- Alves da Silva, A. P. and Moulin, L. S. (1999) "Neural Network based short-term electric load forecasting with confidence intervals" Proceeddings 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.°3, 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°.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 enginnering 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 artifical 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 nonuniform 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"ElectronicJournalofGeotechnicalEngineering,.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 Weslwy.
- Wu, H. (1997) "Constitutive relation modelling for soil using finite elementneural 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 netoworks" 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 ($|lpha_1|$ < 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_o)

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

Se $|\mathbf{T}_{avaliado}| > |\mathbf{T}_{tabela}|$ então rejeita-se H_o (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 critic	al values fo	or 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).

Autocorrelation Partial Correlation AC PAC Q-Stat Product Image: Product of the product	Date: 01/04/80 Time: 00:10 Sample: 1 200 Included observations: 200										
Image:	C Q-Stat Prob	PAC	AC		Partial Correlation	Autocorrelation					
Image: Solution of the second seco	37 178.21 0.000 61 328.47 0.000 02 450.22 0.000 0547.51 0.000 37 620.59 0.000 37 620.59 0.000 37 620.59 0.000 37 620.59 0.000 36 730.08 0.000 22 752.80 0.000 22 752.60 0.000 24 757.60 0.000 24 757.61 0.000 16 764.01 0.000 16 764.01 0.000 16 764.01 0.000 16 764.01 0.000 16 764.01 0.000 17 812.62 0.000 10 79.010 0.000 11 72.62 0.000 12 81.38 0.000	0.937 -0.161 -0.102 0.000 -0.137 -0.071 0.036 -0.023 -0.022 -0.076 -0.077 -0.124 -0.077 -0.124 -0.077 -0.086 0.046 -0.010 -0.071 0.000 -0.033	0.937 0.858 0.771 0.687 0.498 0.408 0.331 0.262 0.198 0.133 0.068 -0.004 -0.077 -0.153 -0.215 -0.269 -0.319 -0.359	1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20							

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) (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- Δ 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:

Ho: C(1) = 0

Então, se **Prob.** < 0.05, rejeita-se Ho e o coeficiente C(1) da variável D191

é significativo em 5%.

Dependent Variable: D191							
Method: Least Square	s						
Sample(adjusted): 2 2	00						
Included observations	199 after a	djusting endpo	oints				
D191=C(1)+C(2)*D19	1(-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 depen	dent var	9.611467			
Adjusted R-squared	0.905642	S.D. depende	ent 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-Wats	on 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.

Date: 01/04/80	Time: 00:24
Sample: 2 200	
Included observ	ations: 199

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
a 🔤	i	1	0.098	0.098	1.9301	0.165
1 1	11	2	-0.003	-0.013	1.9324	0.381
1 💻	1 📕	3	0.142	0.145	6.0228	0.111
1 1		4	-0.023	-0.053	6.1270	0.190
1 🚺	1 11	5	0.043	0.057	6.5087	0.260
1	1	6	0.160	0.132	11.795	0.067
	1 1	7	0.018	0.000	11.861	0.105
1 - 1	1	8	0.088	0.082	13.471	0.097
1	111	9	0.069	0.017	14.478	0.106
1 1	1 1	10	-0.010	-0.007	14.498	0.151
1 1	111	11	0.042	0.015	14.873	0.188
1	1	12	0.090	0.061	16.603	0.165
1 1	111	13	0.002	-0.013	16.604	0.218
1 1	1	14	-0.002	-0.032	16.604	0.278
1	1 1	15	0.020	-0.005	16.691	0.338
1	141	16	-0.047	-0.052	17.182	0.374
1 1 1	1	17	-0.029	-0.036	17.372	0.429
1	1	18	-0.025	-0.048	17.507	0.489
1.1		19	-0.012	0.003	17.539	0.553
0 J D -	i i	20	0.026	0.020	17.693	0.608

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) heterocesdasticidade, 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, considerandose 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.
С	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).

