual médio absoluto (MAPE); raiz do erro médio quadrático (RMSE), que penaliza mais os erros maiores; e o coeficiente U de Theil, que avalia o desempenho da previsão em relação à previsão ingênua ou trivial. Previsão ingênua ou trivial significa que a estimativa do valor futuro é igual ao valor atual.

O coeficiente U de Theil analisa a qualidade de uma previsão através dos seguintes valores:

- $U > 1$, significa que o erro do modelo é maior do que da previsão ingênua;
- $U < 1$, significa que o erro do modelo é menor que da previsão ingênua.

O coeficiente U de Theil menor do que 1 já indica uma previsão melhor que a previsão ingênua; quanto mais próximo o mesmo for de zero, melhor será o resultado da previsão.

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left| \frac{alvo_j - pred_j}{alvo_j} \right| * 100 \quad (4.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (alvo_j - pred_j)^2} \quad (4.3)$$

$$UTHEIL = \frac{\sqrt{\sum_{j=1}^N (alvo_j - pred_j)^2}}{\sqrt{\sum_{j=1}^N (alvo_j - alvo_{j-1})^2}} \quad (4.4)$$

onde $alvo_j$ são os valores reais desejados na previsão, $pred_j$ representa os valores obtidos pela rede neural.

5 PREVISÃO DE SÉRIES TEMPORAIS DE VAZÃO DE DRENOS DA BARRAGEM DE FUNIL

5.1 Introdução

Existem situações, como por exemplo, em grandes obras de engenharia (portos, barragens, usinas nucleares, etc.), em que é fundamental o conhecimento das características do subsolo do terreno onde se pretende implantar o empreendimento e posteriormente o acompanhamento do funcionamento em operação.

Na fase de operação, o funcionamento da obra deve ser acompanhado para verificar se está dentro do previsto em projeto. São monitoradas diversas grandezas relevantes para a segurança do empreendimento.

O programa de monitoramento da obra é composto geralmente por uma série de instrumentações que fornecem o conhecimento adequado da operação da obra. Estas medições podem ser de temperatura, deslocamentos, vazão em drenos, etc., possibilitando a obtenção de algumas características como, por exemplo, as deformações.

As instrumentações, como por exemplo, medições de piezômetro, fornecem dados pontuais que podem ser espalhados para toda a área de interesse. Em obras de maior porte e grande responsabilidade, a quantidade de dados pode se tornar suficiente para permitir a construção de modelos de variabilidade espacial ou temporal das propriedades de interesse com base em métodos geoestatísticos ou em redes neurais artificiais.

Neste capítulo investiga-se a distribuição temporal da vazão dos drenos da barragem de Funil através do método estatístico de Box e Jenkins (1970), redes neurais temporais (RNT) e métodos geoestatísticos.

5.2 Análise com as séries com intervalo de tempo constante

A tabela 5.1 descreve as siglas utilizadas neste trabalho.

Siglas	Significado
T	Data
NA	Nível do reservatório a montante (m)
TMP	Temperatura (°C)
VZ	Vazão (l/min.)
VZ1	Vazão do dreno “D191” (l/min.)
VZ2	Vazão do dreno “D192” (l/min.)
VZ3	Vazão do dreno “D193” (l/min.)

Tabela 5.1 Siglas adotadas.

5.2.1

Previsão obtida pelo método de Box & Jenkins (1970)

Para previsão pelo modelo de Box & Jenkins utilizou-se o programa E-views v 4.0 (2001). A condição de estacionariedade da série de vazão dos drenos “D192”, “D192” e “D193” foram comprovadas pelo teste da raiz unitária (Dickey & Fuller, 1979) enquanto que o exame do comportamento das funções de autocorrelação simples e autocorrelação parcial indicaram que a seqüência histórica de valores pode ser adequadamente modelada através dos modelos autorregressivos lineares AR(1) (“D191” e “D192”) e AR(2) (“D193”). Na seleção do modelo apropriado de Box & Jenkins procurou-se capturar toda a estrutura de dependência serial presente na seqüência de dados, de tal modo que os erros não apresentassem nenhuma dependência em relação ao tempo (ruído branco). A metodologia detalhada utilizada na análise pelo método de Box & Jenkins (1970), sugerida por Gutiérrez (2003), está apresentada no apêndice A.

As equações 5.1 a 5.3 indicam os modelos obtidos para os drenos. As tabelas 6.2 a 6.4 mostram o desempenho das modelagens através das métricas estatísticas, enquanto que as figuras 5.1 a 5.3 ilustram graficamente os resultados.

$$D191=0.5731375666+0.9373114823*D191(-1) \quad (5.1)$$

$$D192=1.623486487+0.7888842178*D192(-1) \quad (5.2)$$

$$D193=0.2210363617+0.7481342115*D193(-1)+0.1965102496*D193(-2) \quad (5.3)$$

Na análise das séries com intervalo de tempo constante, foi considerado somente um conjunto de aprendizado, devido o número reduzido de amostras (455

amostras). Então as métricas de desempenho foram obtidas somente para o conjunto de aprendizado pela modelagem de Box & Jenkins (1970).

MAPE	RMSE	UTHEIL
6.31	0.72	1.0032

Tabela 5.2 Desempenho da previsão por Box & Jenkins para o dreno “D191”.

MAPE	RMSE	UTHEIL
4.74	0.43	1.0615

Tabela 5.3 Desempenho da previsão por Box & Jenkins para o dreno “D192”.

MAPE	RMSE	UTHEIL
4.70	0.39	0.9664

Tabela 5.4 Desempenho da previsão por Box & Jenkins para o dreno “D193”.




Figura 5.1 Modelagem e previsão da vazão com o modelo AR(1) para o dreno “D191”.




Figura 5.2 Modelagem e previsão da vazão com o modelo AR(1) para o dreno “D192”.




Figura 5.3 Modelagem e previsão da vazão com o modelo AR(2) para o dreno “D193”.

5.2.2

Previsão obtida pela técnica de rede neural temporal com janelamento

Para previsão pela técnica de rede neural artificial utilizou-se o programa MatLab 6.1 (2001). Para obter o melhor modelo neural foram testadas quatro redes com as entradas e saídas descritas na tabela 5.5. O primeiro modelo é função somente da própria série histórica da vazão com um atraso, o segundo considera

dois atrasos da série, o terceiro com três atrasos da série e o quarto modelo considera quatro atrasos da série.

As tabelas 5.6 a 5.8 indicam o desempenho das redes. Em todas as tabelas que apresentam os desempenhos das redes, os melhores modelos são marcados em negrito. No processo de seleção dos melhores modelos foram avaliados os erros obtidos nas fases de aprendizado e de validação, sendo considerado mais importante os erros obtidos na validação, onde a capacidade de generalização da rede é examinada.

A validação do treinamento foi feita com a técnica leave-one-out, nesta técnica apenas uma amostra é utilizada para calcular o erro de validação. Então a métrica U de Theil não foi calculada, já que precisa de uma amostra anterior. O gráfico de validação não será apresentado, pois o conjunto de validação é composto de apenas uma amostra.

As figuras 5.4 a 5.6 comparam os valores reais com os obtidos pela RNT. Em todas as figuras que comparam os valores reais com os obtidos pelas RNT, são fornecidos também os erros relativos das estimativas em relação aos dados amostrais da série temporal.

Modelos	Entradas	Saída
I	VZ_{t-1}	VZ_t
II	VZ_{t-2}, VZ_{t-1}	VZ_t
III	$VZ_{t-3}, VZ_{t-2}, VZ_{t-1}$	VZ_t
IV	$VZ_{t-4}, VZ_{t-3}, VZ_{t-2}, VZ_{t-1}$	VZ_t

Tabela 5.5 Entradas e Saídas adotadas.

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	5.65	0.71	0.9872	2.51	0.17
II	5.78	0.72	1.0038	2.53	0.17
III	5.61	0.71	0.9878	2.81	0.19
IV	5.65	0.72	0.9983	2.59	0.17

Tabela 5.6 Desempenho da previsão por RNT com janelamento para o dreno "D191".

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	3.96	0.41	1.0120	1.44	0.10
II	3.79	0.40	0.9780	1.31	0.09
III	3.74	0.39	0.9492	1.28	0.09
IV	3.75	0.38	0.9411	1.51	0.11

Tabela 5.7 Desempenho da previsão por RNT com janelamento para o dreno "D192".

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	4.78	0.30	0.9852	2.19	0.08
II	4.76	0.30	0.9738	1.74	0.07
III	4.67	0.29	0.9489	1.77	0.06
IV	4.70	0.29	0.9482	1.45	0.06

Tabela 5.8 Desempenho da previsão por RNT com janelamento para o dreno "D193".




Figura 5.4 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno "D191".




Figura 5.5 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno "D192".




Figura 5.6 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno “D193”.

5.2.3

Previsão obtida pela técnica de rede neural temporal Elman

Foram testadas quatro redes com as mesmas topologias descritas na tabela 5.5. As tabelas 5.9 a 5.11 indicam o desempenho das redes. As figuras 5.7 a 5.9 comparam os valores reais com os obtidos pela RNT.

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	5.73	0.72	0.9973	3.02	0.20
II	5.78	0.72	1.0015	2.64	0.21
III	5.75	0.73	1.0225	2.46	0.17
IV	5.72	0.73	1.0125	2.80	0.20

Tabela 5.9 Desempenho da previsão por RNT Elman para o dreno “D191”.

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	3.85	0.40	0.9897	1.46	0.10
II	3.80	0.40	0.9823	1.47	0.10
III	3.78	0.39	0.9614	1.54	0.11
IV	3.82	0.39	0.9546	1.57	0.11

Tabela 5.10 Desempenho da previsão por RNT Elman para o dreno “D192”.

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	4.79	0.30	0.9881	1.52	0.06
II	4.79	0.30	0.9802	2.22	0.09
III	4.80	0.30	0.9617	1.60	0.06
IV	4.84	0.30	0.9632	1.81	0.07

Tabela 5.11 Desempenho da previsão por RNT Elman para o dreno "D193".




Figura 5.7 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno "D191".

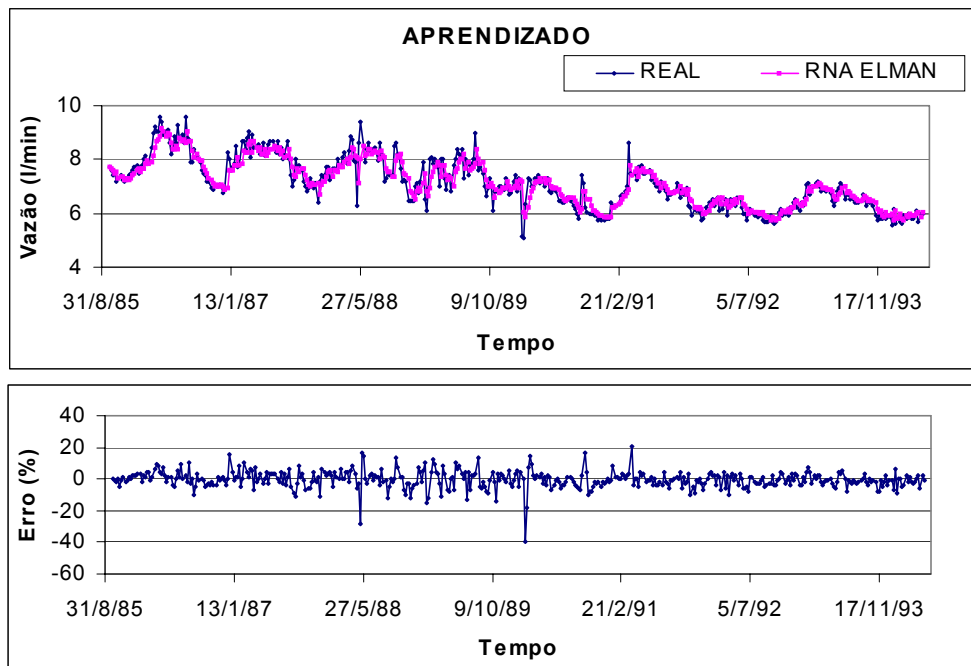


Figura 5.8 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno "D192".




Figura 5.9 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D193”.

5.2.4 Previsão obtida pela técnica de rede neural temporal FIR

Na rede FIR, os valores de entrada são considerados associados à ordem M dos filtros. Por exemplo, o modelo I descrito na tabela 5.5 possui o parâmetro de entrada vazão e filtros com memória de ordem 1 ($M=1$). Enquanto que a rede II apresenta filtros com memória 2 ($M=2$), mas com as mesmas entradas da rede I.

Na RNT FIR, para cada modelo, são avaliada seis topologias diferentes com 2, 3, 5, 8, 10 ou 15 neurônios na camada oculta. As tabelas 5.12 a 5.14 apresentam o desempenho da melhor topologia para cada modelo, indicando o número de neurônios da camada oculta. As figuras 5.10 a 5.12 comparam os valores reais com os obtidos pela RNT.

Na análise com intervalo de tempo constante para a RNT FIR, a validação do modelo com um conjunto de validação não foi realizada. A melhor previsão para cada modelo foi obtida com o menor erro observado no conjunto de aprendizado.

Modelos	Neurônios Ocultos	Aprendizado		
		MAPE	RMSE	UTHEIL
I	5	7.99	1.18	1.6313
II	15	9.53	1.47	2.0319
III	10	9.75	1.58	2.1972
IV	10	10.15	1.75	2.4317

Tabela 5.12 Desempenho da previsão por RNT FIR para o dreno "D191".

Modelos	Neurônios Ocultos	Aprendizado		
		MAPE	RMSE	UTHEIL
I	3	4.40	0.51	1.2702
II	15	4.87	0.60	1.4748
III	15	5.39	0.67	1.6516
IV	15	5.91	0.74	1.8261

Tabela 5.13 Desempenho da previsão por RNT FIR para o dreno "D192".

