

Referências bibliográficas

- 1 International Energy Agency – Key World Energy Statistics 2007.
- 2 GUILHON, L.G.F.; ROCHA, V.F.; MOREIRA, J.C. Comparação de Métodos de Previsão de Vazões Naturais Afluentes a Aproveitamentos Hidroelétricos. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, 2007.
- 3 MACIEIRA, M.E.P.; DAMÁZIO, J.M.; GHIRARD, A.O.; DANTAS, H. Periodic ARMA Models Applied to Weekly Streamflow Forecasts. In: INTERNACIONAL CONFERENCE ON ELECTRIC POWER ENGINEERING. 1999, Budapest. **Anais...** Budapest: IEEE, Power Tech, 1999. P. 86-
- 4 DE CARVALHO, A.R.L.; COSTA, F.S.; DAMÁZIO, J.M.; GUILHON, L.G.F. Previsão de Vazões Diárias Através de uma Abordagem Estocástica – Modelo PREVIVAZH. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 14. 2001, Aracajú.
- 5 BOX, G.E.P.; JENKINS, G.M. and REINSEL, G.C. **Time Series Analysis: Forecasting and Control**. Prentice Hall, Englewood Cliffs, New Jersey, Third Edition.
- 6 BOX, G.E.P. e COX, D.R. An Analysis of Transformations. **Journal of the Royal Statistical Society**, A127, P. 211-252, 1964.
- 7 VALENÇA, M.J.S.; VASCONCELOS, G.C. Estudo Comparativo dos Modelos Box-Jenkins, Redes Neurais e Regressão Múltipla na Previsão de Vazões. In: SIMPÓSIO BRASILEIRO DE REDES NEURAS, 4. 1997, Goiânia. P. 55-57.
- 8 DANH, N.T.; PHIEN, H.N. AND GRUPTA, A. Neural network Models for River Flow Forecasting. **Water S A**, v.25, n.1, Tailândia, Janeiro de 1999.
- 9 LUDERMIR, T.; VALENÇA, M. Neural Networks vs. PARMA Modelling: Case studies of river flow prediction. In: BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS, 6. 2000, Rio de Janeiro. P. 113-116.
- 10 LUDERMIR, T.; VALENÇA, M. Monthly steamlow forecasting usin an Neural Fuzzy network Model, In: INTERNATIONAL JOIN CONFERENCE ON NEURAL NETWORKS. 2000, Italy. Anais do International Join Conference on Neural Networks, Montréal, Canada, 2000.
- 11 VALENÇA, M.; LUDERMIR, T. Neuroinflow: The New Model To Forecast Average Monthly Inflow. In: BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS, 7. 2002, Recife. P. 74.

- 12 ZAKERMOSHFEHGH, M.; GHODSIAN, M.; GH.A. MONTAZER, G.A. River Flow Forecasting using Artificial Neural Networks. **Hydraulics of Dams and River Structures**. Taylor & Francis Group, London, 2004.
- 13 KISI, O. Daily River Flow Forecasting Using Artificial Neural Networks and Auto-Regressive Models. **Turkish J. Eng. Env. Sci.** 29, 9-20. c TUB. ITAK, 2005.
- 14 HSU, K.; GUPTA, H.V. AND SOROOSHIAN, S. Artificial Neural Network Modeling of the Rainfall-Runoff Process. **Water. Resour. Res.**, 31, 2517-2530, 1995.
- 15 MASON, J.C.; TEM'ME, A. and PRICE, R.K. A neural network model of rainfall-runoff using radial basis functions. **J. Hydraul, Res.**, 34, P. 537-548, 1996.
- 16 MINNS, A.W. and HALL, M.J. Artificial neural networks as rainfall-runoff models. **Hydrolog. Sci. J.**, 41, P. 399-417, 1996.
- 17 SHAMSELDIN, A.Y. Application of a neural network technique to rainfall-runoff modelling. **J. Hydrol.**, (3-4), P. 272-294, 1997.
- 18 DIBIKE, Y.B. and SOLOMATINE D.P. River Flow forecasting Using Artificial Neural Networks. **Phys. Chem. Earth (B)**, 26, 1-7, 2001.
- 19 ANDREOLLI, I. **Previsão de Vazão em Tempo Real no Rio Uruguai com Base na Previsão Meteorológica**, Tese de Mestrado, UFRGS, 2003.
- 20 VALENÇA, M.; LUDERMIR, T.; VALENÇA, A. Modeling of the rainfall-runoff relationship with artificial neural network. In: INTERNATIONAL CONFERENCE ON HYBRID INTELLIGENT SYSTEMS (HIS). IEEE Computer Society, 6-9 Nov, Rio de Janeiro, Brazil, 2005b.
- 21 REIS, A.J.R. and SILVA, A.P.A. Aplicação da Transformada Wavelet Discreta Na Previsão De Carga A Curto Prazo Via Redes Neurais. **Revista Controle & Automação**, v. 15, n. 1, Jan, Fev e Março 2004.
- 22 CANNAS, B.; FANNI, A.; SIAS, G.; TRONCI, S.; ZEDDA, M. K. River flow forecasting using neural networks and wavelet analysis. **Geophysical Research Abstracts**, v. 7, 08651, 2005.
- 23 CHOU, S.C. Regional ETA Model. In **Climanálise – Boletim de Monitoramento e Análise Climática**. Edição Comemorativa de 10 anos. Instituto Nacional de Pesquisas Espaciais, INPE/CPTEC, Cachoeira Paulista, SP, 1996.
- 24 DAUBECHIES, I. **Ten Lectures on wavelets**, SIAM, Philadelphia, 1992.

- 25 HAGAN, M. and MENHAJ, M. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, novembro 1994.
- 26 TUCCI, C.E.M. **Modelos Hidrológicos**, 2^a ed., Editora da UFRGS - ABRH, 678 páginas, 2005.
- 27 UNIVERSIDADE FEDERAL DA BAHIA, Grupo de recursos Hídricos, Departamento de Hidráulica e Saneamento. **Apostila de Hidrologia**. Salvador (<http://www.ufpe.br/dcg/uploads/96a138bc-444a-9380.pdf>)
- 28 TODINI, E.: Hydrological Catchment Modeling: Past, Present and Future. **Hydrology & Earth System Sciences**, 11(1), 468-482, 2007.
- 29 MULVANY, T.J. On The Use Of Self Registering Rain And Flood Gauges. **Inst. Civ. Eng. Proc.** (Dublin), 4, 1-8, 1850.
- 30 ABBOTT, M.B.; BATHURST, J.C.; CUNGE, J.A.; O'CONNELL, P.E. and RAMUSSEN, J. An Introduction to the European Hydrological System – Système Hydrologique Européen, “She”, 1: History and Philosophy of a Physically-Based, Distributed Modeling System. **J. Hydrol.**, 87, 45-59, 1986a.
- 31 REFSGAARD, J.C. and STORM, B. Mike She (Chapter 23), In: **Computer models of watershed hydrology**, V.P. Singh (Ed.), Water Resources Publications, Littleton, Colorado, USA, 1995.
- 32 LIU, Z. and TODINI, E. Towards a comprehensive physically-based rainfall-runoff model. **Hydrol. Earth Syst. Sci.**, 6, P. 859-881, 2002.
- 33 SHERMAN, L.K. Streamflow from rainfall by the unit graph method. **Engineering News Record**, 108, P. 501-505, 1932.
- 34 HORTON, R.E. The Role of Infiltration In The Hydrological Cycle. **Transactions of American Geophysical Union**, 14, P. 446-460, 1933.
- 35 McCARTHY, G.T. **The unit hydrograph and flood routing**. US Corps Engrs Office, Providence, Rhode Island, USA, 1939.
- 36 ROCKWORD, D.M. Columbia Basin Streamflow Routing By Computer. **Journal of the Waterways and Harbors Division ASCE** , v. 84, NWW-5, 1958.
- 37 DUAN, D.; FERMINI, B. and NATTELI, S. Sustained Outward Current Observed after Ito1 Inactivation in Rabbit Atrial Myocytes Is a Novel Cl-current. **Am. J. Physiol.**, 263, P. 1967-1971, 1992.
- 38 SOROOSHIAN, S.; DAUN, Q. and GUPTA, V.K. Calibration of Rainfall-Runoff Models: Application of Global Optimization to the Sacramento Soil Moisture Accounting Model. **Water Resour. Res.**, 29, P. 1185-1194, 1993.