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

Se $|\mathbf{T}_{avaliado}| > |\mathbf{T}_{tabela}|$ então rejeita-se H_o (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 critic	al values fo	or 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).

```
Date: 01/04/80 Time: 00:11
Sample: 1 250
Included observations: 250
```

_							
8	Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
1). 		· •	1	0.785	0.785	155.96	0.000
			2	0.639	0.060	259.81	0.000
			3	U.6U4	0.222	352.76	0.000
		1 1	4	0.584	0.106	440.07	0.000
		1 1	5	0.532	0.008	512.93	0.000
	1		6	0.485	0.023	573.54	0.000
		1 I I	7	0.466	0.056	629.80	0.000
		L L	8	0.420	-0.053	675.70	0.000
	1 - 1	1 1	9	0.374	-0.006	712.31	0.000
	1 	1 1	10	0.343	-0.004	743.22	0.000
	1 	1	11	0.312	-0.021	768.92	0.000
	1	1	12	0.258	-0.069	786.54	0.000
	1 💻	1	13	0.214	-0.022	798.75	0.000
	L 🗖	1 1	14	0.193	-0.001	808.72	0.000
	(1)	1	15	0.156	-0.050	815.21	0.000
	i 🖬 👘	1	16	0.087	-0.103	817.24	0.000
	L L	1	17	0.016	-0.103	817.31	0.000
	1		18	-0.009	-0.003	817.33	0 000
			19	-0.042	-0.051	817 81	0.000
			20	-0.093	-0.059	820 18	0.000
			20	0.000	0.000	020.10	0.000

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)

$$D192=1.623486487+0.7888842178*D192(-1)$$
(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- Δ 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:

Ho: C(1) = 0

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

Dependent Variable: [Dependent Variable: D192					
Method: Least Square	S					
Sample(adjusted): 2 2	50					
Included observations	: 249 after ad	djusting endp	oints			
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 depen	dent var	7.714040		
Adjusted R-squared	0.620564	S.D. depend	ent var	0.752288		
S.E. of regression	0.463398	Akaike info criterion 1.307537				
Sum squared resid	uared resid 53.04011 Schwarz criterion 1.335790					
Log likelihood	-160.7883	Durbin-Wats	on 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.

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
ı 🗖	ı 	1	0.211	0.211	11.196	0.001
1 1	1	2	0.030	-0.015	11.423	0.003
1 <mark>1</mark> 1	1 I I	3	0.056	0.056	12.228	0.007
1 1	1 1 1	4	-0.031	-0.056	12.469	0.014
1 1	1	5	0.013	0.033	12.512	0.028
111	1	6	-0.015	-0.029	12.568	0.050
1 1		7	-0.058	-0.046	13.422	0.062
1 1	11	8	-0.012	0.006	13.457	0.097
1		9	-0.031	-0.028	13.712	0.133
1	10	10	-0.052	-0.037	14.414	0.155
1	10	11	-0.047	-0.034	14.990	0.183
1	11	12	-0.030	-0.009	15.234	0.229
1		13	-0.058	-0.052	16.121	0.243
111	1	14	-0.011	0.011	16.154	0.304
111	1 1	15	-0.010	-0.012	16.182	0.370
1	1	16	0.035	0.045	16.515	0.418
1	1	17	-0.030	-0.060	16.757	0.471
1	11	18	-0.037	-0.020	17.126	0.514
111	11	19	0.009	0.011	17.149	0.580
- P	1 1	20	0.010	0.006	17.177	0.641

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) heterocesdasticidade, 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.	t-Statistic	Prob.
		Error		
С	0.169990	0.03473	4.893337	0.0000
		9		
RESID ² (-1)	0.215659	0.06398	3.370270	0.0009
		9		
RESID ² (-2)	-0.015425	0.06394	-0.241219	0.8096
		5		
R-squared	0.045340	Mean de	ependent var	0.212526
Adjusted R-squared	0.037515	S.D. dep	endent var	0.483850
S.E. of regression	0.474687	Akaike ir	nfo criterion	1.359749
Sum squared resid	54.97995	Schwarz	criterion	1.402373
Log likelihood	-164.9290	F-statisti	c	5.794255
Durbin-Watson stat	1.998757	Prob(F-s	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.

$$\alpha_2 + \alpha_1 < 1$$

$$\alpha_2 - \alpha_1 < 1$$

 $-1 < \alpha_2 < 1$

Hipótese nula

Ho: Existe RU

Se $|T_{avaliado}| > |T_{tabela}|$ 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 critic	al values fo	or 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).