Modelos	Neurônios Ocultos	Aprendizado		
		MAPE	RMSE	UTHEIL
I	2	5.49	0.42	1.3518
II	15	6.05	0.50	1.6139
III	15	6.50	0.56	1.8296
IV	15	6.97	0.62	2.0242

Tabela 5.14 Desempenho da previsão por RNT FIR para o dreno "D193".




Figura 5.10 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno "D191".




Figura 5.11 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D192”.




Figura 5.12 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D193”.

5.2.5

Previsão obtida pela técnica de rede neural temporal Jordan

Na rede neural Jordan, foram testados os quatro modelos descritos na tabela 5.5. Para cada modelo, foi acrescentado ao conjunto de entradas o valor obtido pela previsão obtida da interação anterior (tabela 5.15). As tabelas 5.16 a 5.18 indicam o desempenho das redes. As figuras 5.13 a 5.15 comparam os valores reais com os obtidos pela RNT.

Modelos	Entradas	Saída
I	VZ_{t-1}, VZ_{t-1}	VZ_t
II	$VZ_{t-2}, VZ_{t-1}, VZ_{t-1}$	VZ_t
III	$VZ_{t-3}, VZ_{t-2}, VZ_{t-1}, VZ_{t-1}$	VZ_t
IV	$VZ_{t-4}, VZ_{t-3}, VZ_{t-2}, VZ_{t-1}, VZ_{t-1}$	VZ_t

Tabela 5.15 Entradas e Saídas adotadas.

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	5.74	0.73	1.0166	2.07	0.14
II	5.62	0.72	1.0015	2.04	0.15
III	5.64	0.72	0.9980	2.69	0.18
IV	5.69	0.72	1.0081	2.45	0.18

Tabela 5.16 Desempenho da previsão por RNT Jordan para o dreno "D191".

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	3.84	0.40	0.9822	1.34	0.09
II	3.78	0.39	0.9728	1.35	0.09
III	3.72	0.38	0.9470	1.51	0.10
IV	3.76	0.38	0.9439	1.36	0.09

Tabela 5.17 Desempenho da previsão por RNT Jordan para o dreno "D192".

Modelos	Aprendizado			Validação	
	MAPE	RMSE	UTHEIL	MAPE	RMSE
I	4.78	0.31	0.9888	1.89	0.07
II	4.77	0.30	0.9789	1.98	0.08
III	4.70	0.29	0.9530	1.84	0.07
IV	4.73	0.29	0.9512	1.58	0.06

Tabela 5.18 Desempenho da previsão por RNT Jordan para o dreno "D193".




Figura 5.13 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno "D191".




Figura 5.14 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno "D192".




Figura 5.15 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D193”.

5.2.6 Previsão obtida com o método geoestatístico

A condição de estacionariedade das séries de vazão foi comprovada pelo teste da raiz unitária. A série sendo estacionária permite a previsão pela técnica de krigagem ordinária. Para previsão pelo método geoestatístico utilizou-se os programas Gslib 2.0 (1997) e VARIOWIN 2.2 (1996). Os dados utilizados na geração do variograma experimental são as próprias séries históricas. As tabelas 5.19 a 5.21 mostram o desempenho das previsões utilizando krigagem ordinária. As figuras 5.16 a 5.18 mostram os variogramas experimentais escolhidos e os variogramas teóricos para os modelos esférico, exponencial e gaussiano. Os parâmetros dos variogramas teóricos são fornecidos na tabelas 5.22 a 5.24.

Como na análise pela modelagem de Box & Jenkins (1970), foi considerado somente o conjunto de aprendizado com as métricas de desempenho obtidas somente para este conjunto.

MAPE	RMSE	UTHEIL
4.02	0.50	0.6884


Tabela 5.19 Desempenho da previsão por krigagem ordinária para o dreno “D191”.

MAPE	RMSE	UTHEIL
3.02	0.31	0.7712


Tabela 5.20 Desempenho da previsão por krigagem ordinária para o dreno "D192".

MAPE	RMSE	UTHEIL
3.73	0.24	0.7792


Tabela 5.21 Desempenho da previsão por krigagem ordinária para o dreno "D193".



(a)




(b)




(c)


Figura 5.16 Variogramas experimentais e teóricos para o dreno "D191": (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.



(a)




(b)




(c)


Figura 5.17 Variogramas experimentais e teóricos para o dreno “D192”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.



(a)



(b)



(c)

Figura 5.18 Variogramas experimental e teórico para o dreno “D193”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.

Nas figuras 5.16 a 5.18 os variogramas teóricos esférico e gaussiano se adaptam melhor aos variogramas experimentais. O modelo esférico foi escolhido por ser um modelo mais adequado a problemas em que os dados apresentam um comportamento mais irregular. O *lag* de 14 dias foi utilizado para geração dos variogramas.

PARÂMETROS DO MODELO	NUGGET	RANGE	SILL	ANISOTROPIA
	0.00	150.0	0.6	1.00

Tabela 5.22 Valores dos parâmetros do modelo teórico esférico para o dreno "D191".

PARÂMETROS DO MODELO	NUGGET	RANGE	SILL	ANISOTROPIA
	0.00	200.00	0.65	1.00

Tabela 5.23 Valores dos parâmetros do modelo teórico esférico para o dreno "D192".

PARÂMETROS DO MODELO	NUGGET	RANGE	SILL	ANISOTROPIA
	0.00	200.00	0.35	1.00

Tabela 5.24 Valores dos parâmetros do modelo teórico esférico para o dreno "D193".

As figuras 5.19 e 5.21 comparam os valores reais com os obtidos pela krigagem ordinária, para as séries.




Figura 5.19 Modelagem e previsão da vazão com krigagem ordinária para o dreno "D191".




Figura 5.20 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D192”.




Figura 5.21 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D193”.

5.2.7 Análise dos Resultados

As tabelas 5.25 a 5.27 apresentam os melhores modelos obtidos pelo método de Box & Jenkins (1970), pelas RNT's e pelo método geostatístico. Em relação aos resultados, pode-se observar que:

- Observando os gráficos de erros, nota-se que os erros ficaram em um intervalo de $\pm 20\%$. Apresentado a ordem dos erros dos dados mais irregulares (outliers) das séries semelhantes. Isto indica que para todos os métodos a precisão dos resultados afetada pela presença de ruídos introduzidos pela súbita variação das séries temporais;
- O comportamento temporal das séries de vazão foi captado pela RNT com janelamento indicando que os resultados com outras RNT's deveriam apresentar previsões similares. As RNT's com janelamento, Elman e Jordan apresentaram resultados similares;
- A utilização do mesmo algoritmo de treinamento para as RNT's com janelamento, Elman e Jordan, o algoritmo de regularização bayseana associado ao método leave-one-out, permitiu que se comparem apenas os tipos de RNT's. Não se considera a influência do algoritmo de treinamento, que será igual para todas as redes;
- A RNT FIR apresentou os piores resultados. O algoritmo de treinamento retropropagação temporal associado ao método de validação cruzada parece não ter conseguido capturar o melhor modelo;
- O modelo de Box & Jenkins apresentou desempenho levemente inferior para os drenos, com exceção do observado para o dreno "D193";
- O modelo AR(1) para o dreno "D191" foi confirmado para a maioria das RNT's;
- Observa-se que em quase todas as RNT's, o coeficiente U de Theil é menor do que 1, evidenciando que as previsões obtidas têm melhor desempenho do que uma previsão ingênua;
- Os valores da métrica U de Theil para o método geostatístico bem menores que os das RNT's se justifica pelo *lag* adotado na geração dos variogramas ser de 14 dias. Os valores de U de Theil das RNT's janelamento, Elman e Jordan para intervalo de tempo quinzenal

apresentados nas tabelas 5.28 a 5.30 são equivalentes aos obtidos pelo método geoestatístico já que apresentam o mesmo intervalo de tempo;

Métodos	Modelos	Aprendizado			Validação	
		MAPE	RMSE	UTHEIL	MAPE	RMSE
Box & Jenkins	AR(1)	6.31	0.72	1.0032		
RNT com janelamento	I	5.65	0.71	0.9872	2.51	0.17
RNT Elman	I	5.73	0.72	0.9973	3.02	0.20
RNT FIR	I	7.99	1.18	1.6313		
RNT Jordan	III	5.64	0.72	0.9980	2.69	0.18
Geoestatística		4.02	0.50	0.6884		

Tabela 5.25 Desempenho das previsões para o dreno "D191".

Métodos	Modelos	Aprendizado			Validação	
		MAPE	RMSE	UTHEIL	MAPE	RMSE
Box & Jenkins	AR(1)	4.74	0.43	1.0615		
RNT com janelamento	III	3.74	0.39	0.9492	1.28	0.09
RNT Elman	IV	3.82	0.39	0.9546	1.57	0.11
RNT FIR	I	4.40	0.51	1.2702		
RNT Jordan	IV	3.76	0.38	0.9439	1.36	0.09
Geoestatística		3.02	0.31	0.7712		

Tabela 5.26 Desempenho das previsões para o dreno "D192".

Métodos	Modelos	Aprendizado			Validação	
		MAPE	RMSE	UTHEIL	MAPE	RMSE
Box & Jenkins	AR(2)	4.70	0.39	0.9664		
RNT com janelamento	IV	4.70	0.29	0.9482	1.45	0.06
RNT Elman	III	4.80	0.30	0.9617	1.60	0.06
RNT FIR	I	5.49	0.42	1.3518		
RNT Jordan	IV	4.73	0.29	0.9512	1.58	0.06
Geoestatística		3.73	0.24	0.7792		

Tabela 5.27 Desempenho das previsões para o dreno "D193".

- Para verificar a influência do intervalo de tempo na previsão foram feitas análises com intervalo de tempo quinzenal e mensal. O dreno D-191 foi escolhido por apresentar erros maiores. A tabela 5.28 a 5.31 apresentam os desempenhos das previsões. Para os intervalos de tempo quinzenal e mensal foram considerados os melhores modelos da análise semanal. Analisando o desempenho das previsões, o aumento do intervalo de tempo melhorou o U-Theil para todas as redes. Esta

melhoria justifica-se pela definição da métrica U-theil que analisa se a previsão é melhor que a previsão ingênua. Com o intervalo de tempo maior, os valores de vazão consecutivos devem apresentar uma diferença mais acentuada, enquanto que na métrica MAPE houve um desempenho ligeiramente inferior, indicando que o intervalo de tempo semanal apresenta as melhores previsões. Os gráficos para os intervalos de tempo quinzenal e mensal são apresentados no anexo B.

Métodos	Modelos	Aprendizado			Validação	
		MAPE	RMSE	UTHEIL	MAPE	RMSE
Semanal	I	5.65	0.71	0.9872	2.51	0.17
Quinzenal	I	5.81	0.71	0.6613	2.14	0.14
Mensal	I	6.46	0.75	0.4376	2.45	0.16

Tabela 5.28 Desempenho das previsões para o dreno "D191" com a RNT com janelamento.

Métodos	Modelos	Aprendizado			Validação	
		MAPE	RMSE	UTHEIL	MAPE	RMSE
Semanal	I	5.73	0.72	0.9973	3.02	0.20
Quinzenal	I	5.89	0.75	0.7022	2.61	0.18
Mensal	I	6.74	0.80	0.4705	2.77	0.19

Tabela 5.29 Desempenho das previsões para o dreno "D191" com a RNT Elman.

Métodos	Modelos	Neurônios	Aprendizado		
			MAPE	RMSE	UTHEIL
Semanal	I	5	7.99	1.18	1.6313
Quinzenal	I	15	10.34	1.54	1.4379
Mensal	I	15	20.49	2.45	1.4423

Tabela 5.30 Desempenho das previsões para o dreno "D191" com a RNT FIR.

Métodos	Modelos	Aprendizado			Validação	
		MAPE	RMSE	UTHEIL	MAPE	RMSE
Semanal	III	5.64	0.72	0.9980	2.69	0.18
Quinzenal	III	5.92	0.73	0.6826	2.29	0.17
Mensal	III	5.27	0.66	0.4278	2.84	0.20

Tabela 5.31 Desempenho das previsões para o dreno "D191" com a RNT Jordan.

5.3

Análise com as séries com intervalo de tempo variável

5.3.1

Previsão obtida pela técnica de rede neural temporal com janelamento

Para obter o melhor modelo neural foram testadas oito redes com as entradas e saídas descritas nas tabelas 5.32 a 5.34. Os modelos neurais são função das próprias séries históricas de vazão, do nível d'água do reservatório e da temperatura. Devido as amostras não estarem todas espaçadas com frequência semanal, as datas das medições foram consideradas como entrada. As tabelas 5.35 a 5.37 indicam o desempenho das redes. As figuras 5.22 A 5.24 comparam os valores reais com os obtidos pela RNT.

Modelos	Entradas	Saída
I	$T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$
II	$T_{t-2}, NA_{t-2}, TMP_{t-2}, VZ1_{t-2}, T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$
III	$T_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$
IV	$T_{t-2}, VZ1_{t-2}, T_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$
V	$T_{t-1}, NA_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$
VI	$T_{t-2}, NA_{t-2}, VZ1_{t-2}, T_{t-1}, NA_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$
VII	$T_{t-1}, VZ2_{t-1}, VZ3_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$
VIII	$T_{t-2}, VZ2_{t-2}, VZ3_{t-2}, VZ1_{t-2}, T_{t-1}, VZ2_{t-1}, VZ3_{t-1}, VZ1_{t-1}, T_t$	$VZ1_t$

Tabela 5.32 Entradas e Saídas adotadas para o dreno "D191".