- 39 YAPO, P.; GUPTA, V.K. and SOROOSHIAN, S. Calibration of Conceptual Rainfall-Runoff Models: Sensitivity to Calibration Data. **J. Hydrol.**, 181, P. 23-48, 1996.
- 40 HSU, K.; GUPTA, H.V. and SOROOSHIAN, S. Artificial Neural Network Modeling of the Rainfall-Runoff Process. **Water. Resour. Res.**, 31, P. 2517-2530, 1995.
- 41 LINSLEY, R.K.; KOHLER, M.A. and PAULHUS, J.L. **Applied Hydrology**. MacGraw-Hill Book Co., Inc. New York, 1958.
- 42 TVA, Matrix Operations in Hydrograph Computations. Research Paper, n. 1, TENNESSEE VALLEY AUTHORITY, Knoxville, 1961.
- 43 DOOGE, J.C.I. Linear Theory of hydrologic Systems, Technical Bulletin n. 1948, ARS US DEPARTMENT OF AGRICULTURE, 1973.
- 44 CRAWFORD, M.; LINSLEY, R. Digital Simulation in Hydrology. Technical Report n. 39, DEPARTMENT OF CIVIL ENGINEER, Stanford University, 1966.
- 45 DAWDY, D.; O'DONNELL, T. Mathematical Models of Catchments Behavior. **J. Hydraulic Division**, ASCE HY4, 1965.
- 46 TUCCI, C.E.M.; ORDONEZ, J.S. e SIMÕES, M.L. Modelo Matemático Precipitação-Vazão IPH II Alguns Resultados. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 4. 1981, Fortaleza. **Anais...ABRH**.
- 47 LOPES, J.E.; BRAGA, B.F.F. e CONEJO, J.L. A Simplified Hydrologic Model in Applied Modeling in Catchment Hydrology. **Water Resources Publication**, 1982.
- 48 BEASLEY, D.B. e HUGGINS, L.F. Answers: User's Manual Chicago: U.S. ENVIRONMENTAL PROTECTION AGENCY 54 p, 1981.
- 49 ABBOT, M.B.; BATHURST, J.C.; CUNGE, J.A.; O'CONNELL, P.E. and RASMUSSEN, J. **An introduction to the European Hydrological System – Système Hydrologique Européen**, "SHE", 2: structure of a physically-based, distributed modelling system. **J. Hydrology**, 87, P. 61-77, 1986b.
- 50 GARCEZ, L.N. **Hidrogeologia**, Ed. Blucher Ltda, 1961.
- 51 SOUZA PINTO, N.; TATIT HOLTZ, A.C. e MARTINS, J.A. **Hidrologia de superfície**. Ed. Edgar Blucher, São Paulo, 180 pgs, 1973.
- 52 YEJVJEVICH, V.M. Structural Analysis of Hydrologic Time Series. **Hidrology Papers**, Colorado State University, Fort Collins, 1972
- 53 COSTA, F.S.; MACIEIRA, M.E.P. e DAMÁZIO, J.M. Modelos de Previsão Hidrológica Aplicados ao Planejamento da Operação do Sistema Elétrico

- Brasileiro. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, P. 21-30, jul/set 2007.
- 54 COSTA, F.S.; DAMÁZIO, J.M.; MACEIRA, M.E.P.; SOUZA, M.D.S.; GUILHON, L.G. e SILVA, S.B. Modelagem Estocástica de Previsão de Vazões Mensais: PREVIVAZM. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 15. Curitiba, 2003.
- 55 HIPEL, K.W.A. and MCLEOD, I. **Time Series Modelling of Water Resources and Environmental Systems**, Elsevier, 1994.
- 56 KELMAN, J.; DAMÁZIO, J.M. e COSTA, J.P. Geração de Séries Sintéticas de Vazões Diárias – Modelo Diana, **Revista Brasileira De Engenharia**. Caderno Recursos Hídricos, v. 1, n. 2, Brasil, 1983.
- 57 LOPES, J.E.; BRAGA, B.F.F. and CONEJO, J.L. A Simplified Hydrologic Model in Applied Modeling in Catchment Hydrology. **Water Resources Publication**, 1982.
- 58 BERTHELOT, R. **Curso de Hidrologia Sintética**. Porto Alegre, 1970. Mestrado em Hidrologia Aplicada . IPH – UFRGS, 1970.
- 59 http://www.wmo.ch/pages/prog/hwrrp/homs/sectionJ_en.html
- 60 BEVEN, K.; LAMB, R.; QUINN, P.; ROMANOWICZ, R. and FREER, J., **Topmodel in: Computer Model of Watershed Hydrology**. V.P. Singh (ed) Water Resources Publication. Fort Collins, 1994.
- 61 <http://www.weather.gov/iao/InternationalHydrologyCourseCD2/NWSRFSLarson/RFSMenu.html>
- 62 Projeto PreVIP: Modelo de Previsão de Vazões com Incorporação de Informações de Precipitação. ONS - PUC-Rio, 2005.
- 63 CHUNG, F-L. and DUAN, J-C. On Multistage Fuzzy Neural Network Modeling. **IEEE Transactions on Fuzzy Systems**, v. 8, P. 125-816, 2000.
- 64 SEBER, G.A F. and WILD, C.J. **Nonlinear Regression**; Wiley, 1989.
- 65 JANG, J.S.R. ANFIS: Adaptive-Network-Based Fuzzy Inference System – **IEEE Transactions on Systems**, Vol.23, No.3, pp.665-685. May/jun 1993.
- 66 MILLER, A J. **Subset Selection in Regression**. London, U. K. Chapman Hall, 1990.
- 67 McCULLOCH, W.S. and PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, 1943.
- 68 ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain.. **Psychol. Rev.**, 1958.

- 69 MINSK, M. and PAPERT, S. **Perceptrons: an introduction to computational geometry**. MIT Press, Massachusetts, 1969.
- 70 HOPFIELD, J.J. **Neural networks and physical systems with emergent collective properties**. Proc. Nat. Acad. Sci., 1982.
- 71 RUMELHART, D.E.; HINTON, G.E.; and WILLIAMS, R.J. **Learning representations by back-propagation erros**. Nature, 1986.
- 72 CYBENKO, G. Approximation by superposition of a sigmoidal function. **Math. Control Signals Syst.**, 2, 303-314, 1989.
- 73 OSÓRIO, F. e BITTENCOURT, J.R. Sistemas Inteligentes baseados em RNAs aplicados ao Processamento de Imagens. In: Workshop de Int. Artificial, 1. 2000, Santa Catarina. UNISC.
- 74 PRODUTO P4 – Relatório Final de Metodologia (Bacia Hidrográfica Itaipu) – **Projeto PreVIP: Modelo de Previsão de Vazões com incorporação de Informações de Precipitação**. ONS - PUC-Rio, 2005.
- 75 GRAPS, A. An Introduction to Wavelets. **IEEE Computational Science and Engineering**, Summer 1995, vol. 2, num. 2, published by the IEEE Computer Society.
- 76 GOLDENSTEIN, S. **Wavelets: Teoria, Software e Aplicações**. Instituto de Matemática Pura e Aplicada, 1995.
- 77 HUBBARD, B.B. **The world according to wavelets: the story of a mathematical technique in the making**. A K Peters, 1998.
- 78 MEYER, Y. Wavelets: Algorithms and Applications. **Society for Industrial and Applied Mathematics**, Philadelphia, P. 13-31, 101-105, 1983.
- 79 JAFFARD, S.; MEYER, Y. and RYAN, R.D. Wavelets: Tools for Science & Technology. **Society for Industrial and Applied Mathematics**, Philadelphia, P. 20-21, 2001.
- 80 MALLAT, S. A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. **IEEE Trans. Pattern Anal. Mach. Intell.**, P. 674-693, 1989.
- 81 GABOR, D. Theory of Communication. **Jour. Inst. Elect. Eng.**, 93(3): P. 429-457, 1946.
- 82 PARKER, J.R. **Algorithms for image processing and computer vision**. New York: John Wiley & Sons, 1997.
- 83 BURRUS, C.S.; GOPINATH, R.A. and GUO, H. **Introduction to wavelets and wavelets transforms: a primer**. New Jersey: Prentice Hall, 1998.