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	0.933	0.933	398.16	0.00
		2	0.895	0.183	764.90	0.00
	I I I	3	0.870	0.139	1112.7	0.00
	l i 🖡	4	0.846	0.046	1441.9	0.00
	1	5	0.819	-0.001	1751.1	0.00
	()	6	0.800	0.056	2046.7	0.00
	1.1	7	0.779	0.005	2327.8	0.00
	11	8	0.757	0.001	2594.1	0.00
1	վել	9	0.739	0.014	2847.9	0.00
	j je	10	0.721	0.013	3090.3	0.00
	1	11	0.696	-0.056	3316.6	0.0
	1 I I	12	0.686	0.089	3536.8	0.00
		13	0.695	0.195	3763.4	0.0
	10	14	0.687	-0.024	3985.2	0.0
	() ()	15	0.685	0.074	4206.5	0.0
	i i ju	16	0.683	0.010	4426.9	0.0
		17	0.674	-0.032	4642.2	0.0
		18	0.664	-0.013	4851.3	0.0
	()	19	0.663	0.054	5060.4	0.0
1	1	20	0.669	0.103	5274.3	0.00

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) (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:

Ho: C(1) = 0

Então, se Prob. < 0.05, rejeita-se Ho e o coeficiente C(1) da variável D193

é significativo em 5%.

Dependent Variable: D193						
Method: Least Square	S					
Sample(adjusted): 4 4	55					
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 depen	dent var	4.090398		
Adjusted R-squared	0.888872	S.D. depend	ent 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-Wats	on 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.

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
1 🛌	1	1	0.278	0.278	16.230	0.000
1 1	1	2	-0.004	-0.088	16.234	0.000
1	I I	3	-0.036	-0.011	16.513	0.001
1	1	4	-0.061	-0.051	17.296	0.002
1 1	T T	5	-0.022	0.008	17.401	0.004
1.	10	6	-0.031	-0.035	17.608	0.007
1	10	7	-0.041	-0.029	17.977	0.012
1.	T T	8	-0.031	-0.018	18.181	0.020
1	L L L	9	-0.034	-0.028	18.435	0.030
1 1 1	I 🚺	10	0.061	0.079	19.254	0.037
1	1 🗖	11	0.283	0.261	36.981	0.000
1	I 🚺	12	0.203	0.063	46.148	0.000
1	1 📕	13	0.177	0.148	53.153	0.000
1 1 1	1	14	0.011	-0.052	53.180	0.000
1	10	15	-0.078	-0.029	54.537	0.000
1	T T	16	-0.058	-0.022	55.308	0.000
1 0 1	1	17	-0.091	-0.067	57.200	0.000
1	11	18	-0.070	-0.027	58.311	0.000
1	ГГ	19	-0.034	-0.006	58.570	0.000
1 L	l ili	20	-0.014	0.011	58.619	0.000

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) heterocesdasticidade, 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.		
С	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		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 freqüência 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
Ι	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, VZ3t	VZ1 t
VI	T_{t-1} , VZ2 t-1, VZ3t-1, Tt, VZ2 t, VZ3t	VZ1 t

Tabela C.1 Entradas e Saídas adotadas para o dreno "D191" danificado.

Modelos	Entradas	Saída
Ι	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, VZ3t	VZ2 _t
VI	T_{t-1} , VZ1 t-1, VZ3t-1, Tt, VZ1 t, VZ3t	VZ2 t

Tabela C.2 Entradas e Saídas adotadas para o dreno "D192" danificado.

Modelos	Entradas	Saída
Ι	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 Te		Teste	leste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL	
Ι	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	Aprendi	izado		Validaçã	ă0	Teste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL
Ι	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	084	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	Aprendi	zado		Validação Te		Teste	Feste		
	MAPE	RMSE	UTHEIL	MAPE	RMSE	MAPE	RMSE	UTHEIL	
Ι	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.