Modelos	Entradas	Saída
I	$T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$
II	$T_{t-2}, NA_{t-2}, TMP_{t-2}, VZ2_{t-2}, T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$
III	$T_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$
IV	$T_{t-2}, VZ2_{t-2}, T_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$
V	$T_{t-1}, NA_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$
VI	$T_{t-2}, NA_{t-2}, VZ2_{t-2}, T_{t-1}, NA_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$
VII	$T_{t-1}, VZ1_{t-1}, VZ3_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$
VIII	$T_{t-2}, VZ1_{t-2}, VZ3_{t-2}, VZ2_{t-2}, T_{t-1}, VZ1_{t-1}, VZ3_{t-1}, VZ2_{t-1}, T_t$	$VZ2_t$

Tabela 5.33 Entradas e Saídas adotadas para o dreno "D192".

Modelos	Entradas	Saída
I	$T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$
II	$T_{t-2}, NA_{t-2}, TMP_{t-2}, VZ3_{t-2}, T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$
III	$T_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$
IV	$T_{t-2}, VZ3_{t-2}, T_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$
V	$T_{t-1}, NA_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$
VI	$T_{t-2}, NA_{t-2}, VZ3_{t-2}, T_{t-1}, NA_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$
VII	$T_{t-1}, VZ1_{t-1}, VZ2_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$
VIII	$T_{t-2}, VZ1_{t-2}, VZ2_{t-2}, VZ3_{t-2}, T_{t-1}, VZ1_{t-1}, VZ2_{t-1}, VZ3_{t-1}, T_t$	$VZ3_t$

Tabela 5.34 Entradas e Saídas adotadas para o dreno "D193".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	5.81	0.72	0.9180	2.85	0.19	6.21	0.56	1.0770
II	5.84	0.71	0.9117	3.16	0.22	6.26	0.55	1.0678
III	5.98	0.77	0.9783	2.90	0.21	6.51	0.65	1.2578
IV	6.05	0.76	0.9738	2.66	0.19	6.56	0.62	1.2036
V	6.01	0.76	0.9646	3.06	0.22	6.99	0.66	1.2722
VI	5.88	0.74	0.9445	2.43	0.16	6.55	0.59	1.1401
VII	5.91	0.77	0.9763	2.48	0.16	6.41	0.65	1.2566
VIII	6.08	0.77	0.9817	2.43	0.16	6.63	0.61	1.1806

Tabela 5.35 Desempenho da previsão por RNT com janelamento para o dreno "D191".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	3.88	0.39	0.9666	1.64	0.11	5.58	0.56	0.9742
II	3.67	0.37	0.9136	1.60	0.11	5.18	0.49	0.8543
III	3.89	0.39	0.9770	1.63	0.11	5.57	0.57	0.9844
IV	3.64	0.37	0.9160	1.47	0.10	5.25	0.51	0.8879
V	3.87	0.39	0.9672	1.43	0.10	5.55	0.56	0.9717
VI	3.65	0.37	0.9127	1.30	0.09	5.16	0.50	0.8637
VII	3.74	0.36	0.9009	1.71	0.11	5.35	0.50	0.8705
VIII	3.62	0.35	0.8804	1.59	0.11	5.14	0.49	0.8446

Tabela 5.36 Desempenho da previsão por RNT com janelamento para o dreno "D192".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	4.84	0.30	0.9613	1.65	0.06	6.18	0.29	1.0126
II	4.55	0.28	0.9000	1.56	0.05	6.21	0.29	0.9990
III	4.88	0.31	0.9731	1.82	0.06	5.93	0.28	0.9804
IV	4.69	0.29	0.9184	1.86	0.07	5.80	0.28	0.9649
V	4.88	0.30	0.9626	1.93	0.07	6.04	0.28	0.9932
VI	4.59	0.28	0.9050	1.63	0.06	5.99	0.28	0.9830
VII	4.82	0.29	0.9296	2.09	0.07	6.37	0.29	1.0072
VIII	4.59	0.28	0.8854	2.18	0.08	5.92	0.28	0.9691

Tabela 5.37 Desempenho da previsão por RNT com janelamento para o dreno "D193".




Figura 5.22 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno "D191".




Figura 5.23 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno "D192".




Figura 5.24 Modelagem e previsão da vazão com o modelo de RNT com janelamento para o dreno "D193".

5.3.2

Previsão obtida pela técnica de rede neural temporal Elman

De maneira análoga à empregada para previsão das vazões pela técnica de rede neural com janelamento, foram utilizados os oito modelos das tabelas 5.32 a 5.34. As tabelas 5.38 a 5.40 indicam o desempenho das redes. As figuras 5.25 a 5.27 comparam os valores reais com os obtidos pela RNT.

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	6.00	0.74	0.9419	2.84	0.20	6.43	0.57	1.1032
II	6.04	0.74	0.9431	3.02	0.21	6.47	0.57	1.0976
III	5.94	0.77	0.9770	2.36	0.15	6.40	0.64	1.2422
IV	6.11	0.77	0.9824	2.68	0.17	6.63	0.63	1.2189
V	6.05	0.76	0.9702	2.48	0.16	7.00	0.65	1.2583
VI	5.93	0.75	0.9599	3.15	0.21	6.62	0.60	1.1550
VII	5.92	0.77	0.9835	2.85	0.18	6.32	0.64	1.2360
VIII	6.13	0.78	0.9919	3.02	0.19	6.72	0.62	1.2003

Tabela 5.38 Desempenho da previsão por RNT Elman para o dreno "D191".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	3.91	0.39	0.9680	1.38	0.09	5.67	0.56	0.9684
II	3.71	0.37	0.9235	1.65	0.11	5.22	0.49	0.8432
III	3.90	0.39	0.9760	1.48	0.10	5.69	0.57	0.9827
IV	3.68	0.37	0.9224	1.44	0.10	5.33	0.50	0.8740
V	3.91	0.39	0.9693	1.46	0.10	5.64	0.56	0.9659
VI	3.70	0.37	0.9230	1.47	0.10	5.21	0.49	0.8501
VII	3.81	0.37	0.9164	1.93	0.13	5.43	0.50	0.8697
VIII	3.70	0.36	0.8968	1.35	0.09	5.25	0.48	0.8336

Tabela 5.39 Desempenho da previsão por RNT Elman para o dreno "D192".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	4.90	0.30	0.9621	1.97	0.07	6.13	0.29	0.9984
II	4.58	0.29	0.9075	1.70	0.06	6.08	0.28	0.9901
III	4.90	0.31	0.9731	1.78	0.06	5.94	0.28	0.9759
IV	4.71	0.29	0.9214	2.12	0.07	5.81	0.28	0.9671
V	4.92	0.30	0.9628	1.92	0.07	6.00	0.28	0.9870
VI	4.62	0.29	0.9100	1.57	0.06	5.92	0.28	0.9793
VII	4.86	0.29	0.9316	1.81	0.06	6.29	0.28	0.9933
VIII	4.64	0.28	0.8993	1.81	0.07	5.85	0.28	0.9691

Tabela 5.40 Desempenho da previsão por RNT Elman para o dreno "D193".




Figura 5.25 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno "D191".




Figura 5.26 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno “D192”.




Figura 5.27 Modelagem e previsão da vazão com o modelo de RNT Elman para o dreno "D193".

5.3.3

Previsão obtida pela técnica de rede neural temporal FIR

Nas redes FIR, os modelos descritos nas tabelas 5.32 a 5.34 foram utilizados com filtros FIR de ordem um ($M=1$) para os modelos I, III, V, VII. Para os quatro modelos restantes a ordem foi $M=2$. As tabelas 5.41 a 5.43 indicam o desempenho das redes. As figuras 5.28 a 5.30 comparam os valores reais com os obtidos pela RNT.

Modelos	Neurônios Ocultos	Aprendizado			Teste		
		MAPE	RMSE	UTHEIL	MAPE	RMSE	UTHEIL
I	10	10.22	1.19	1.5243	11.89	1.04	2.0199
II	5	11.36	1.41	1.8005	12.64	1.12	2.1699
III	10	9.09	1.23	1.5677	9.14	0.87	1.6829
IV	5	10.06	1.41	1.8051	10.57	1.00	1.9366
V	10	10.22	1.24	1.5855	13.04	1.05	2.0367
VI	10	11.74	1.44	1.8435	14.05	1.19	2.2963
VII	15	9.93	1.26	1.6033	10.37	0.91	1.7675
VIII	5	10.74	1.46	1.8604	10.64	1.01	1.9586

Tabela 5.41 Desempenho da previsão por RNT FIR para o dreno "D191".

Modelos	Neurônios Ocultos	Aprendizado			Teste		
		MAPE	RMSE	UTHEIL	MAPE	RMSE	UTHEIL
I	15	4.47	0.49	1.2160	5.98	0.56	0.9670
II	15	4.94	0.56	1.4080	6.71	0.63	1.1009
III	15	4.05	0.46	1.1426	5.84	0.55	0.9596
IV	3	4.59	0.54	1.3413	7.30	0.66	1.1402
V	8	4.38	0.48	1.2003	6.18	0.57	0.9886
VI	15	4.79	0.55	1.3794	6.99	0.65	1.1351
VII	10	4.47	0.47	1.1798	6.68	0.57	0.9944
VIII	10	4.63	0.53	1.3245	7.34	0.65	1.1309

Tabela 5.42 Desempenho da previsão por RNT FIR para o dreno "D192".

Modelos	Neurônios Ocultos	Aprendizado			Teste		
		MAPE	RMSE	UTHEIL	MAPE	RMSE	UTHEIL
I	15	5.32	0.40	1.2588	7.43	0.34	1.1822
II	15	5.79	0.47	1.4811	7.96	0.35	1.2207
III	15	5.22	0.39	1.2414	6.92	0.33	1.1499
IV	15	5.66	0.45	1.4462	7.76	0.35	1.2212
V	15	5.27	0.39	1.2503	7.20	0.34	1.1754
VI	15	5.57	0.46	1.4598	7.69	0.34	1.1991
VII	15	5.38	0.39	1.2388	7.48	0.34	1.1853
VIII	10	5.95	0.47	1.4909	8.54	0.37	1.2956

Tabela 5.43 Desempenho da previsão por RNT FIR para o dreno "D193".




Figura 5.28 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno "D191".




Figura 5.29 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno "D192".




Figura 5.30 Modelagem e previsão da vazão com o modelo de RNT FIR para o dreno “D193”.

5.3.4 Previsão obtida pela técnica de rede neural temporal Jordan

Na rede neural Jordan, foram testados os oito modelos descritos nas tabelas 5.32 a 5.34. Para cada modelo, foi acrescentado ao conjunto de entradas o valor

obtido pela previsão obtida da interação anterior (tabelas 5.44 a 5.46). As tabelas 5.47 a 5.49 indicam o desempenho das redes. As figuras 5.31 a 5.33 comparam os valores reais com os obtidos pela RNT.

Modelos	Entradas	Saída
I	$T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$
II	$T_{t-2}, NA_{t-2}, TMP_{t-2}, VZ1_{t-2}, T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$
III	$T_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$
IV	$T_{t-2}, VZ1_{t-2}, T_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$
V	$T_{t-1}, NA_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$
VI	$T_{t-2}, NA_{t-2}, VZ1_{t-2}, T_{t-1}, NA_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$
VII	$T_{t-1}, VZ2_{t-1}, VZ3_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$
VIII	$T_{t-2}, VZ2_{t-2}, VZ3_{t-2}, VZ1_{t-2}, T_{t-1}, VZ2_{t-1}, VZ3_{t-1}, VZ1_{t-1}, T_t, VZ1_{t-1}$	$VZ1_t$

Tabela 5.44 Entradas e Saídas adotadas para a rede neural temporal Jordan para o dreno "D191".

Modelos	Entradas	Saída
I	$T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$
II	$T_{t-2}, NA_{t-2}, TMP_{t-2}, VZ2_{t-2}, T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$
III	$T_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$
IV	$T_{t-2}, VZ2_{t-2}, T_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$
V	$T_{t-1}, NA_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$
VI	$T_{t-2}, NA_{t-2}, VZ2_{t-2}, T_{t-1}, NA_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$
VII	$T_{t-1}, VZ1_{t-1}, VZ3_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$
VIII	$T_{t-2}, VZ1_{t-2}, VZ3_{t-2}, VZ2_{t-2}, T_{t-1}, VZ1_{t-1}, VZ3_{t-1}, VZ2_{t-1}, T_t, VZ2_{t-1}$	$VZ2_t$

Tabela 5.45 Entradas e Saídas adotadas para a rede neural temporal Jordan para o dreno "D192".

Modelos	Entradas	Saída
I	$T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$
II	$T_{t-2}, NA_{t-2}, TMP_{t-2}, VZ3_{t-2}, T_{t-1}, NA_{t-1}, TMP_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$
III	$T_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$
IV	$T_{t-2}, VZ3_{t-2}, T_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$
V	$T_{t-1}, NA_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$
VI	$T_{t-2}, NA_{t-2}, VZ3_{t-2}, T_{t-1}, NA_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$
VII	$T_{t-1}, VZ1_{t-1}, VZ2_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$
VIII	$T_{t-2}, VZ1_{t-2}, VZ2_{t-2}, VZ3_{t-2}, T_{t-1}, VZ1_{t-1}, VZ2_{t-1}, VZ3_{t-1}, T_t, VZ3_{t-1}$	$VZ3_t$

Tabela 5.46 Entradas e Saídas adotadas para a rede neural temporal Jordan para o dreno "D193".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	5.88	0.73	0.9294	3.26	0.20	6.31	0.56	1.0893
II	5.97	0.73	0.9326	2.81	0.18	6.43	0.56	1.0933
III	5.95	0.77	0.9789	2.71	0.19	6.46	0.65	1.2546
IV	6.09	0.77	0.9804	2.62	0.18	6.61	0.62	1.2105
V	6.01	0.76	0.9679	2.92	0.19	6.98	0.66	1.2680
VI	5.90	0.74	0.9493	2.75	0.19	6.58	0.59	1.1450
VII	5.92	0.77	0.9804	2.50	0.17	6.42	0.65	1.2544
VIII	6.06	0.77	0.9817	2.47	0.16	6.63	0.61	1.1832

Tabela 5.47 Desempenho da previsão por RNT Jordan temporal para o dreno "D191".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	3.88	0.39	0.9661	1.67	0.11	5.61	0.56	0.9739
II	3.68	0.37	0.9161	1.24	0.08	5.20	0.49	0.8519
III	3.89	0.39	0.9749	1.41	0.09	5.60	0.57	0.9853
IV	3.65	0.37	0.9179	1.38	0.10	5.26	0.51	0.8841
V	3.88	0.39	0.9658	1.45	0.10	5.59	0.56	0.9719
VI	3.65	0.37	0.9128	1.49	0.10	5.17	0.50	0.8609
VII	3.75	0.36	0.9031	1.62	0.11	5.37	0.50	0.8697
VIII	3.64	0.35	0.8856	1.60	0.11	5.16	0.48	0.8401

Tabela 5.48 Desempenho da previsão por RNT Jordan para o dreno "D192".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	4.86	0.30	0.9621	1.63	0.06	6.16	0.29	1.0086
II	4.57	0.28	0.9029	1.76	0.06	6.19	0.29	0.9970
III	4.88	0.31	0.9769	1.56	0.05	5.88	0.28	0.9755
IV	4.69	0.29	0.9190	1.81	0.06	5.79	0.28	0.9652
V	4.89	0.30	0.9640	1.90	0.06	6.01	0.28	0.9909
VI	4.59	0.28	0.9039	1.79	0.06	5.98	0.28	0.9821
VII	4.83	0.29	0.9287	2.06	0.08	6.35	0.29	1.0039
VIII	4.60	0.28	0.8866	1.81	0.07	5.92	0.28	0.9688

Tabela 5.49 Desempenho da previsão por RNT Jordan para o dreno "D193".