- 84 REIS, A.J.; ROCHA and SILVA, A.P. Aplicação da transformada wavelet discreta na previsão de carga a curto prazo via redes neurais. **Sba Controle & Automação**, Jan./Mar., v. 15, n.1, P.101-108. ISSN 0103-1759, 2004.
- 85 MISITI, M.; MISITI, Y.; OPPENHEIM, G. and POGGI, J.-M. **Wavelet Toolbox Manual . User's guide**. The Math Works Inc., USA, 1996.
- 86 PRODUTO P1 – Relatório de Análise dos Dados Pluviométricos e Fluviométricos da Bacia do Iguaçu – **Projeto PreVIP: Modelo de Previsão de Vazões com Incorporação de Informações de Precipitação**. ONS - PUC-Rio, 2005.
- 87 CANNAS, B.; FANNI, A.; SIAS, G.; TRONCI, S. and ZEDDA, M.K. River flow forecasting using neural networks and wavelet analysis. **Geophysical Research Abstracts**, v. 7, 08651, 2005.
- 88 PRODUTO P2 – Relatório de Análise dos Dados Pluviométricos e Fluviométricos da Bacia de Itaipu – **Projeto PreVIP: Modelo de Previsão de Vazões com Incorporação de Informações de Precipitação**. ONS - PUC-Rio, 2005.
- 89 HAYKIN, S. **Neural Networks – A Comprehensive Foundation**. Macmillan College Publishing Company, Inc, 1998.
- 90 HORNIK, K.; STINCHCOMBE, M. and WHITE, H. Multilayer Feedforward Networks Are Universal Approximators. **Neural Networks 2**, P. 359-366, 1989.
- 91 COULIBALY, P.; ANCTIL, F. and BOBE'E, B. Pre'vision hydrologique par re'seaux de neurones artificiels: e'tat de l'art" Can. **J. Civil Eng.**, 26, P. 293-304, 1999.
- 92 ZHANG, G.; PATUWO, B.E. and HU, M.Y. Forecasting With Artificial Neural Networks: The State of the Art. **Int. J. Forecasting**, 14, P. 35-62, 1998.
- 93 DEMUTH, H.; BEALE, M. and HAGAN, M. **Neural Network Toolbox . User's guide**. The Math Works Inc., USA, 2008.
- 94 MAIDMENT, D.R. **Handbook of Hydrology**, McGraw-Hill, New York, 1993.
- 95 STEYAERT, L. A Perspective on the State of Environmental Simulation Modeling. In: **Environmental Modeling with GIS**. Edited by Michael F. Goodchild, Bradley O. Parks and Louis T. Steyaert, P. 16-30, 1993.
- 96 Prechelt, L.. Automatic Early Stopping Using Cross Validation: Quantifying the Criteria. **Neural Networks**, v. 11, n. 4, P. 761- 767, 1998.

APÊNDICE 1

DEFINIÇÕES E MODELAGEM HIDROLÓGICA

Esta seção tem por objetivo esclarecer alguns termos hidrológicos usados amplamente no decorrer deste trabalho, além de esclarecer os principais aspectos numa modelagem hidrológica.

Definições Hidrológicas:

- Montante – posição relativa a uma referência, para o lado da nascente de uma corrente fluvial;
- Jusante – posição relativa a uma referência do lado para onde escoam as correntes fluviais;
- Descarga – o mesmo que vazão;
- Vazão natural – É a vazão que seria medida numa seção do rio, se não existissem reservatórios a montante. Vazão original do rio (em rios com barragens, só pode ser obtida por cálculos);
- Vazão incremental - contribuição dos rios que afluem a um reservatório (incremento sem controle);
- Vazão afluyente – vazão que aflui (chega) a uma determinada seção transversal de um rio ou a um reservatório.

Pelo acima exposto, pode-se concluir que a vazão natural incremental verificada, por exemplo, entre as UHE Porto Primavera, Rosana e Itaipu, é a vazão afluyente em Itaipu.

- Turbina – equipamento para gerar energia elétrica;
- Vertedouro – Estrutura destinada a escoar a água excedente de um reservatório, para controle de nível (funciona como um ladrão de caixa d'água).
- Escoamento (“Routing”) – Determinação do fluxo de saída de certo trecho de um canal, por meio dos valores conhecidos da vazão de entrada nesse trecho, usando a velocidade da onda e a equação de armazenamento (ou equação de continuidade). Técnica usada para computar o efeito de armazenagem e translação em um canal sobre o

formato e movimento de uma onda de cheia através de um comprimento definido de um rio.

Detalhes de um ciclo hidrológico

A figura a seguir mostra resumidamente os detalhes de um ciclo hidrológico.

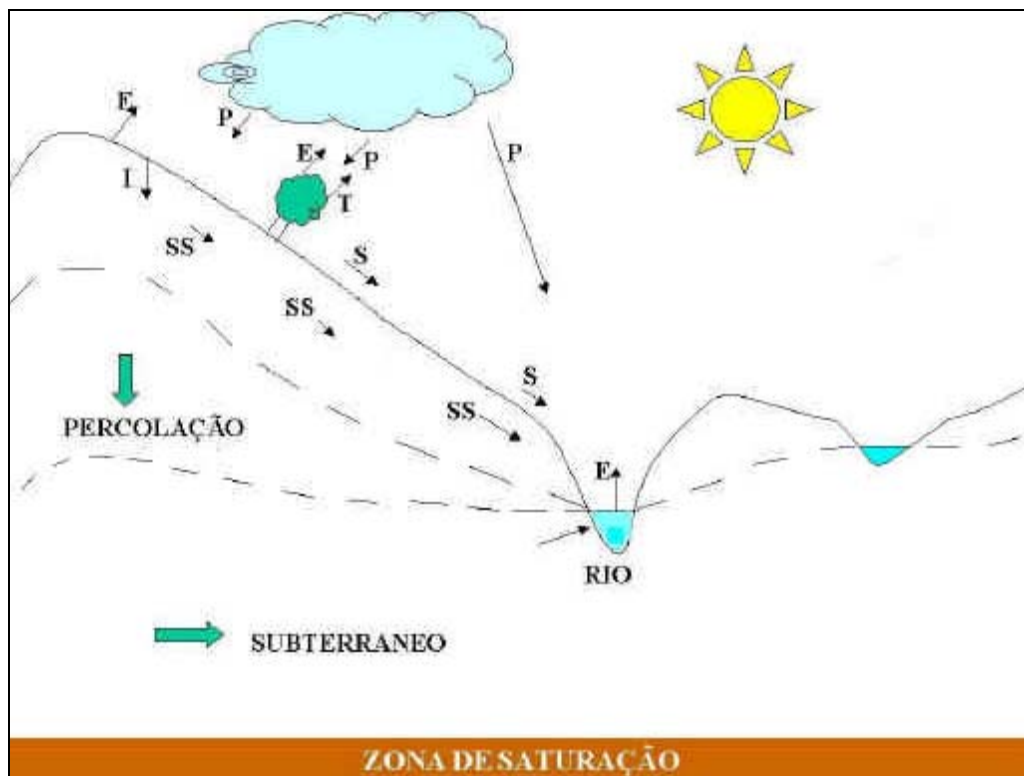


Figura A.1.1 Componentes de um ciclo hidrológico

Para quantificar as diversas parcelas que participam da composição da vazão num curso d'água, não se pode esquecer da precipitação direta sobre o rio e no solo da bacia, com a formação de um escoamento superficial S, um escoamento sub-superficial SS (formado pela infiltração I), um lençol freático ou subterrâneo (formado pela percolação), além da evaporação sobre os rios e lagos e as retiradas de água para os mais diferentes usos como a irrigação, o abastecimento e a dessedentação de animais. Os diversos fatores intervenientes na determinação das afluições num curso d'água são assim descritos:

- Declividade da Bacia: é um fator que influencia diretamente na velocidade da água e, portanto, na conformação da vazão em si. Esse fator sofre alterações periódicas devidas ao assoreamento e à erosão topográfica do curso d'água e das margens do rio, devendo ser reavaliado periodicamente.

- Evaporação: é importante quantificar a evaporação líquida nos reservatórios, isto é, a diferença entre a evaporação de lago atual e a evapotranspiração que havia antes da implantação do reservatório. Para tal, este fator é influenciado diretamente pela vegetação da bacia e da mata ciliar, o vento, a temperatura e umidade do ar e a temperatura da superfície do lago. Quantifica-se a água perdida para a atmosfera e, após algumas décadas, seja por modificação nas normais climatológicas, seja por mudanças climáticas significativas, este fator deve ser recalculado.

- Infiltração: é um fator associado fortemente ao uso do solo, isto é, bastante dependente da umidade, permeabilidade e temperatura da superfície do rio e da profundidade do trecho impermeável. Da mesma forma que a declividade, este fator também deve ser reavaliado periodicamente ou sempre que houver indícios de alteração destes parâmetros na bacia em estudo.

- Precipitação: É, sem dúvida, o principal fator interveniente na formação das vazões. É um fator extremamente dependente das normais climatológicas e das mudanças climáticas. É a variável que acaba imputando a característica aleatória no processo hidrológico.

- Recarga do Aquífero: mede a capacidade de retorno da água do lençol freático subterrâneo aos rios, lagos e lagoas. Este fator está diretamente ligado às mudanças nas camadas do solo e ao uso deste.

- Percolação: mede a capacidade do escoamento sub-superficial se tornar aquífero subterrâneo, ou seja, está diretamente ligado a dois fatores fundamentais, que são a formação geológica do solo e o uso desse solo tanto na composição da vegetação quanto na capacidade de permeabilização do mesmo.

Atentando para a figura A.1.1 e para as variáveis do ciclo hidrológico que influenciam diretamente nas vazões fluviais, e tendo em mente que muitas delas são mal medidas ou estimadas por métodos aproximativos, e outras bastante dinâmicas, percebe-se que o processo de obtenção/reconstituição de vazões nos trechos dos rios é um processo difícil e por muitas vezes caro, demorado e impreciso.

Classificação dos modelos hidrológicos:

Discussões sobre aspectos relacionados à classificação de modelos podem ser encontradas em Maidment [94] e Tucci [26].

Os modelos podem ser classificados sob diferentes aspectos. Comumente, os modelos são classificados, dentre outras formas, de acordo com o tipo de variáveis utilizadas na modelagem (estocásticas ou determinísticas), o tipo de relações entre essas variáveis (empíricos ou conceituais), a forma de representação dos dados (discretos ou contínuos), a existência ou não de relações espaciais (concentrados ou distribuídos), a existência de dependência temporal (estáticos ou dinâmicos), a existência ou não de memória (com memória ou sem memória) e quanto à linearidade (lineares ou não-lineares)

Um modelo é dito **estocástico** quando pelo menos uma das variáveis envolvidas tem comportamento aleatório. Por exemplo, o nível futuro de um reservatório depende da vazão afluente futura, que é uma variável aleatória com uma dada distribuição de probabilidade. Caso os conceitos de probabilidade sejam negligenciados durante a elaboração de um modelo, este será denominado **determinístico**. Nota-se, no entanto, que uma variável de entrada pode ser aleatória, mas o modelo ainda assim é determinístico quando cada valor de entrada produz um único valor de saída. Sistemas multivariados não-lineares podem levar a resultados caóticos que erroneamente são interpretados como variáveis aleatórias.

Os modelos podem ser **empíricos** ou “**caixa-preta**”, quando utilizam relações baseadas em observações. Eles ajustam os valores calculados às respostas desejadas por meio de uma equação que, geralmente, não tem relação com as leis que regem os processos do sistema. Em sua grande maioria, estes modelos são bastante simples e úteis no dia a dia. No entanto, são pouco robustos, uma vez que são específicos para aquela região para qual as relações foram estimadas. Além disso, os modelos empíricos não possibilitam fazer simulações de mudanças em condições para as quais o modelo não previu, tais como, chuvas extremamente altas, mudança de uso do solo, etc. Os modelos podem ser também baseados em processos – modelos **conceituais**. A definição de modelo conceitual é artificial, já que funções empíricas são também usadas (equações de Darcy, Horton, etc.), mas estão relacionadas com a física do sistema. Em geral, são mais complexos que os empíricos, uma vez que procuram descrever todos os processos que envolvem

determinado fenômeno estudado. Por exemplo, o cálculo da variação do nível do lençol freático é bastante complexo e tem a necessidade de envolver o uso de modelos detalhados e multivariados, que geralmente requerem um bom conjunto de informações e uma parametrização cuidadosa antes que possam ser executados.

Alguns autores utilizam uma subdivisão na classificação dos modelos conceituais: **semi-conceituais**, e **físicos** ou **físico-distribuídos**. Os primeiros se referem aos modelos que relacionam características do processo, mas mantêm um razoável empirismo nos parâmetros das equações envolvidas. Por sua vez, os físicos utilizam as principais equações diferenciais do sistema físico para representar os processos, e os seus parâmetros são os que mais se aproximam da física do sistema. As dificuldades dos modelos físicos têm residido sempre na variabilidade espacial dos processos e na dificuldade de estimar os parâmetros.

Apesar dos fenômenos naturais variarem continuamente no tempo, na maioria das vezes, estes fenômenos são representados por modelos **discretos**. A escolha do intervalo de tempo (passo) no qual o modelo será executado depende basicamente do fenômeno estudado, da disponibilidade de dados e da precisão desejada nos resultados. Em geral, quanto menor o intervalo de tempo, maior será a exatidão dos resultados, aumentando também o custo computacional para geração destes resultados.

Atualmente, dado que os computadores são intrinsecamente discretos, grande parte dos modelos também é discreta. Na prática, é comum coletar os valores de uma variável contínua em intervalos discretos. Um exemplo de registro de uma variável contínua em intervalos discretos são os níveis de um rio. Normalmente, estes níveis são registrados por um observador duas vezes ao dia. O registro contínuo deste mesmo procedimento é feito por um aparelho chamado linígrafo.

Os modelos podem ainda ser classificados como **concentrados** (em inglês “**lumped**”) ou **distribuídos**. Modelos concentrados são aqueles que não levam em consideração a variabilidade espacial das variáveis hidrológicas envolvidas no processo modelado. Nestes modelos a principal variável é o tempo. Na modelagem concentrada do processo chuva-vazão de uma bacia hidrográfica, por exemplo, todas as variáveis do sistema são avaliadas em termos da média espacial. Isto significa que chuva, evaporação, infiltração, vazões e outras variáveis são consideradas em termos médios na bacia. Considera-se que todas as

variáveis de entrada e saída são representativas de toda área estudada. Por outro lado, os modelos distribuídos consideram a variabilidade espacial encontrada nas diversas variáveis do modelo. De maneira geral, alguma discretização do espaço é feita e conseqüentemente cada elemento pode ser tratado como um ponto que representa homogeneamente toda sua área. Modelos distribuídos mais realísticos consideram também a existência de relação espacial entre elementos vizinhos.

Finalmente, os modelos podem ser **estáticos** quando, com um conjunto de dados de entrada produz-se um resultado oriundo da resolução das equações do modelo em um único passo. Já modelos **dinâmicos** utilizam o resultado de uma iteração como entrada para uma próxima iteração.