Figura 5.31 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno "D191".




Figura 5.32 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno “D192”.




Figura 5.33 Modelagem e previsão da vazão com o modelo de RNT Jordan para o dreno "D193".

5.3.5 Previsão obtida com o método geoestatístico

Utiliza-se a mesma metodologia empregada na análise das séries com intervalo de tempo constante. As tabelas 5.50 a 5.52 mostram o desempenho das

previsões utilizando krigagem ordinária. As figuras 5.34 a 5.36 mostram os variogramas experimentais escolhidos e os variogramas teóricos para os modelos esférico, exponencial e gaussiano. Os parâmetros dos variogramas teóricos são fornecidos na tabelas 5.53 a 5.55.






Figura 5.34 Variogramas experimental e teórico para o dreno “D191”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.

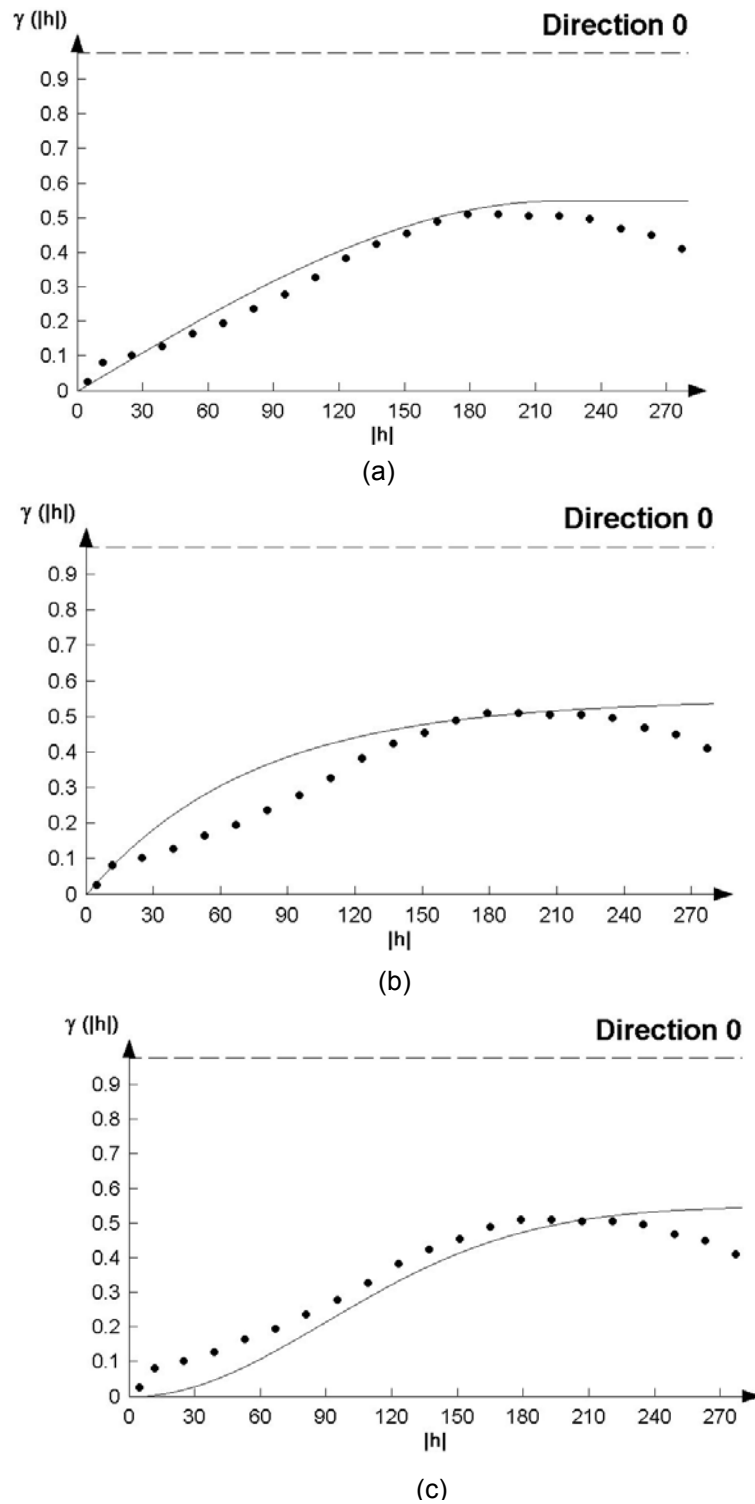


Figura 5.35 Variogramas experimental e teórico para o dreno “D192”: (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.






Figura 5.36 Variogramas experimentais e teórico para o dreno "D193": (a) modelo esférico, (b) modelo exponencial e (c) modelo gaussiano.

Nas figuras 5.34 a 5.36 os variogramas teóricos esférico se adaptam melhor aos variogramas experimentais. Novamente, o *lag* de 14 dias foi utilizado para geração dos variogramas.

Aprendizado			Teste		
MAPE	RMSE	UTHEIL	MAPE	RMSE	UTHEIL
4.43	0.56	0.7117	3.79	0.34	0.6562

Tabela 5.50 Desempenho da previsão por krigagem ordinária para o dreno "D191".

Aprendizado			Teste		
MAPE	RMSE	UTHEIL	MAPE	RMSE	UTHEIL
3.49	0.34	0.8527	4.48	0.46	0.7997

Tabela 5.51 Desempenho da previsão por krigagem ordinária para o dreno "D192".

Aprendizado			Teste		
MAPE	RMSE	UTHEIL	MAPE	RMSE	UTHEIL
4.00	0.25	0.7981	4.52	0.23	0.8125

Tabela 5.52 Desempenho da previsão por krigagem ordinária para o dreno "D193".

PARÂMETROS DO MODELO	NUGGET	RANGE	SILL	ANISOTROPIA
	0.00	480.00	2.20	1.00

Tabela 5.53 Valores dos parâmetros do modelo teórico esférico para o dreno "D191".

PARÂMETROS DO MODELO	NUGGET	RANGE	SILL	ANISOTROPIA
	0.00	220.00	0.55	1.00

Tabela 5.54 Valores dos parâmetros do modelo teórico esférico para o dreno "D192".

PARÂMETROS DO MODELO	NUGGET	RANGE	SILL	ANISOTROPIA
	0.00	240.00	0.25	1.00

Tabela 5.55 Valores dos parâmetros do modelo teórico esférico para o dreno "D193".

As figuras 5.37 e 5.39 comparam os valores reais com os obtidos pela krigagem ordinária, para as séries.




Figura 5.37 Modelagem e previsão da vazão com krigagem ordinária para o dreno “D191”.




Figura 5.38 Modelagem e previsão da vazão com krigagem ordinária para o dreno "D192".




Figura 5.39 Modelagem e previsão da vazão com krigagem ordinária para o dreno "D193".

5.3.6

Geração do intervalo de confiança utilizando os resultados da previsão obtida com o método geoestatístico

As figuras 5.40 a 5.42 mostram o histograma dos erros da previsão do modelo geoestatístico. Analisando-se os histogramas observa-se que a distribuição do erro não é gaussiana, mas a distribuição do erro é contínua e unimodal. Podendo-se utilizar a desigualdade proposta por Vysochanskii-Petunin em 1980 para determinação do intervalo que compreenda 95% de probabilidade. As equações 5.4 a 5.6 mostram os valores obtidos para os intervalos de confiança para os drenos “D191”, “D192” e “D193” respectivamente. As figuras 5.43 a 5.45 mostram as previsões e os intervalos de confiança. A tabela 5.56 apresenta a porcentagem de acerto dos intervalos de confiança, sendo todas superiores a probabilidade de 95%.




Figura 5.40 Histograma dos erros da previsão do modelo geoestatístico do dreno “D191”.




Figura 5.41 Histograma dos erros da previsão do modelo geoestatístico do dreno “D192”.




Figura 5.42 Histograma dos erros da previsão do modelo geoestatístico do dreno “D193”.

$$\tilde{\sigma}_K = 0.52$$

$$\left[\hat{V}(x_0) - 3\tilde{\sigma}_K, \hat{V}(x_0) + 3\tilde{\sigma}_K \right] \tag{5.4}$$

$$\left[\hat{V}(x_0) - 1.56, \hat{V}(x_0) + 1.56 \right]$$

$$\tilde{\sigma}_K = 0.35$$

$$\left[\hat{V}(x_0) - 3\tilde{\sigma}_K, \hat{V}(x_0) + 3\tilde{\sigma}_K \right] \tag{5.5}$$

$$\left[\hat{V}(x_0) - 1.05, \hat{V}(x_0) + 1.05 \right]$$

$$\tilde{\sigma}_K = 0.25$$

$$\left[\hat{V}(x_0) - 3\tilde{\sigma}_K, \hat{V}(x_0) + 3\tilde{\sigma}_K \right] \tag{5.6}$$

$$\left[\hat{V}(x_0) - 0.75, \hat{V}(x_0) + 0.75 \right]$$




Figura 5.43 Intervalo de Confiança gerado pela previsão do método geoestatístico para o dreno “D191”.




Figura 5.44 Intervalo de Confiança gerado pela previsão do método geoestatístico para o dreno "D192".




Figura 5.45 Intervalo de Confiança gerado pela previsão do método geoestatístico para o dreno "D193".

Drenos	Aprendizado	Teste
“D191”	98%	99%
“D192”	99%	97%
“D193”	98%	97%

Tabela 5.56 Desempenho do intervalo de confiança gerado pela previsão do método geoestatístico.

5.3.7

Geração do intervalo de confiança através dos erros de saída da rede utilizando os resultados da previsão obtida com a técnica de RNT com janelamento

Utiliza-se a técnica proposta por Alves da Silva & Moulin (2000) para geração de intervalos de confiança. Esta técnica foi escolhida por não ser necessário que a distribuição de erros da previsão seja gaussiana. Para estimar o intervalo de confiança, foi acrescentada uma saída do erro da previsão da vazão no melhor modelo da RNT com janelamento.

As figuras 5.46 a 5.48 mostram as previsões e os intervalos de confiança. A tabela 5.57 apresenta a porcentagem de acerto dos intervalos de confiança, já que nesta técnica o grau de confiança não é estabelecido antecipadamente. Deve ser calculado verificando o sucesso da estimação do intervalo de confiança para o conjunto de teste.




Figura 5.46 Intervalo de Confiança gerado pela técnica de saída do erro com a previsão obtida pela RNT com janelamento para o dreno “D191”.




Figura 5.47 Intervalo de Confiança gerado pela técnica de saída do erro com a previsão obtida pela RNT com janelamento para o dreno "D192".




Figura 5.48 Intervalo de Confiança gerado pela técnica de saída do erro com a previsão obtida pela RNT com janelamento para o dreno "D193".

Drenos	Aprendizado	Teste
“D191”	100%	100%
“D192”	100%	99%
“D193”	100%	100%

Tabela 5.57 Desempenho do intervalo de confiança gerado pela técnica do erro de saída da rede utilizando os resultados da previsão obtida com a técnica de RNT com janelamento.

5.3.8

Geração do intervalo de confiança através de *re-amostragem dos erros* utilizando os resultados da previsão obtida com a RNT com janelamento

A técnica de *re-amostragem dos erros* também foi escolhida por não ser necessário que a distribuição de erros da previsão seja gaussiana. O conjunto de treinamento foi utilizado como conjunto de *re-amostragem dos erros*. O modelo da RNT com janelamento é o mesmo utilizado na técnica de saída de erro. A técnica foi utilizada para determinação de intervalo que compreenda 95% de probabilidade.

As figuras 5.49 a 5.51 mostram as previsões e os intervalos de confiança. A tabela 5.58 apresenta a porcentagem de acerto dos intervalos de confiança.




Figura 5.49 Intervalo de Confiança gerado pela técnica de *re-amostragem dos erros* obtida com a previsão da RNT com janelamento para o dreno “D191”.




Figura 5.50 Intervalo de Confiança gerado pela técnica de *re-amostragem dos erros* obtida com a previsão da RNT com janelamento para o dreno "D192".




Figura 5.51 Intervalo de Confiança gerado pela técnica de *re-amostragem dos erros* obtida com a previsão da RNT com janelamento para o dreno "D193".