Os modelos geralmente descrevem processos com diferentes níveis de detalhamento e diferentes escalas de tempo. Um modelo pode ser detalhado, apropriado a pequenos intervalos de tempo e espaço, ou ser mais simples e genérico, podendo simular o comportamento de regiões inteiras e/ou períodos de tempo mais longos (décadas, séculos). De fato, muitos modelos trabalham em diferentes escalas espaciais e temporais. Alguns processos podem ser simulados considerando-se intervalos de tempo bastante pequenos (minutos, horas e dias) e escalas espaciais muito detalhadas (estômato, folha, planta), mas os resultados serem gerados para intervalos de tempo maiores (dias, meses, estações, anos, décadas) e escalas espaciais menos detalhadas (dossel, comunidade, região). A generalização espacial dos resultados pode ser conseguida por meio de técnicas de geoprocessamento e com o uso de dados de sensoriamento remoto [95].

A tabela A.1.1, a seguir, dá algumas características de modelos utilizados no gerenciamento dos recursos hídricos

Tabela A.1.1: Características de modelos usados no gerenciamento de recursos hídricos

Nome	Tipo	Estrutura	Características	Usos
Precipitação-vazão	Determinístico: empírico, conceitual	Comportamento	Calcula a vazão de uma bacia a partir da precipitação	Extensão de séries de vazão; dimensionamento; previsão em tempo real; avaliação do uso da terra
Vazão-vazão	Determinístico: empírico, conceitual	Comportamento	Calcula a vazão de uma seção a partir de um ponto a montante	Extensão de séries de vazão; dimensionamento; previsão de cheias
Geração estocástica de vazão	Estocástico	Comportamento	Calcula a vazão com base nas características da série histórica	Dimensionamento do volume de um reservatório
Fluxo saturado	Determinístico	Comportamento	Determina o movimento, vazão potencial de águas subterrâneas a partir de dados de realimentação, bombeamento, etc.	Capacidade de bombeamento; nível do lençol freático; iteração rio-aquífero
Hidrodinâmico	Determinístico	Comportamento	Sintetiza vazões em rios e rede de canais	Simulação de alterações do sistema; efeitos de escoamento de jusante
Qualidade de água de rios e reservatórios	Determinístico	Comportamento	Simula a concentração de parâmetros de qualidade da água	Impacto de afluentes; eutrofização de reservatórios; condições ambientais
Rede de canais e condutos	Determinístico	Comportamento e otimização	Otimiza o diâmetro dos e verifica as condições de projeto	Rede de abastecimento de água; rede de irrigação
Operação de reservatórios	Estocástico, determinístico	Comportamento e otimização	Determina a operação ótima de sistemas de reservatórios	Usos múltiplos
Planejamento e gestão de sistema múltiplos	Estocástico, determinístico	Comportamento, otimização e planejamento	Simula condições de projeto e operação de sistemas (usa vários modelos)	Reservatórios, canais, estações de tratamento, irrigação, navegação fluvial, etc

Segundo a literatura [26], modelos “precipitação-vazão” são aqueles que representam a parte do ciclo hidrológico entre a precipitação e a vazão, descrevendo a distribuição espacial da precipitação, as perdas por interceptação, evaporação, depressão do solo, infiltração, percolação e água subterrânea, escoamento superficial, sub-superficial e no rio.

APÊNDICE 2

MÉTODOS DOS POLÍGONOS DE THIESSEN

Polígonos de Thiessen são áreas de “domínio” de um posto pluviométrico. Considera-se que no interior dessas áreas a altura pluviométrica é a mesma do respectivo posto.

Os polígonos são traçados da seguinte forma:

- 1º. Dois postos adjacentes são ligados por um segmento de reta;
- 2º. Traça-se a mediatriz deste segmento de reta. Esta mediatriz divide para um lado e para outro, as regiões de “domínio”;

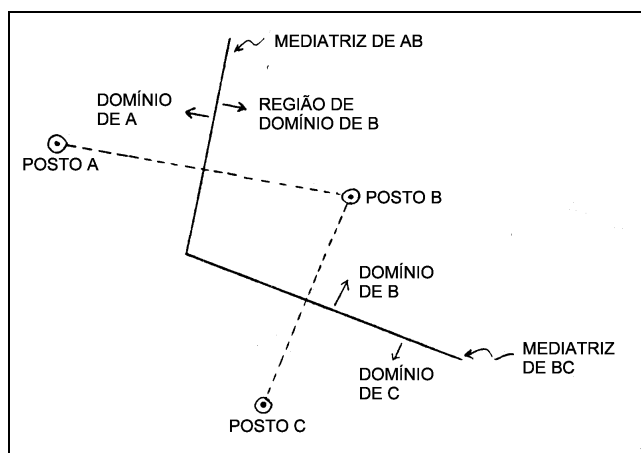


Figura A.2.1 Traçado da mediatriz

3º. Este procedimento é realizado, inicialmente, para um posto qualquer (ex.: posto B), ligando-o aos adjacentes. Define-se, desta forma, o polígono daquele posto;




Figura A.2.2 Definição do polígono de área

- 4°. Repete-se o mesmo procedimento para todos os postos;
- 5°. Desconsidera-se as áreas dos polígonos que estão fora da bacia;
- 6°. A precipitação média na bacia é calculada pela expressão:

$$\bar{P} = \frac{\sum_{i=1}^n A_i \bar{P}_i}{A}$$

onde \bar{P} é a precipitação média na bacia (mm), \bar{P}_i é a precipitação no posto i (mm), A_i é a área do respectivo polígono, dentro da bacia (km²) e A é a área total da bacia.

APÊNDICE 3

COMPLEMENTO DAS SÉRIES HISTÓRICAS DE CHUVAS

Para o caso particular de séries históricas de chuvas, o preenchimento das faltas efetuado neste trabalho, seguiu o método descrito através do exemplo abaixo, onde se muda os pesos de Thiessen dos postos que não apresentam falta de registro para um determinado dia.

Exemplo: Suponha que existam 5 postos pluviométricos na bacia X, e que seus pesos de Thiessen e chuvas registradas em 3 dias estejam registradas na tabela que segue.

Posto	Precipitação em mm			Peso
	Dia 1	Dia 2	Dia 3	
1	30,5	10,5	Falta registro	0,2
2	Falta registro	Falta registro	20	0,1
3	32	0	15	0,25
4	18	10	Falta registro	0,15
5	0	Falta registro	8	0,3

Como há falta de registros, os pesos diários serão ponderados pela soma dos pesos dos postos onde houve registro. Então, na realidade haverá um novo peso para cada dia, totalizando 15 novos pesos, conforme descrito a seguir:

Para o dia 1, os novos pesos serão:

$$\text{Posto 1: } \frac{0,2}{0,2 + 0,25 + 0,15 + 0,3} = \frac{0,2}{0,9} = 0,22; \text{ Posto 2: } 0 \text{ (pois não houve registro);}$$

$$\text{Posto 3: } \frac{0,25}{0,2 + 0,25 + 0,15 + 0,3} = \frac{0,25}{0,9} = 0,28;$$

$$\text{Posto 4: } \frac{0,15}{0,2 + 0,25 + 0,15 + 0,3} = 0,17;$$

$$\text{Posto 5: } \frac{0,3}{0,2 + 0,25 + 0,15 + 0,3} = 0,33.$$

Para o dia 2, os novos pesos serão:

$$\text{Posto 1: } \frac{0,2}{0,2 + 0,25 + 0,15} = \frac{0,2}{0,6} = 0,33; \text{ Posto 2: } 0 \text{ (pois não houve registro);}$$

$$\text{Posto 3: } \frac{0,25}{0,2 + 0,25 + 0,15} = \frac{0,25}{0,6} = 0,42; \text{ Posto 4: } \frac{0,15}{0,2 + 0,25 + 0,15} = 0,25;$$

Posto 5: 0 (pois não houve registro).

Para o dia 3 o raciocínio é análogo.

APÊNDICE 4

ALGORITMO DE LEVENBERG-MARQUARDT

Enquanto o backpropagation utiliza a descida de gradiente como método de aproximação do mínimo da função de erro, o algoritmo Levenberg-Marquardt é uma aproximação do método de Newton. Sendo uma determinada função $V(x)$ que se deseja minimizar com respeito a uma variável x (x pode ser um vetor de variáveis), então o método de Newton seria:

$$\Delta x = -[\nabla^2 V(x)]^{-1} \nabla V(x) \quad (1)$$

onde $\nabla^2 V(x)$ é a matriz hessiana e $\nabla V(x)$ é o gradiente de $V(x)$. Se for assumido que $V(x)$ é uma soma de quadrados:

$$V(x) = \sum_{i=1}^N e_i^2(x) \quad (2)$$

pode ser mostrado que:

$$\nabla V(x) = J^T(x) e(x) \quad \text{e} \quad \nabla^2 V(x) = J^T(x) J(x) + S(x) \quad (3) \text{ e } (4)$$

onde $J(x)$ é a matriz jacobiana:

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \dots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \dots & \frac{\partial e_N(x)}{\partial x_n} \end{bmatrix} \quad \text{e} \quad S(x) = \sum_{i=1}^N e_i(x) \nabla^2 e_i(x). \quad (5) \text{ e } (6)$$

Para o método de Newton-Gauss é assumido que $S(x) \approx 0$ e, então, (1) fica:

$$\Delta x = [J^T(x) J(x)]^{-1} J^T(x) e(x). \quad (7)$$

É feita, então, a modificação que resulta no cálculo de Δx pelo método de Levenberg-Marquardt:

$$\Delta x = [J^T(x) J(x) + \mu I]^{-1} J^T(x) e(x). \quad (8)$$

Se a nova soma dos quadrados dos erros para $x = x + \Delta x$ for maior que a antiga, ou seja, $V(x + \Delta x) > V(x)$, então μ é multiplicado por um fator β . Caso contrário, quando $V(x + \Delta x) < V(x)$, então divide-se μ por β .

APÊNDICE 5

MÉTODO DA PARADA ANTECIPADA (*EARLY STOPPING*)

Neste método, o conjunto de dados de treinamento é dividido em dois subconjuntos, um para estimação e outro para validação do modelo. Neste método, o treinamento é interrompido a cada atualização dos pesos sinápticos da rede neural e calculado o erro MAPE para o subconjunto de validação, permitindo que o seu desempenho em termos de generalização seja avaliado durante o treinamento.

Este conjunto de dados complementar é usualmente chamado de conjunto de *teste de generalização*. A figura A.5.1, abaixo, apresenta um gráfico típico da evolução do erro durante o aprendizado de uma rede neural, comparando a curva do erro (aprendizado supervisionado) referente à base de aprendizado com a curva do erro da base de teste de generalização.

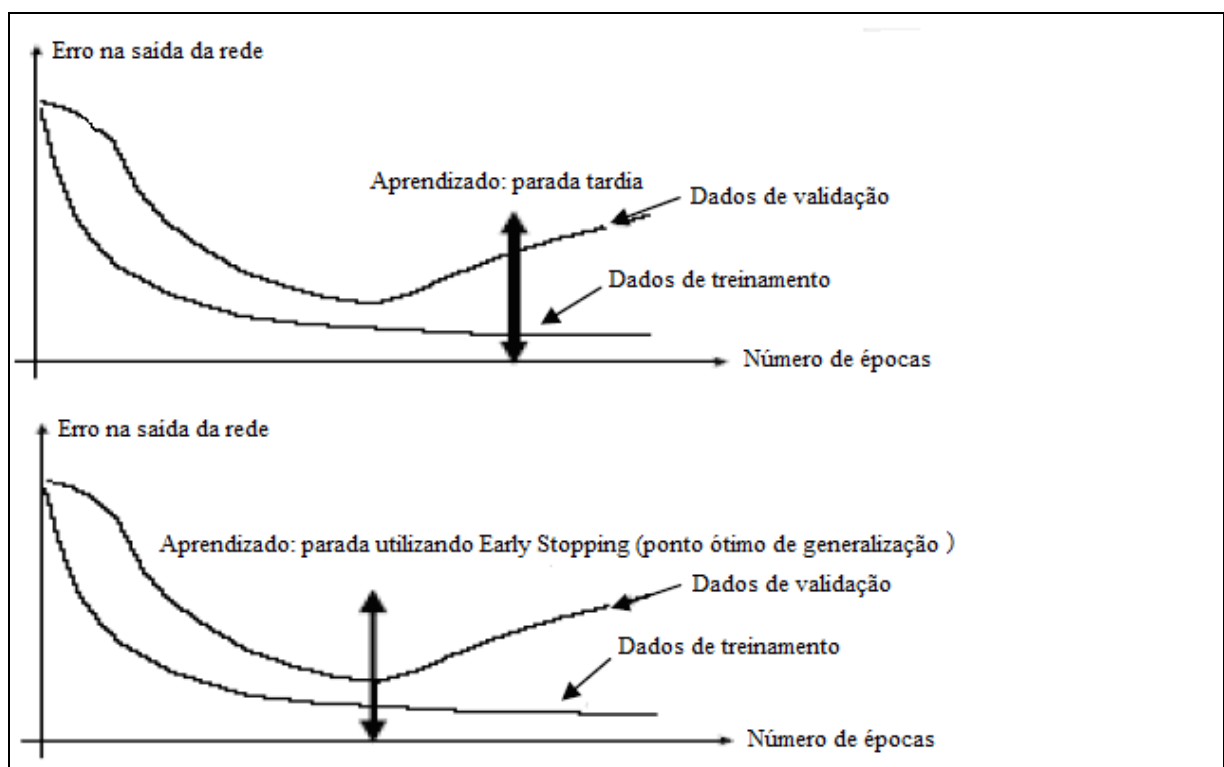


Figura A.5.1 Parada tardia e ponto ótimo de generalização

A utilização desses procedimentos diminui os problemas em relação ao sobre-treinamento da rede e conseqüentemente ameniza os efeitos das redes sobredimensionadas [96].

O treinamento usando *early stopping* deve ser interrompido quando o erro na validação começar a crescer de forma consistente.

Assim, para este método deve se dividir os padrões em três conjuntos:

- Treinamento – padrões usados para modificar os pesos;
- Validação – padrões usados para verificar o problema de overfitting;
- Teste – padrões para se testar o desempenho do modelo final.


Deve-se guardar duas cópias do conjunto de pesos da rede: uma cópia para o treinamento e outra com a melhor configuração na validação até o momento.

Após realizar a separação dos padrões em três partes (treinamento, validação e teste), todo o conjunto de dados de treinamento é apresentado à rede neural e ao final, são ajustados os pesos dos neurônios da camada escondida, conforme o método de aprendizado escolhido. Este processo é definido como uma *época*. A cada n épocas, a base de dados de validação é apresentada à rede treinada. Com os valores de saída da rede, após a base de dados de validação ter sido submetida à rede neural, é calculado o erro entre a saída da rede para os dados de validação e os dados reais (target). Este processo é repetido um número i de vezes. A rede neural (matriz de pesos) que apresentar o menor erro para o conjunto de validação, após as $i * n$ épocas, será a rede escolhida (nessa dissertação usou-se $n = 5$ e $i = 10$). Nesta dissertação este procedimento foi repetido 30 vezes para cada topologia (neste caso, topologia se refere ao número de neurônios na camada escondida).