Drenos	Aprendizado	Teste
“D191”	87%	91%
“D192”	93%	93%
“D193”	84%	93%

Tabela 5.58 Desempenho do intervalo de confiança gerado pela técnica de *re-amostragem dos erros* utilizando os resultados da previsão obtida com a técnica de RNT com janelamento.

5.3.9 Análise dos Resultados

As tabelas 5.59 a 5.61 apresentam os melhores modelos obtidos para as análises com intervalo de tempo variável. Em relação aos resultados, as conclusões citadas no item 5.3.7 são válidas para estes modelos. Pode-se observar ainda que:

- A determinação de quais variáveis de entrada são importantes para a previsão é feita analisando os erros de cada modelo neural testado. Para o dreno “D191” as variáveis explicativas nível do reservatório e temperatura foram importantes, já que o modelos neurais apresentaram menores erros, para as RNT’s com janelamento e Jordan. Já para o dreno “D192” as variáveis explicativas mais importantes forma as vazões dos drenos “D191” e “D193”. Enquanto que para o dreno “D193” somente a série de vazão foi importante para a geração dos modelos neurais;
- Apesar de o grau de correlação da série de vazão do dreno “D191” com a série de temperatura ser pequeno, o melhor modelo para as RNT com “janelamento” e Jordan consideram a série de temperatura como uma variável explicativa. Deve-se lembrar que as redes neurais são utilizadas para análise de problemas não lineares, então a rede pode capturar alguma correlação que não pode ser observada através do grau de correlação;
- Observa-se que em quase todas as RNT’s, o coeficiente U de Theil foi melhor para as análises com intervalo de tempo variável quando comparadas com as obtidas com intervalo de tempo constante;

- Observando os gráficos de erros, nota-se que os erros ficaram em um intervalo de $\pm 20\%$, com exceção da RNT FIR que apresenta uma variação maior.
- Vale ressaltar que o conjunto de teste selecionado apresentou várias amostras com uma frequência de tempo diferente que o intervalo regular semanal, acarretando que o teste de generalização apresentou erros relativamente maiores que nas duas fases prévias;

Métodos	Modelo	Aprendizado			Validação		Teste		
		MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
RNT com janelamento	I	5.81	0.72	0.9180	2.85	0.19	6.21	0.56	1.0770
RNT Elman	VII	5.92	0.77	0.9835	2.85	0.18	6.32	0.64	1.2360
RNT FIR	III	9.09	1.23	1.5677			9.14	0.87	1.6829
RNT Jordan	I	5.88	0.73	0.9294	3.26	0.20	6.31	0.56	1.0893
Geoestatística		4.43	0.56	0.7117			3.79	0.34	0.6562

Tabela 5.59 Desempenho das previsões para o dreno "D191".

Métodos	Modelo	Aprendizado			Validação		Teste		
		MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
RNT com janelamento	VIII	3.62	0.35	0.8804	1.59	0.11	5.14	0.49	0.8446
RNT Elman	VIII	3.70	0.36	0.8968	1.35	0.09	5.25	0.48	0.8336
RNT FIR	III	4.05	0.46	1.1426			5.84	0.55	0.9596
RNT Jordan	VIII	3.64	0.35	0.8856	1.60	0.11	5.16	0.48	0.8401
Geoestatística		3.49	0.34	0.8527			4.48	0.46	0.7997

Tabela 5.60 Desempenho das previsões para o dreno "D192".

Métodos	Modelo	Aprendizado			Validação		Teste		
		MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
RNT com janelamento	IV	4.69	0.29	0.9184	1.86	0.07	5.80	0.28	0.9649
RNT Elman	IV	4.71	0.29	0.9214	2.12	0.07	5.81	0.28	0.9671
RNT FIR	III	5.22	0.39	1.2414			6.92	0.33	1.1499
RNT Jordan	IV	4.69	0.29	0.9190	1.81	0.06	5.79	0.28	0.9652
Geoestatística		4.00	0.25	0.7981			4.52	0.23	0.8125

Tabela 5.61 Desempenho das previsões para o dreno "D193".

Em relação aos intervalos de confiança pode-se observar que:

- Os obtidos para as previsões geoestatísticas apresentaram o melhor desempenho, com grau de confiança acima do esperado e intervalos de confiança mais reais;

- Os obtidos pela técnica de saída do erro apresentam grau de confiança elevado, mas os intervalos são muitos “largos”;
- Os obtidos pela técnica de *re-amostragem dos erros* não atenderam ao grau de confiança esperado.

6 CONCLUSÕES E SUGESTÕES

6.1 Conclusões

Barragens costumam apresentar uma grande quantidade de ensaios e instrumentações. Nestas obras, o monitoramento hidráulico e mecânico através da instalação de um sistema de instrumentação desempenha um papel fundamental na avaliação do comportamento destas estruturas, tanto durante o período de construção quanto no período de operação. O programa de monitoramento das barragens é composto geralmente por uma série de instrumentações que fornecem o conhecimento adequado da operação da obra. Estas medições podem ser de deslocamentos, cargas em elementos estruturais, poro-pressões, percolação e drenagem e também medidas de fatores ambientais que afetam o comportamento da barragem como temperatura, nível do reservatório, precipitação pluviométrica e etc., possibilitando a obtenção de algumas características, como por exemplo, as deformações.

Neste trabalho os resultados de instrumentação da barragem Funil, de Furnas Centrais Elétricas, em relação aos valores de vazão drenada da fundação da barragem (“D191”), da margem direita (“D192”) e da margem esquerda (“D193”), foram analisados com o auxílio de redes neurais temporais. As redes neurais temporais empregadas foram: RNT com arquitetura *feedforward* associada a técnica de janelamento, RNT recorrente Elman, RNT FIR e RNT Jordan. Adicionalmente, foram utilizadas duas técnicas para análise das séries temporais: os modelos de Box & Jenkins (1970) e métodos geoestatísticos, com a finalidade de comparar com o desempenho das RNT’s.

Nesta pesquisa estuda-se também a geração de intervalos de confiança para RNT e para métodos geoestatísticos. As previsões obtidas pela RNT com arquitetura *feedforward* associada à técnica de janelamento são utilizadas para a geração de intervalos de confiança pelos métodos de saída do erro e re-amostragem dos erros. O intervalo de confiança para previsões da krigagem

ordinária são gerados a partir da desigualdade proposta por Vysochanskii-Petunin em 1980.

As séries dos valores instrumentados são: as leituras de vazão dos drenos “D191”, “D192”, “D193”, do nível do reservatório e da temperatura. As séries foram amostradas no período compreendido entre 02/09/1985 e 25/02/2002, com frequência semanal. Na etapa de pré-processamento dos dados, os dados faltantes foram “recuperados” e leituras aberrantes substituídas por valores obtidos com base em interpolação por *splines cúbicas* com os valores adjacentes.

Cada uma das técnicas empregadas apresenta vantagens e desvantagens. As redes neurais temporais são redes dinâmicas que apresenta a vantagem de possuir propriedades de memória. Estas propriedades permitem-nas realizar tarefas de caráter temporal. Outra vantagem, comum a qualquer RNA, é a habilidade de simular fenômenos não lineares. A desvantagem da técnica é a necessidade de realização de testes com vários modelos de redes, com diferentes topologias e reinicializações randômicas, para tentar-se determinar a “melhor” rede neural para análise em questão.

Os modelos de Box & Jenkins apresentam como vantagem sua metodologia sistemática, que permite estimações baseadas em uma série de hipóteses e testes estatísticos para aceitação dos modelos, mas devem ser aplicados apenas para problemas lineares, estacionários ou não.

Métodos geoestatísticos, baseados na teoria das funções aleatórias, sobressai o conceito de “variograma” que expressa a correlação entre pares de “pontos” (na realidade valores da própria variável amostrada em diferentes posições temporais), não encarando o valor do “ponto” de maneira isolada, e assim capturando importantes informações sobre a variabilidade temporal da série.

No problema estudado correspondente à modelagem das vazões dos drenos, foi realizado duas análises distintas: a primeira considera o intervalo de tempo constante, ou seja, o conjunto de dados analisados apresenta sempre um intervalo de tempo semanal entre as amostras e a segunda análise considera que o conjunto de dados pode apresentar um intervalo de tempo variável entre as amostras.

No estudo com intervalo de tempo constante, os modelos obtidos pelas RNT com arquitetura *feedforward* associada a técnica de janelamento, RNT recorrente Elman e RNT Jordan apresentaram desempenho semelhante o que indica que o problema analisado apresenta características temporais que são fáceis de serem

captadas por todas as RNT, até pela RNT mais simples que é a com arquitetura *feedforward* associada a técnica de janelamento. Observando as métricas obtidas constatou-se que, tanto pelos modelos RNT quanto pelo modelo de Box & Jenkins e método geoestatístico, as previsões foram satisfatoriamente obtidas, com as previsões obtidas pelo método geoestatístico apresentando desempenho ligeiramente melhor. Foi analisada ainda a influência do intervalo de tempo na previsão, neste estudo foram considerados intervalos de tempo semanal, quinzenal e mensal sendo os melhores resultados obtidos para o intervalo de tempo semanal. Este resultado está bem coerente já que quanto menor o intervalo de tempo entre as amostras, mais informações da dependência temporal podem ser captadas pelos modelos de previsão.

No estudo do problema considerando o intervalo de tempo variável, o conjunto de amostras é bem maior já que se pode considerar todas as amostras independente de apresentarem o mesmo intervalo de tempo. Outro aspecto é que para os modelos conseguirem captar a distância entre as amostras, a data da amostra foi considerada como variável explicativa. Esta data foi utilizada como entrada para uma função seno, com o intuito de considerar o caráter cíclico do fenômeno estudado, onde a saída foi utilizada como entrada das RNT. Nesta análise consideram-se ainda, outras variáveis explicativas o nível do reservatório à montante e a temperatura. Observando as métricas obtidas constatou-se que, tanto pelos modelos RNT quanto pelo método geoestatístico, as previsões foram também satisfatoriamente obtidas, com a métrica U de Theil apresentando melhores resultados quando comparada com as obtidas com o intervalo de tempo constante.

Quanto ao estudo dos intervalos de confiança foram necessários utilizar técnicas que permitissem a geração de intervalos de confiança para estimativas com distribuição do erro não gaussiana. As técnicas de saída do erro, reamostragem dos erros apresentam esta característica, sendo utilizadas nas previsões geradas pelos modelos das RNT. Já para as previsões obtidas pela krigagem ordinária foi utilizada a desigualdade proposta por Vysochanskii-Petunin em 1980 para geração dos intervalos de confiança. Os intervalos de confiança obtidos pela previsão da krigagem ordinária apresentaram melhor desempenho. A aplicação de metodologias para determinação de intervalos de confiança é de grande importância, já que o processo de previsão sempre estará

associado a erros de estimativa. O intervalo de confiança permite que ao invés de fornecer um valor único para a estimativa, seja fornecido um intervalo e a probabilidade que o valor desconhecido esteja dentro deste intervalo.

No processo de pré-análise, o grau de correlação entre as séries temporais foi calculado para verificar se este pode ser tomado como um critério eficiente de seleção de variáveis de entrada para a RNT. Observando-se que pelos resultados obtidos para o dreno “D191” o melhor mecanismo para verificação de quais são as variáveis de entrada mais adequadas é a análise dos erros obtidos para os modelos neurais analisados.

No capítulo anterior (5), existem itens no qual constam as conclusões específicas das análises dos diferentes métodos, contendo comentários detalhados a respeito dos mesmos.

No presente capítulo, procurou-se fazer comentários mais gerais sobre este trabalho, bem como sugestões para a continuidade deste estudo.

6.2 Sugestões

Como trabalhos futuros para a continuidade do desenvolvimento de pesquisa na área da análise de séries temporais relacionadas com dados de instrumentação, sugerem-se os seguintes tópicos:

1 – aplicação das técnicas de redes neurais temporais na análise de séries temporais de instrumentações com dados que apresentem tendência para observar a capacidade de previsão de RNT's.

2 – utilização de métodos geoestatísticos apropriados à análise das séries temporais com tendência, como por exemplo, a técnica *de krigagem universal*.

3 – comparação de diferentes técnicas para geração de intervalos de confiança aplicadas nas previsões das redes neurais temporais.

REFERÊNCIAS BIBLIOGRÁFICAS

- Alves da Silva, A. P. and Moulin, L. S. (1999) “Neural Network based short-term electric load forecasting with confidence intervals” Proceedings of the IV Brazilian Conference on Neural Networks. ITA, São José dos Campos. pp. 7-12.
- Alves da Silva, A. P. and Moulin, L. S. (2000) “Confidence intervals for neural network based short-term load forecasting” IEEE Trans. Power Syst., vol. 15, pp. 1191-1196, Nov.
- Bandyopadhyay, J. K., Yerrapragada, S. S. and Gauri, K. L. (1995) “Artificial neural networks and durability of sphinx limestone” ASCE Journal of materials in civil engineering, vol.7, n.º3, August, pp.174-177.
- Basheer, I. A. and Najjar, Y. M. (1995) “A neural network for soil compaction” NUMOG V Numerical models in geomechanics, Pande & Pietruszczak Ed., Balkema, Rotterdam, pp. 435-440.
- Bishop, C. M. (1995) “Neural networks for pattern recognition”, Oxford Univ. Press.
- Box, G. E. P. and Jenkins, G. M. (1970) “Time series analysis: forecasting and control”. San Francisco, Calif.: Holden-Day.
- Box, G. E. P.; Jenkins, G. M. and Reinsel, G. C. (1994) “Time series analysis: forecasting and control”. 3nd. edition., Prentice –Hall, Inc.
- Chilès, J. P. and Delfiner, P. (1999) “Geostatistics: modeling spatial uncertainty” Series: Wiley series in probability and statistics. Applied probability and statistics section, Wiley-Interscience publication, John Wiley & Sons, Inc., New York.

Chow, Y. K.; Liu, L. F. and Chan, W. T. (1995) “Applications of neural networks in stress wave problems in piles” NUMOG V Numerical models in geomechanics, Pande & Pietruszczak Ed., Balkema, Rotterdam, pp. 429-435.

Chryssolouris, M. L. and Ramsey, A. (1996) “Confidence Interval prediction for neural network models” IEEE Trans. Neural Networks, vol. 7, pp. 229-232, Jan.

Dickley, D.A. and Fuller, W.A. (1979) “Distribution of the estimates for autoregressive time series with a unit root” Journal of the American Statistical Association, vol. 74, pp. 427-431.

Dyminski, A. D. (2000) “Análise de problemas geotécnicos através de redes neurais” Tese de Doutorado, PUC-Rio, Departamento de Engenharia Civil, Rio de Janeiro.

Ellis, G. W.; Yao, .; Zhao, R. and Penumadu, D. (1995) “Stress-strain modeling of sands using artificial neural networks”. ASCE Journal of geotechnical engineering, vol. 121, n.º 5, May, pp.429-435.

Eviews 4.0 Quantitative Micro Software, California. Copyright © 1994-2001

Gangopadhyay, S.; Gautam, T. R. and Gupta, A. D.(1999) “Subsurface characterization using artificial neural networks and GIS” ASCE Journal of computing in civil engineering, vol. 13, n.º.3, July, pp.153-161.

Gao, L.; Xie, K. H.; Ying, H. W. and Zhang, D. J. (2001) “Displacement prediction for soil nailed structure based on ANN” Computer methods and Advances in Geomechanics, Desai et al. Eds., Balkema, Rotterdam, pp. 197-200.

Ghaboussi, J. (1992) “Potential applications of neuro-biological computational models in geotechnical engineering” Proceedings, fourth international symposium on numerical models in geomechanics, Swansea, U. K., pp.543-555.

- Ghaboussi, J.; Garret Jr., J. H. and Wu, X. (1991) “Knowledge-based modeling of material behavior with neural networks”. ASCE Journal of engineering mechanics, vol.117, n.º1, January, pp.132-153.
- Ghaboussi, J. and Sidarta, D. E. (1997) “New method of material modeling using neural networks” Numerical Models in Geomechanics, Pietruszczak & Pande Eds., Balkema, Rotterdam, pp. 393-400.
- Ghaboussi, J.; Sidarta, D. E. and Lade, P. V. (1994) “Neural Network based modelling in geomechanics” Computer Methods and Advances in Geomechanics, Siriwardane & Zaman Eds., Balkema, Rotterdam, pp. 153-164.
- Goh, A. T. C. (1994) “Seismic liquefaction potential assessed by neural networks” ASCE Journal of geotechnical engineering, vol.120, n.º9, pp.1467-1480.
- Goh, A. T. C. (1996) “Neural-networks modeling of CPT seismic liquefaction data” ASCE Journal of geotechnical engineering, vol.122, n.º1, January, pp.70-73.
- Gutiérrez, J. L. C. (2003). “Monitoramento da instrumentação da barragem Corumbá I por redes neurais e modelos de Box & Jenkins”. Dissertação de Mestrado, PUC-Rio, Departamento de Engenharia Civil, Rio de Janeiro.
- Haykin, S. (1999) “Neural Networks – A comprehensive foundation”, 2nd. edition, IEEE Press.
- Isaaks, E. H. and Srivastava, R. M. (1989) “Applied geostatistics”, Oxford University Press., Inc., New York.
- Juang, C. H. and Jiang, T. (2001) “Site characterization using generalized regression neural networks” Computer methods and Advances in Geomechanics, Desai et al. Eds., Balkema, Rotterdam, pp. 213-217.

- Kiefa, M. A. A. (1998) "General regression neural networks for driven piles in cohesionless soils" ASCE Journal of geotechnical and geoenvironmental engineering, vol. 124, n.º 12, Dec, pp.1177-1185.
- King, R. L. and Signer, S. P. (1994) "Using artificial neural networks for feature detection in coal mine roofs" Proc. of 8th. International conference on computer methods and advances in geomechanics, Morgantown, Siriwardane & Zaman Ed., Balkema, Rotterdam, pp.1853-1857.
- Liu, H.; Li, T. and Zhang, Y. (1997) "The application of artificial neural networks in estimating the pile bearing capacity" Computer methods and advances in geomechanics, Yuan Ed., Balkema, Rotterdam, pp. 635-638.
- Matheron, G. (1962) "Traité de Géostatistique Appliquée", Mémoires du Bureau de Recherches Géologiques et Minières., Tome I, 333pp., Tome II, 172 pp.
- Matheron, G. (1970) "La théorie des variables régionalisées et ses applications", Les Cahiers du Centre de Morphologie Mathématique de Fontainebleau, École Nationale Supérieure des Mines de Paris, Fascicule 5, 212 pp.
- MATLAB (2001) The Language of Technical Computing, v. 6.1.0.450 Release 12.1., Copyright 1984-2001 The MathWorks, Inc. May 18.
- Medeiros, M. C. and Pedreira, C. E. (2001) "What are the effects of forecasting linear time series with neural networks?", Enginnering Intelligent Systems, vol. 9, pp.237-242.
- Millar, D. L. and Calderbank, P. A. (1995) "On the investigation of a multilayer feedforward neural network model of rock deformability behavior" Proc. of 8th. International congress on rock mechanics, Fujii Ed., Tóquio, Japão, pp.933-938.
- Musso, A.; Provenzano, P. and Ferlisi, S. (2002) "Modelling of a footing behavior using an Adaptive Neuro-Fuzzy Inference System" NUMOG VIII Numerical

Models in Geomechanics, Pande & Pietruszczak Eds., Swets & Zeitlinger, Lisse, pp. 253-258.

Najjar, Y. M.; Ali, H. E. and Basheer, I. A. (1999) "On the use of neuronets for simulating the stress-strain behavior of soils" NUMOG VII Numerical Models in Geomechanics, Pande, Pietruszczak & Schweiger Eds., Balkema, Rotterdam, pp. 657-662.

Oulapour, M. and Dadfar, F. (2002) "Prediction of soil parameters using MLPBP artificial neural networks" NUMOG VIII Numerical Models in Geomechanics, Pande & Pietruszczak Eds., Swets & Zeitlinger, Lisse, pp. 129-134.

Pande, G. N. and Shin, H. S. (2002) "Finite elements with artificial intelligence" NUMOG VIII Numerical Models in Geomechanics, Pande & Pietruszczak Eds., Swets & Zeitlinger, Lisse, pp. 241-246.

Pannatier, Y. (1996) VARIOWIN: Software for Spatial Data Analysis in 2D, Springer-Verlag, New York, NY.

Papadopoulos, G.; Edwards, P. J. and Murray, A. F. (2001) "Confidence estimation methods for neural networks: A practical comparison" IEEE Trans. Neural Networks, vol. 12, pp. 1278-1287, Nov.

Pedreira, C. E. (2001) "Notas de aula do curso de redes neurais" PUC-Rio, Departamento de Engenharia Elétrica, Rio de Janeiro.

Rahman, M. S. and Wang, J. (2002) "Adaptive neuro-fuzzy inference models for geotechnical problems" NUMOG VIII Numerical Models in Geomechanics, Pande & Pietruszczak Eds., Swets & Zeitlinger, Lisse, pp. 285-290.

Rivals, I. and Personnaz, L. (2000) "Construction of confidence intervals for neural networks based on least squares estimation" Neural Networks, vol. 13, pp. 463-484.

- Shin, H. S. and Pande, G. N. (2002) “Enhancement of data for training neural network based constitutive models for geomaterials” NUMOG VIII Numerical Models in Geomechanics, Pande & Pietruszczak Eds., Swets & Zeitlinger, Lisse, pp. 141-146.
- Sidarta, D. E. and Ghaboussi, J. (1997) “NN constitutive modeling using non-uniform material tests” Numerical Models in Geomechanics, Pietruszczak & Pande Eds., Balkema, Rotterdam, pp. 401-408.
- Soto, C. P. (1999) “Redes neurais temporais para o tratamento de sistemas variantes no tempo”, Dissertação de Mestrado, PUC-Rio, Departamento de Engenharia Elétrica, Rio de Janeiro.
- Tan, Y and Hui, Z (2001) “A fast radial basis function neural network model for approaching the stress-strain curve of rock” Computer methods and Advances in Geomechanics, Desai et al. Eds., Balkema, Rotterdam, pp. 227-230.
- Teh, C. I.; Wong, K. S.; Goh, A. T. C. and Jaritngam, S. (1997) “Prediction of pile capacity using neural networks” ASCE Journal of computing in civil engineering, vol. 11, nº.2, Apri, pp.129-138.
- Toll, D. (1996) “Artificial intelligence applications in geotechnical engineering” Electronic Journal of Geotechnical Engineering, <http://geotech.civen.okstate.edu/ejge/ppr9608>.
- Townsend, N. W. and Tarassenko, L. (1999) “Estimations of error bounds for neural-network function approximators” IEEE Trans. Neural Networks, vol. 10, pp. 217-230, Mar.
- Veiga, J.; Inoue, N; Dyminski, A. e Romanel, C. (2002) “Distribuição espacial dos valores de N-SPT por métodos geoestatísticos e redes neurais” XII COMBRAMSEG Congresso Brasileiro de Mecânica do Solos e Engenharia Geotécnica, São Paulo, Brasil, vol. 1 pp. 49 – 59.

- Wan, E. A. (1994) "Time Series Prediction by Using a Connectionist Network with Internal Delay Lines". Time Series Prediction. Forecasting the Future and Understanding the Past.. SFI Studies in the Sciences of Complexity, Proc. Vol XVII, Addison Wesley.
- Wu, H. (1997) "Constitutive relation modelling for soil using finite element-neural network hybrid algorithms" Computer Methods and Advances in Geomechanics, Yuan Ed., Balkema, Rotterdam, pp. 613-617.
- Xavier, S. R. (1999) "Estudo geoestatístico do subsolo da usina nuclear de Angra-2, RJ". Dissertação de mestrado, PUC-Rio, Departamento de Engenharia Civil, Rio de Janeiro.
- Zettler, A. H.; Poisel, R; Unterberger, W. and Stadler, G (1997) "Neural network combined with fuzzy logic to allow pressure sensitive grouting (PSG)" Computer Methods and Advances in Geomechanics, Yuan Ed., Balkema, Rotterdam, pp. 623-628.
- Zhang, L. and Luh, P. B (2001) "Confidence regions for cascaded neural network prediction in power markets" IEEE Power Eng. Soc. Winter Meeting, Columbus, OH, Jan., pp. 533-538.
- Zhang, L.; Luh, P. B and Kasiviswanathan, K. (2003) "Energy clearing price prediction and confidence interval estimation with cascaded neural networks" IEEE Trans. on Power Systems, vol. 18, n. 1, pp. 99-105, Feb.

APÊNDICE A

A.1. Previsão da Vazão para o dreno D-191 por Box & Jenkins.

Dados:

Fonte dos dados:	Furnas Centrais Elétricas.
Série:	Vazão nos drenos D-191 da barragem de Funil
Período:	02/09/1985 à 16/05/1994
Periodicidade:	Semanal.
Software utilizado	E-views vs 4.0.
Análise	Univariado
Previsão	Um horizonte

Conta-se com um total de 455 dados, estes foram obtidos através de prévio pré processamento de dados através de *splines cúbica*. Do conjunto as 200 amostras iniciais foram utilizadas para gerar o modelo por Box & Jenkins.

A.1.1. Identificação da série.

a) Gráfico da série de vazão.

Verifica-se pela figura A.1, que a série de interesse parece ser estacionária.




Figura A.1 Série de vazão para o conjunto de modelagem (200 primeiros valores da série histórica).

Pelo gráfico da série de vazão, observamos antecipadamente que a mesma apresenta média e variância constantes no tempo.

b) Teste da Raiz Unitária ($|\alpha_1| < 1$ para condição de estacionariedade para um AR(1))

O teste mais usual para determinar a estacionariedade de uma série temporal consiste na aplicação do chamado teste de Dickey–Fuller Ampliado (ADF test).

Hipótese nula (H_0)

H_0 : Existe RU (raiz unitária, $|\alpha_1| = 1$)

Se $|T_{\text{avaliado}}| > |T_{\text{tabela}}|$ então rejeita-se H_0 (hipótese nula)

Da tabela abaixo, $|-3.639976| > |-2.8764|$ com 5% de significância. Logo não existe raiz unitária (RU) e a série é admitida estacionária.

ADF Test Statistic	-3.639976	1% Critical Value*	-3.4651
		5% Critical Value	-2.8764
		10% Critical Value	-2.5746
*Mackinnon critical values for rejection of hypothesis of a unit root.			

Tabela A.1 Teste de Dickey–Fuller Ampliado (ADF test) para a série de vazão do dreno “D191” (E-views 4.0)

A.1.2. Análise do Correlograma (Identificação do modelo)

Para identificar o modelo analisamos as funções de autocorrelação simples (ACF) e de autocorrelação parcial (PACF).




Figura A.2 Funções de autocorrelação simples e parcial da série de vazão do dreno D-191 (E-views 4.0).

Observando o comportamento da ACF na figura A.2, verifica-se que a autocorrelação decresce exponencialmente, indicando que a série é estacionária na média, conforme observado na figura A.1. O comportamento da PACF mostra um corte no ‘lag 1’, podendo-se inferir que se trata de um processo auto-regressivo de ordem $p=1$, isto é, AR(1).

A.1.3. Modelo autoregressivo AR(1)

$$D191=0.5731375666+0.9373114823*D191(-1) \quad (A.1)$$

onde, a variável D191, no instante t , é uma função linear da mesma variável atrasada em um período D191(-1), ou seja, o valor da vazão no tempo $t-\Delta t$. Onde $\alpha_1 = 0.9373114823 < 1$

A.1.4. Verificação do desempenho do modelo AR(1)

a) Teste de significância dos parâmetros (*t-student*)

Para um nível de confiança do 95%, a hipótese nula é:

$$H_0: C(1) = 0$$

Então, se **Prob.** < **0.05**, rejeita-se H_0 e o coeficiente C(1) da variável D191 é significativo em 5%.