APÊNDICE 6


GRAUS DE IMPORTÂNCIA EM RELAÇÃO AS 15 VARIÁVEIS DE SAÍDA

Gráfico/Tabela A.6.1: Graus de importância em relação à Vms1




1	2	3	4	5	6	7	8	9	10
0,176	0,297	0,126	0,088	0,036	0,048	0,059	0,030	0,086	0,049
0,028	0,549	0,016	0,391	0,014					
0,149	0,055	0,136	0,122	0,205	0,058	0,271			

Gráfico/Tabela A.6.2: Graus de importância em relação à Vms2




1	2	3	4	5	6	7	8	9	10
0,185	0,336	0,049	0,145	0,017	0,095	0,050	0,052	0,055	0,010
0,022	0,460	0,025	0,463	0,028					
0,149	0,077	0,170	0,135	0,176	0,116	0,174			

Gráfico/Tabela A.6.3: Graus de importância em relação à Vms3




1	2	3	4	5	6	7	8	9	10
0,172	0,317	0,066	0,183	0,010	0,136	0,025	0,063	0,001	0,023
0,028	0,305	0,042	0,577	0,046					
0,129	0,125	0,197	0,1414	0,150	0,158	0,097			

Gráfico/Tabela A.6.4: Graus de importância em relação à Vmd1



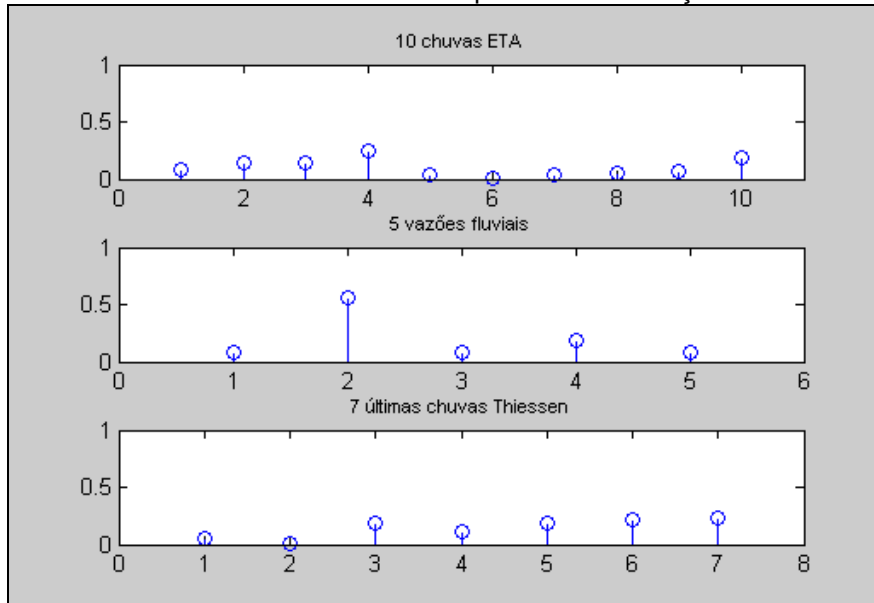
1	2	3	4	5	6	7	8	9	10
0,233	0,102	0,055	0,241	0,041	0,042	0,070	0,095	0,015	0,101
0,152	0,559	0,116	0,145	0,025					
0,158	0,047	0,189	0,243	0,118	0,163	0,078			

Gráfico/Tabela A.6.5: Graus de importância em relação à Vmd2



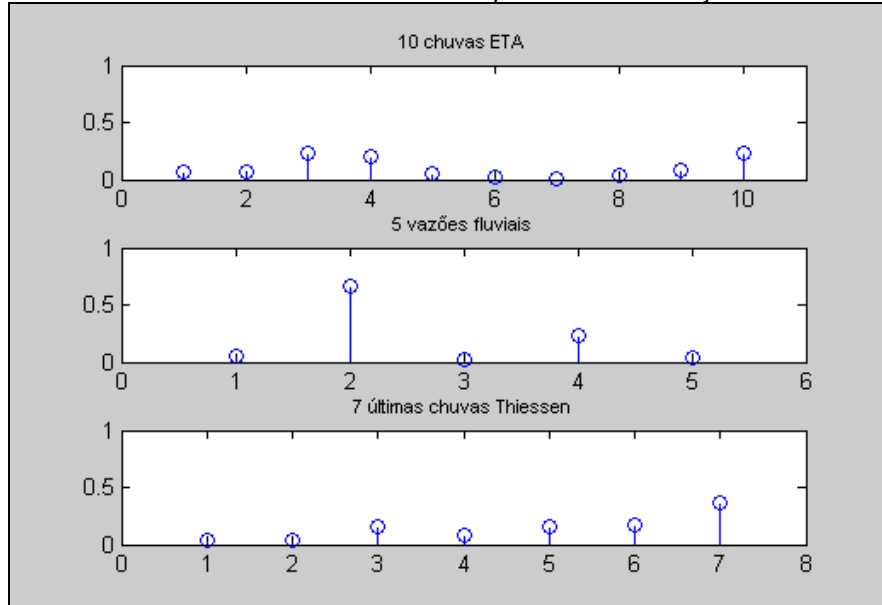
1	2	3	4	5	6	7	8	9	10
0,185	0,097	0,109	0,250	0,027	0,023	0,057	0,078	0,025	0,145
0,201	0,365	0,181	0,138	0,113					
0,123	0,041	0,170	0,197	0,180	0,253	0,032			

Gráfico/Tabela A.6.6: Graus de importância em relação à Vmd3




1	2	3	4	5	6	7	8	9	10
0,077	0,146	0,148	0,244	0,044	0,004	0,035	0,052	0,060	0,185
0,089	0,566	0,077	0,182	0,084					
0,056	0,008	0,188	0,114	0,183	0,222	0,226			

Gráfico/Tabela A.6.7: Graus de importância em relação à Vmd4




1	2	3	4	5	6	7	8	9	10
0,072	0,072	0,228	0,201	0,058	0,020	0,003	0,033	0,082	0,225
0,046	0,665	0,018	0,238	0,030					
0,036	0,035	0,154	0,077	0,154	0,176	0,365			

Gráfico/Tabela A.6.8: Graus de importância em relação à Vmd5




1	2	3	4	5	6	7	8	9	10
0,140	0,154	0,244	0,085	0,064	0,003	0,041	0,009	0,087	0,168
0,024	0,620	0,000	0,350	0,003					
0,171	0,086	0,006	0,078	0,153	0,106	0,396			

Gráfico/Tabela A.6.9: Graus de importância em relação à Vmd6




1	2	3	4	5	6	7	8	9	10
0,134	0,295	0,202	0,009	0,062	0,020	0,054	0,031	0,081	0,106
0,019	0,575	0,014	0,386	0,004					
0,201	0,032	0,197	0,021	0,156	0,081	0,308			

Gráfico/Tabela A.6.10: Graus de importância em relação à Vmd7




1	2	3	4	5	6	7	8	9	10
0,122	0,371	0,148	0,083	0,076	0,005	0,065	0,025	0,088	0,012
0,031	0,575	0,026	0,350	0,015					
0,108	0,071	0,234	0,156	0,218	0,033	0,177			

Gráfico/Tabela A.6.11: Graus de importância em relação à Vmd8




1	2	3	4	5	6	7	8	9	10
0,148	0,301	0,012	0,208	0,041	0,000	0,072	0,015	0,091	0,106
0,046	0,454	0,038	0,420	0,039					
0,069	0,108	0,172	0,212	0,157	0,149	0,130			

Gráfico/Tabela A.6.12: Graus de importância em relação à Vmd9




1	2	3	4	5	6	7	8	9	10
0,145	0,214	0,073	0,237	0,061	0,055	0,049	0,034	0,033	0,096
0,017	0,346	0,055	0,510	0,069					
0,085	0,109	0,150	0,232	0,113	0,223	0,085			

Gráfico/Tabela A.6.13: Graus de importância em relação à Vmd10




1	2	3	4	5	6	7	8	9	10
0,124	0,188	0,124	0,194	0,057	0,167	0,009	0,059	0,019	0,054
0,038	0,219	0,046	0,589	0,106					
0,150	0,136	0,108	0,179	0,111	0,253	0,059			

Gráfico/Tabela A.6.14: Graus de importância em relação à Vmd11



1	2	3	4	5	6	7	8	9	10
0,086	0,104	0,203	0,112	0,046	0,211	0,045	0,077	0,098	0,013
0,016	0,629	0,012	0,308	0,033					
0,141	0,186	0,112	0,037	0,110	0,275	0,135			

Gráfico/Tabela A.6.15: Graus de importância em relação à Vmd12



1	2	3	4	5	6	7	8	9	10
0,019	0,048	0,315	0,038	0,070	0,161	0,094	0,045	0,188	0,017
0,022	0,939	0,008	0,026	0,002					
0,020	0,263	0,167	0,162	0,078	0,153	0,154			

APÊNDICE 7

FUNÇÕES DE ATIVAÇÃO

Função Sigmóide:

Esta função, ao contrário da função limiar, pode assumir todos os valores entre 0 e 1. A representação mais utilizada para esta função é a função logística, definida por:

$$f(v) = \frac{1}{1 + e^{(-av)}}$$

Onde a é o parâmetro de inclinação da função sigmóide e v é o valor de ativação do neurônio.