Dependent Variable: D191				
Method: Least Squares				
Sample(adjusted): 2 200				
Included observations: 199 after adjusting endpoints				
D191=C(1)+C(2)*D191(-1)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.573138	0.216258	2.650247	0.0087
C(2)	0.937311	0.021496	43.60483	0.0000
R-squared	0.906118	Mean dependent var		9.611467
Adjusted R-squared	0.905642	S.D. dependent var		2.832169
S.E. of regression	0.869981	Akaike info criterion		2.569308
Sum squared resid	149.1027	Schwarz criterion		2.602407
Log likelihood	-253.6462	Durbin-Watson stat		1.498176

Tabela A.2 Teste de significância dos parâmetros para o modelo AR(1) na previsão da vazão para o dreno “D191”.

Os critérios de Akaike e Schwarz são úteis para comparações com outros modelos.

b) Análise do resíduo

Nesta fase, verifica-se se o resíduo é um ruído branco (RB).

b.1) Análise dos resultados gráficos

O gráfico da figura A.3 mostra a série experimental das vazões, a previsão pelo modelo de Box & Jenkins e a distribuição temporal dos resíduos. Nesta última, observa-se que alguns “picos” caem fora da faixa de significância estabelecida em 5% mas, em geral, o comportamento é satisfatório.




Figura A.3 Representação gráfica das séries de vazão, do modelo ajustado AR(1) e dos resíduos para o dreno “D191”.

b.2) Análise do correlograma (quadrado dos resíduos)

Mostra as funções de autocorrelação simples e parcial do quadrado dos resíduos (erros) da equação A.1 estimada. No caso, observa-se que não existe autocorrelação com 5% de significância.




Figura A.4 Correlograma do quadrado dos resíduos obtidos pelo modelo AR(1) na modelagem da vazão para o dreno "D191".

b.3) Análise da variância dos resíduos (teste de ARCH)

Regra de decisão:

Hipótese nula

Ho: variância é constante (homocedasticidade)

Se (Prob < 0.05) heterocedasticidade, então rejeita-se a Ho

Se (Prob > 0.05) homocedasticidade, então aceita-se a Ho

No caso, como **Prob(0.170667) > 0.05** então aceita-se a Ho, considerando-se a variância do resíduo constante.

ARCH Test:

F-statistic	1.890933	Probability	0.170667
Obs*R-squared	1.891975	Probability	0.168979

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 01/04/80 Time: 00:38

Sample(adjusted): 3 200

Included observations: 198 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.675905	0.137344	4.921258	0.0000
RESID^2(-1)	0.097757	0.071090	1.375112	0.1707
R-squared	0.009555	Mean dependent var		0.749276
Adjusted R-squared	0.004502	S.D. dependent var		1.784827
S.E. of regression	1.780805	Akaike info criterion		4.002058
Sum squared resid	621.5681	Schwarz criterion		4.035272
Log likelihood	-394.2037	F-statistic		1.890933
Durbin-Watson stat	1.997257	Prob(F-statistic)		0.170667

Tabela A.3 Teste de ARCH para avaliação da variância dos resíduos obtidos pelo ajuste do modelo AR(1) na previsão de vazão do dreno "D191".

A estatística de Durbin-Watson (DW) indica o grau de correlação serial existente nos resíduos, com valores entre 0 e 2 indicando correlação positiva e valores entre 2 e 4 correlação negativa. O ideal é que DW seja 2, isto é, não exista correlação. Neste estudo $DW=1,997257$, podendo-se portanto inferir que o modelo AR(1) capturou toda a estrutura da série temporal analisada.

A.1.5. Previsão

As estimativas para os conjuntos de validação e teste foram pontuais. Os resultados da previsão são mostrados no item 5.2.1 e na figura 5.1.

A.2. Previsão da Vazão para o dreno D-192 por Box & Jenkins.

Dados:

Fonte dos dados: Furnas Centrais Elétricas.
Série: Vazão nos drenos D-192 da barragem de Funil

Período:	02/09/1985 à 16/05/1994
Periodicidade:	Semanal.
Software utilizado	E-views vs 4.0.
Análise	Univariado
Previsão	Um horizonte

Conta-se com um total de 455 dados, estes foram obtidos através de prévio pré processamento de dados através de *splines cúbica*. Do conjunto as 250 amostras iniciais foram utilizadas para gerar o modelo por Box & Jenkins.

A.2.1. Identificação da série.

a) Gráfico da série de vazão.

Verifica-se pela figura A.5, que a série de interesse parece ser estacionária.




Figura A.5 Série de vazão para o conjunto de modelagem (250 primeiros valores da série histórica).

Pelo gráfico da série de vazão, observamos antecipadamente que a mesma apresenta média e variância constantes no tempo.

b) Teste da Raiz Unitária ($|\alpha_1| < 1$ para condição de estacionariedade para um AR(1))

O teste mais usual para determinar a estacionariedade de uma série temporal consiste na aplicação do chamado teste de Dickey–Fuller Ampliado (ADF test).

Hipótese nula (H_0)

H_0 : Existe RU (raiz unitária, $|\alpha_1| = 1$)

Se $|T_{\text{avaliado}}| > |T_{\text{tabela}}|$ então rejeita-se H_0 (hipótese nula)

Da tabela abaixo, $|-2.937674| > |-2.8734|$ com 5% de significância. Logo não existe raiz unitária (RU) e a série é admitida estacionária.

ADF Test Statistic	-2.937674	1% Critical Value*	-3.4586
		5% Critical Value	-2.8734
		10% Critical Value	-2.5730
*MacKinnon critical values for rejection of hypothesis of a unit root.			

Tabela A.4 Teste de Dickey–Fuller Ampliado (ADF test) para a série de vazão do dreno “D192” (E-views 4.0).

A.2.2. Análise do Correlograma (Identificação do modelo)

Para identificar o modelo analisamos as funções de autocorrelação simples (ACF) e de autocorrelação parcial (PACF).




Figura A.6 Funções de autocorrelação simples e parcial da série de vazão do dreno “D192” (E-views 4.0).

Observando o comportamento da ACF na figura A.6, verifica-se que a autocorrelação decresce exponencialmente, indicando que a série é estacionária na

média, conforme observado na figura A.5. O comportamento da PACF mostra um corte no ‘lag 1’, podendo-se inferir que se trata de um processo auto-regressivo de ordem $p=1$, isto é, AR(1).

A.2.3. Modelo autoregressivo AR(1)

$$D192=1.623486487+0.7888842178*D192(-1) \quad (A.2)$$

onde, a variável D192, no instante t , é uma função linear da mesma variável atrasada em um período D192(-1), ou seja, o valor da vazão no tempo $t-\Delta t$. Onde $\alpha_1 = 0.7888842178 < 1$

A.2.4. Verificação do desempenho do modelo AR(1)

a) Teste de significância dos parâmetros (*t-student*)

Para um nível de confiança do 95%, a hipótese nula é:

$$H_0: C(1) = 0$$

Então, se **Prob.** < **0.05**, rejeita-se H_0 e o coeficiente C(1) da variável D192 é significativo em 5%.

Dependent Variable: D192				
Method: Least Squares				
Sample(adjusted): 2 250				
Included observations: 249 after adjusting endpoints				
D192=C(1)+C(2)*D192(-1)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	1.623486	0.303470	5.349744	0.0000
C(2)	0.788884	0.039123	20.16435	0.0000
R-squared	0.622094	Mean dependent var		7.714040
Adjusted R-squared	0.620564	S.D. dependent var		0.752288
S.E. of regression	0.463398	Akaike info criterion		1.307537
Sum squared resid	53.04011	Schwarz criterion		1.335790
Log likelihood	-160.7883	Durbin-Watson stat		2.071237

Tabela A.5 Teste de significância dos parâmetros para o modelo AR(1) na previsão da vazão para o dreno “D192”.

Os critérios de Akaike e Schwarz são úteis para comparações com outros modelos.

b) Análise do resíduo

Nesta fase, verifica-se se o resíduo é um ruído branco (RB).

b.1) Análise dos resultados gráficos

O gráfico da figura A.7 mostra a série experimental das vazões, a previsão pelo modelo de Box & Jenkins e a distribuição temporal dos resíduos. Nesta última, observa-se que alguns “picos” caem fora da faixa de significância estabelecida em 5% mas, em geral, o comportamento é satisfatório.




Figura A.7 Representação gráfica das séries de vazão, do modelo ajustado AR(1) e dos resíduos para o dreno “D192”.

b.2) Análise do correlograma (quadrado dos resíduos)

Mostra as funções de autocorrelação simples e parcial do quadrado dos resíduos (erros) da equação A.2 estimada. No caso, observa-se que não existe autocorrelação com 5% de significância.




Figura A.8 Correlograma do quadrado dos resíduos obtidos pelo modelo AR(1) na modelagem da vazão para o dreno "D192".

b.3) Análise da variância dos resíduos (teste de ARCH)

Regra de decisão:

Hipótese nula

Ho: variância é constante (homocedasticidade)

Se (Prob < 0.05) heterocedasticidade, então rejeita-se a Ho

Se (Prob > 0.05) homocedasticidade, então aceita-se a Ho

No caso, como **Prob(0.8096) > 0.05** então aceita-se a Ho, considerando-se a variância do resíduo constante.

ARCH Test:

F-statistic	5.794255	Probability	0.003480
Obs*R-squared	11.19910	Probability	0.003700

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 01/04/80 Time: 02:20

Sample(adjusted): 4 250

Included observations: 247 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.169990	0.03473	4.893337	0.0000
RESID^2(-1)	0.215659	0.06398	3.370270	0.0009
RESID^2(-2)	-0.015425	0.06394	-0.241219	0.8096
R-squared	0.045340	Mean dependent var		0.212526
Adjusted R-squared	0.037515	S.D. dependent var		0.483850
S.E. of regression	0.474687	Akaike info criterion		1.359749
Sum squared resid	54.97995	Schwarz criterion		1.402373
Log likelihood	-164.9290	F-statistic		5.794255
Durbin-Watson stat	1.998757	Prob(F-statistic)		0.003480

Tabela A.6 Teste de ARCH para avaliação da variância dos resíduos obtidos pelo ajuste do modelo AR(1) na previsão de vazão do dreno "D192".

A estatística de Durbin-Watson (DW) indica o grau de correlação serial existente nos resíduos, com valores entre 0 e 2 indicando correlação positiva e valores entre 2 e 4 correlação negativa. O ideal é que DW seja 2, isto é, não exista correlação. Neste estudo $DW=1,998757$, podendo-se portanto inferir que o modelo AR(1) capturou toda a estrutura da série temporal analisada.

A.2.5. Previsão

As estimativas para os conjuntos de validação e teste foram pontuais. Os resultados da previsão são mostrados no item 5.2.1 e na figura 5.2.

A.3. Previsão da Vazão para o dreno D-193 por Box & Jenkins.

Dados:

Fonte dos dados:	Furnas Centrais Elétricas.
Série:	Vazão nos drenos D-193 da barragem de Funil
Período:	02/09/1985 à 16/05/1994
Periodicidade:	Semanal.
Software utilizado	E-views vs 4.0.
Análise	Univariado
Previsão	Um horizonte

Conta-se com um total de 455 dados, estes foram obtidos através de prévio pré processamento de dados através de *splines cúbica*. Do conjunto as 200 amostras iniciais foram utilizadas para gerar o modelo por Box & Jenkins.

A.3.1. Identificação da série.

a) Gráfico da série de vazão.

Verifica-se pela figura A.9, que a série de interesse parece ser estacionária.




Figura A.9 Série de vazão para o conjunto de modelagem (200 primeiros valores da série histórica).

Pelo gráfico da série de vazão, observamos antecipadamente que a mesma apresenta média e variância constantes no tempo.

b) Teste da Raiz Unitária (Condições de estacionariedade para um AR(2))

$$\alpha_2 + \alpha_1 < 1$$

$$\alpha_2 - \alpha_1 < 1$$

$$-1 < \alpha_2 < 1$$

Hipótese nula

Ho: Existe RU

Se $|T_{\text{avaliado}}| > |T_{\text{tabela}}|$ então rejeita-se Ho

Da tabela abaixo, $|-3.274533| > |-2.8764|$ com 5% de significância. Logo não existe raiz unitária (RU) e a série é admitida estacionária.

ADF Test Statistic	-3.274533	1% Critical Value*	-3.4653
		5% Critical Value	-2.8764
		10% Critical Value	-2.5746
*MacKinnon critical values for rejection of hypothesis of a unit root.			

Tabela A.7 Teste de Dickey–Fuller Ampliado (ADF test) para a série de vazão do dreno “D193” (E-views 4.0).

A.3.2. Análise do Correlograma (Identificação do modelo)

Para identificar o modelo analisamos as funções de autocorrelação simples (ACF) e de autocorrelação parcial (PACF).




Figura A.10 Funções de autocorrelação simples e parcial da série de vazão do dreno “D193” (E-views 4.0).

Observando o comportamento da ACF na figura A.10, verifica-se que a autocorrelação decresce exponencialmente, indicando que a série é estacionária na média, conforme observado na figura A.9. O comportamento da PACF mostra um corte no ‘lag 2’, podendo-se inferir que se trata de um processo auto-regressivo de ordem $p=1$, isto é, AR(2).

A.3.3. Modelo autoregressivo AR(2)

$$D193=0.221036+0.748134*D193(1)+0.196510*D193(-2) \quad (A.3)$$

onde, a variável D193, no instante t , é uma função linear da mesma variável atrasada em um período D193(-1) e atrasada em dois períodos D193(-2), onde $\alpha_1 + \alpha_2 = 0.748134 + 0.196510 < 1$

A.3.4. Verificação do desempenho do modelo AR(2)

a) Teste de significância dos parâmetros (*t-student*)

Para um nível de confiança do 95%, a hipótese nula é:

$$H_0: C(1) = 0$$

Então, se **Prob.** < **0.05**, rejeita-se H_0 e o coeficiente C(1) da variável D193 é significativo em 5%.

Dependent Variable: D193				
Method: Least Squares				
Sample(adjusted): 4 455				
Included observations: 452 after adjusting endpoints				
D193=C(1)+C(2)*D193(-1)+C(3)*D193(-2)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.221036	0.066128	3.342555	0.0009
C(2)	0.748134	0.046916	15.94640	0.0000
C(3)	0.196510	0.046565	4.220169	0.0000
R-squared	0.889365	Mean dependent var		4.090398
Adjusted R-squared	0.888872	S.D. dependent var		0.893882
S.E. of regression	0.297984	Akaike info criterion		0.423059
Sum squared resid	39.86865	Schwarz criterion		0.450363
Log likelihood	-92.61144	Durbin-Watson stat		2.035736

Tabela A.8 Teste de significância dos parâmetros para o modelo AR(2) na previsão da vazão para o dreno “D193”.

Os critérios de Akaike e Schwarz são úteis para comparações com outros modelos.

b) Análise do resíduo

Nesta fase, verifica-se se o resíduo é um ruído branco (RB).

b.1) Análise dos resultados gráficos

O gráfico da figura A.11 mostra a série experimental das vazões, a previsão pelo modelo de Box & Jenkins e a distribuição temporal dos resíduos. Nesta última, observa-se que alguns “picos” caem fora da faixa de significância estabelecida em 5% mas, em geral, o comportamento é satisfatório.




Figura A.11 Representação gráfica das séries de vazão, do modelo ajustado AR(2) e dos resíduos para o dreno “D193”.

b.2) Análise do correlograma (quadrado dos resíduos)

Mostra as funções de autocorrelação simples e parcial do quadrado dos resíduos (erros) da equação A.3 estimada. No caso, observa-se que não existe autocorrelação com 5% de significância.




Figura A.12 Correlograma do quadrado dos resíduos obtidos pelo modelo AR(2) na modelagem da vazão para o dreno "D193".

b.3) Análise da variância dos resíduos (teste de ARCH)

Regra de decisão:

Hipótese nula

Ho: variância é constante (homocedasticidade)

Se (Prob < 0.05) heterocedasticidade, então rejeita-se a Ho

Se (Prob > 0.05) homocedasticidade, então aceita-se a Ho

No caso, como **Prob(0.0909) > 0.05** então aceita-se a Ho, considerando-se a variância do resíduo constante.

ARCH Test:

F-statistic	34.46021	Probability	0.000000
Obs*R-squared	60.11429	Probability	0.000000

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Sample(adjusted): 6 455

Included observations: 450 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.061329	0.011907	5.150801	0.0000
RESID^2(-1)	0.395965	0.048414	8.178743	0.0000
RESID^2(-2)	-0.082018	0.048414	-1.694096	0.0909
R-squared	0.133587	Mean dependent var		0.088170
Adjusted R-squared	0.129711	S.D. dependent var		0.249095
S.E. of regression	0.232379	Akaike info criterion		-0.074249
Sum squared resid	24.13803	Schwarz criterion		-0.046854
Log likelihood	19.70595	F-statistic		34.46021
Durbin-Watson stat	1.942856	Prob(F-statistic)		0.000000

Tabela A.9 Teste de ARCH para avaliação da variância dos resíduos obtidos pelo ajuste do modelo AR(2) na previsão de vazão do dreno “D193”.

A estatística de Durbin-Watson (DW) indica o grau de correlação serial existente nos resíduos, com valores entre 0 e 2 indicando correlação positiva e valores entre 2 e 4 correlação negativa. O ideal é que DW seja 2, isto é, não exista correlação. Neste estudo $DW=1,942856$, podendo-se portanto inferir que o modelo AR(2) capturou toda a estrutura da série temporal analisada.

A.3.5. Previsão

As estimativas para os conjuntos de validação e teste foram pontuais. Os resultados da previsão são mostrados no item 5.2.1 e na figura 5.3.

APÊNDICE B

Apresenta-se neste apêndice os gráficos relativos as redes neurais temporais consideradas para modelagem do comportamento no tempo com intervalo quinzenal e mensal para o dreno D-191.

B.1. Intervalo de tempo quinzenal.

Dos gráficos B.1 a B.4 pode-se concluir que o modelo neural para a RNT com janelamento, Elman e Jordan apresentaram desempenho equivalente ao do intervalo de tempo semanal. Enquanto que a RNT FIR apresentam o desempenho inferior, com erros maiores.




Figura B.1 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT com janelamento para o dreno "D191".




Figura B.2 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT Elman para o dreno "D191".




Figura B.3 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT FIR para o dreno "D191".




Figura B.4 Modelagem e previsão da vazão com intervalo de tempo quinzenal para o modelo de RNT Jordan para o dreno "D191".

B.2. Intervalo de tempo mensal.

Assim como nos resultados obtidos para o intervalo de tempo quinzenal, os gráficos B.5 a B.8 indicam que o modelo neural para a RNT com janelamento e Elman apresentaram desempenho equivalente ao do intervalo de tempo semanal. Enquanto que a RNT FIR apresenta o desempenho inferior. Já a RNT Jordan apresenta o desempenho superior, com erros menores.




Figura B.5 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT com janelamento para o dreno "D191".




Figura B.6 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT Elman para o dreno "D191".




Figura B.7 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT FIR para o dreno "D191".




Figura B.8 Modelagem e previsão da vazão com intervalo de tempo mensal para o modelo de RNT Jordan para o dreno "D191".

APÊNDICE C

Apresenta-se neste apêndice, o estudo que considera que a instrumentação de determinado dreno parasse de funcionar, procurando-se estimar a provável evolução no tempo de suas leituras em função das variáveis causais nível d'água do reservatório, temperatura e vazões dos drenos não danificados. É importante ressaltar que nesta aplicação, as previsões efetuadas no tempo t são feitas com base em leituras de outras variáveis efetuadas também no tempo t e anteriores, ou seja, sem um horizonte de previsão.

C.1. Previsão de vazão de drenos danificados.

Para pesquisar as potencialidades das RNA em tratar este problema, foram testados seis modelos diferentes para cada dreno, com as entradas e saídas descritas nas tabelas C.1 a C.3. Os modelos neurais são função do nível d'água do reservatório, da temperatura e das vazões dos drenos não danificados. A saída da rede é o valor da vazão do dreno danificado analisado.

Devido as amostras não estarem todas espaçadas com frequência semanal, as datas das medições foram consideradas como entrada. As tabelas C.4 a C.6 indicam o desempenho das redes. O melhor modelo em cada tabela é marcado em negrito. As figuras C.1 a C.3 comparam os valores reais com os obtidos pela RNA e com os obtidos pelas RNTs estudadas no capítulo 5.

Modelos	Entradas	Saída
I	T_t, NA_t, TMP_t	$VZ1_t$
II	$T_{t-1}, NA_{t-1}, TMP_{t-1}, T_t, NA_t, TMP_t$	$VZ1_t$
III	T_t, NA_t	$VZ1_t$
IV	$T_{t-1}, NA_{t-1}, T_t, NA_t$	$VZ1_t$
V	$T_t, VZ2_t, VZ3_t$	$VZ1_t$
VI	$T_{t-1}, VZ2_{t-1}, VZ3_{t-1}, T_t, VZ2_t, VZ3_t$	$VZ1_t$

Tabela C.1 Entradas e Saídas adotadas para o dreno "D191" danificado.

Modelos	Entradas	Saída
I	T_t, NA_t, TMP_t	$VZ2_t$
II	$T_{t-1}, NA_{t-1}, TMP_{t-1}, T_t, NA_t, TMP_t$	$VZ2_t$
III	T_t, NA_t	$VZ2_t$
IV	$T_{t-1}, NA_{t-1}, T_t, NA_t$	$VZ2_t$
V	$T_t, VZ1_t, VZ3_t$	$VZ2_t$
VI	$T_{t-1}, VZ1_{t-1}, VZ3_{t-1}, T_t, VZ1_t, VZ3_t$	$VZ2_t$

Tabela C.2 Entradas e Saídas adotadas para o dreno “D192” danificado.

Modelos	Entradas	Saída
I	T_t, NA_t, TMP_t	$VZ3_t$
II	$T_{t-1}, NA_{t-1}, TMP_{t-1}, T_t, NA_t, TMP_t$	$VZ3_t$
III	T_t, NA_t	$VZ3_t$
IV	$T_{t-1}, NA_{t-1}, T_t, NA_t$	$VZ3_t$
V	$T_t, VZ1_t, VZ2_t$	$VZ3_t$
VI	$T_{t-1}, VZ1_{t-1}, VZ2_{t-1}, T_t, VZ1_t, VZ2_t$	$VZ3_t$

Tabela C.3 Entradas e Saídas adotadas para o dreno “D193” danificado.

Analisando-se as métricas obtidas e os gráficos nota-se que:

- no processo de aprendizagem os valores de vazão do dreno “D191” podem ser razoavelmente previstos a partir da série do nível do reservatório à montante. Enquanto que as previsões obtidas com o conjunto de teste, acompanham a mesma tendência da série de vazão, mas com erros maiores do que os obtidos no aprendizado;
- os melhores modelos obtidos para previsão dos drenos danificados “D192” e “D193” utilizam como variáveis explicativas a data e as vazões dos drenos não danificados. Este fato se justifica pela correlação elevada encontrada entre as vazões dos drenos “D192” e “D193” (grau de correlação de 83%);
- os menores valores de MAPE e U-Theil para o conjunto de teste foram obtidos para o dreno “D192”. O gráfico das previsões indica regiões que apresentam erros maiores para o conjunto de aprendizagem, como por exemplo no final da série no ano de 1994;

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	14.99	1.44	1.8304	6.53	0.44	18.39	1.35	2.6198
II	14.23	1.42	1.8061	8.10	0.54	17.88	1.32	2.5592
III	13.26	1.28	1.6246	5.82	0.37	15.24	1.14	2.2001
IV	13.53	1.33	1.6906	4.23	0.31	16.46	1.22	2.3550
V	18.93	2.32	2.9589	6.63	0.50	20.04	1.57	3.0415
VI	21.32	2.56	3.2627	9.89	0.83	20.25	1.53	2.9568

Tabela C.4 Desempenho da previsão da vazão a partir das outras séries para o dreno "D191".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	9.93	0.84	2.0996	4.56	0.31	13.94	0.94	1.6340
II	9.64	0.82	2.0558	4.60	0.31	13.80	0.92	1.5956
III	9.55	0.82	2.0361	3.45	0.23	13.77	0.93	1.6134
IV	9.84	0.84	2.1034	3.34	0.23	13.91	0.93	1.6091
V	5.30	0.48	1.1858	1.61	0.11	9.33	0.66	1.1548
VI	5.03	0.46	1.1537	2.19	0.14	8.20	0.57	0.9931

Tabela C.5 Desempenho da previsão da vazão a partir das outras séries para o dreno "D192".

Modelos	Aprendizado			Validação		Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
I	16.08	0.77	2.4525	9.86	0.37	18.75	0.63	2.1920
II	15.91	0.76	2.4078	11.35	0.45	19.62	0.64	2.2366
III	15.91	0.76	2.3931	10.50	0.39	18.77	0.62	2.1585
IV	16.24	0.78	2.4913	9.25	0.35	18.84	0.62	2.1503
V	9.89	0.52	1.6350	3.25	0.11	13.92	0.48	1.6695
VI	9.47	0.50	1.5983	3.32	0.12	12.80	0.44	1.5415

Tabela C.6 Desempenho da previsão da vazão a partir das outras séries para o dreno "D193".




Figura C.1 Comparação da previsão do modelo III da tabela C.2 com as previsões obtidas pelas RNT's para o dreno "D191".




Figura C.2 Comparação da previsão do modelo III da tabela C.3 com as previsões obtidas pelas RNT's para o dreno "D192".




Figura C.3 Comparação da previsão do modelo III da tabela C.4 com as previsões obtidas pelas RNT's para o dreno "D193".

APÊNDICE D

Apresenta-se neste apêndice, uma tentativa de obtenção dos dados faltantes das séries de vazão dos drenos “D191”, “D192” e “D193” utilizando a cokrigagem. Nesta tentativa considerou-se como variável primária a séries de vazão e como variável secundária o nível do reservatório à montante. O método da cokrigagem procura explorar as correlações cruzadas, utilizando nas estimativas da variável principal também as informações fornecidas pela variável secundária. Para a aplicação da cokrigagem, deseja-se que o nível do reservatório à montante seja linearmente correlacionado com a vazão do dreno. O valor do coeficiente de correlação é um bom indicador de quão bem sucedida será a tentativa de prever o valor de uma variável a partir da outra. Sendo assim, foram elaborados os diagramas de dispersão do nível do reservatório à montante x vazão do dreno “D191”, nível do reservatório à montante x vazão do dreno “D192” e nível do reservatório à montante x vazão do dreno “D193”, ilustrados na Figura D.1 a D.3.




Figura D.1 Diagrama de dispersão “D191” x nível do reservatório.




Figura D.2 Diagrama de dispersão “D192” x nível do reservatório.




Figura D.3 Diagrama de dispersão “D193” x nível do reservatório.

Pode-se verificar alguma correlação entre as variáveis nível do reservatório à montante com os valores de vazão dos drenos. Sendo assim, tentou-se utilizar o método da cokrigagem para estimar os dados faltantes das séries de vazão. Para a tentativa de estimativa dos valores faltantes pelo método de cokrigagem utilizou-se os programas Gslib 2.0 (1997) e VARIOWIN 2.2 (1996). Ao utilizar o método, constatou-se que um modelo linear de co-regionalização não podia ser gerado a partir da variável primária e secundária.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)