Figura A.7.1:Gráfico da Função Sigmóide

Quando se aumenta o valor do parâmetro a , tendendo-o ao infinito, esta função comporta-se como uma função de limiar, como se pode observar no gráfico da figura A.7.2, a seguir:




Figura A.7.2: Gráfico da Função Sigmóide com a tendendo ao infinito

Tangente Hiperbólica:

Como a Função Logística, também possui forma de "s", assumindo valores entre 1 e -1, sendo representada por:

$$f(v) = a \frac{e^{(bv)} - e^{(-bv)}}{e^{(bv)} + e^{(bv)}}$$

Onde:

a é o parâmetro de inclinação da curva;

b são os limites inferiores e superiores ($b = |I|$ no gráfico);

v é o valor de ativação da unidade.




Figura A.7.3: Gráfico da Função Tangente Hiperbólica

APÊNDICE 8

SIMULAÇÃO COM E SEM WAVELET

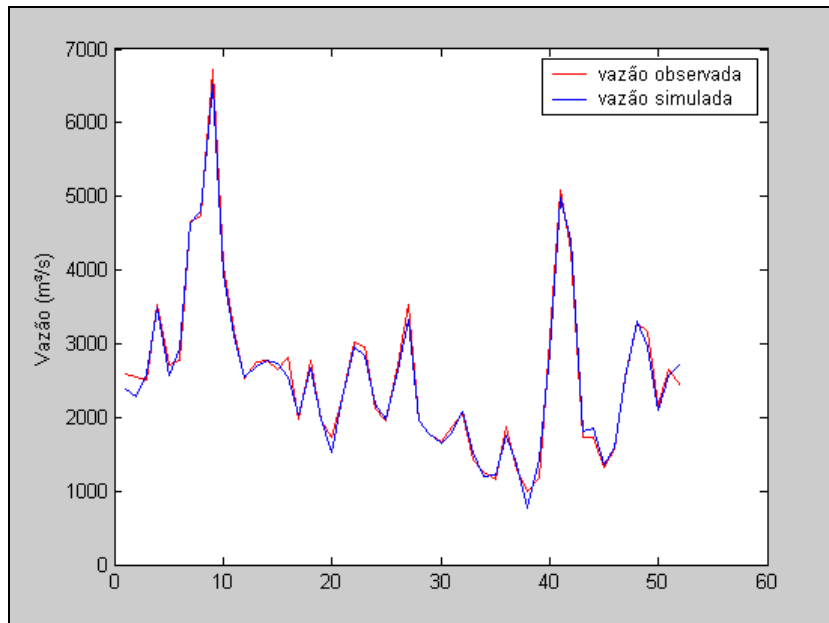


Figura A.8.1: Vazões observada e simulada de Vmd2 com wavelet




Figura A.8.2: Vazões observada e simulada de Vmd2 sem wavelet

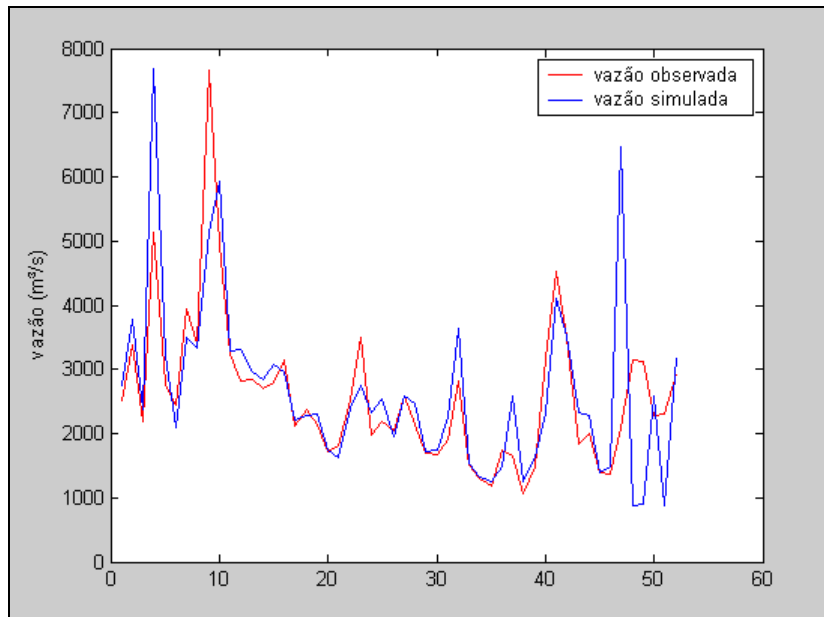


Figura A.8.3: Vazões observada e simulada de Vmd4 com wavelet




Figura A.8.4: Vazões observada e simulada de Vmd4 sem wavelet




Figura A.8.5 Vazões observada e simulada de Vmd11 com wavelet

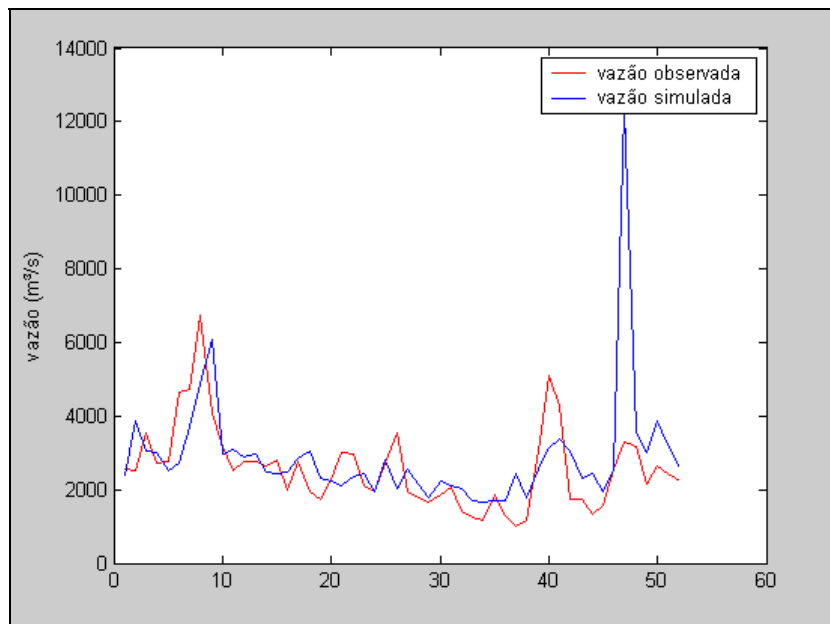


Figura A.8.6 Vazões observada e simulada de Vmd11 sem wavelet

APÊNDICE 9

MÉTRICAS DE ERRO

O Índice MAPE (“*Mean Absolute Percentage Error*”) é definido por:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \frac{|Vp_t - Vo_t| \times 100}{Vo_t}$$

O RMSE (“*Root Mean Square Error*”) é definido por:

$$RMSE (m^3/s) = \frac{1}{N} \left[\sum_{t=1}^N (Vp_t - Vo_t)^2 \right]^{0,5}$$

O MAE (“*Mean Absolute Error*”) é definido por:

$$MAE (m^3/s) = \frac{1}{N} \sum_{t=1}^N |Vp_t - Vo_t|$$

Vp_t = vazão prevista no instante t ;

Vo_t = vazão observada no instante t ;