

## MODELAGEM DE SÉRIES HIDROLÓGICAS ATRAVÉS DE REDES DE NEURÔNIOS

**Francisco Jácome Sarmiento**

*Colaborador da Universität Hannover  
Inst. für Wasserwirtschaft, Hydrologie und landwirtschaftl. Wasserbau  
Appelstrasse 9A  
30167 - Hannover - Deutschland / Fax : 0049 511 762 3731*

### RESUMO

No presente artigo é feita inicialmente uma sucinta classificação das redes de neurônios artificiais no âmbito da Teoria Geral dos Sistemas.

Em seguida é apresentada a formulação matemática básica da categoria denominada redes cibernéticas, sob a ótica da otimização dos parâmetros. Algoritmos de otimização local e global e sua eficiência para a finalidade considerada são também comentados bem como aspectos relacionados com a definição da arquitetura das redes em função da natureza do problema a ser modelado.

Com o objetivo de demonstrar a possibilidade de uso desta técnica na modelagem de variáveis hidrológicas são apresentadas duas aplicações, as quais consistem na simulação da relação chuva-vazão a nível mensal em uma bacia da região semi-árida do Nordeste do Brasil e na previsão de vazões médias diárias com intervalos de 1 e 2 dias fazendo uso das séries fluviométricas da bacia do rio Leine (região central da Alemanha). Na primeira aplicação a série histórica de vazões disponível é dividida em duas sub-séries, usadas para o treinamento e validação da rede. Os resultados obtidos na validação são comparados com os correspondentes advindos da calibração do modelo chuva-vazão MODHAC. Na segunda aplicação as vazões médias diárias para um posto de jusante são previstas com o intervalo de tempo especificado em dias tendo como base as vazões médias diárias registradas em dois postos localizados a montante, além da vazão

atual no próprio posto para o qual realiza-se a previsão.

A qualidade dos resultados obtidos enfatiza a propriedade das redes de perceptrons como aproximadores universais.

### HISTÓRICO E CLASSIFICAÇÃO

As redes de neurônios artificiais (RNA) foram desenvolvidas em analogia com as redes de neurônios biológicas. Os estudos que levaram a sua criação começaram há pouco mais de 50 anos, sendo o trabalho de McCulloch e Pitts (1943) apontado como contribuição pioneira para este ramo de pesquisa, cujo desenvolvimento foi inicialmente motivado pelo desejo de tentar entender e emular sob uma abordagem matemática algumas características do cérebro humano.

Desde a sua criação muitas aplicações têm sido apresentadas, principalmente na área de previsão de índices financeiros (ver por exemplo Hoptroff, 1993). Os estudos realizados sobre séries de tempo tem levado a um crescente desenvolvimento de modelos de previsão não lineares para processos estocásticos (por exemplo, Reininger e Wolf, 1990). As RNA's têm também sido aplicadas tanto na identificação de comportamento caótico de sistemas dinâmicos pela estimativa dos expoentes de Lyapunov (Nychka, et al., 1992) como na reconstrução de atratores identificados em tais sistemas (Grieger e Latif, 1993).

As redes de neurônios artificiais constituem uma poderosa alternativa na modelagem matemática de sistemas que envolvem transformações não lineares. Em comparação com os modelos estatísticos



lineares convencionais bastante utilizados em estudos hidrológicos, as redes têm apresentado resultados no mínimo em igual nível que os apresentados por aqueles modelos (Grieger e Latif, 1993). As possibilidades de aplicação deste método no ramo da Hidrologia são muitas, como por exemplo na operação de reservatórios em tempo real, como ferramenta alternativa na construção de programas especialistas destinados a apoiar as decisões no gerenciamento de recursos hídricos, na previsão de eventos extremos como secas e cheias, etc.

No atual estágio de desenvolvimento a teoria das RNA's apresenta três grandes ramos associados com os modelos da Teoria Geral dos Sistemas que tratam da não linearidade, são eles: Redes Cibernéticas (Rosenblatt, 1958), Memória Associativa (Hopfield, 1982) e modelos biológicos (Carpenter e Grossberger, 1985).

As redes cibernéticas, a serem aqui tratadas, têm seu conceito de desenvolvimento analogamente associado com a propriedade do sistema nervoso central de aprender reações face a estímulos externos em um ambiente hostil. A possibilidade de aplicação deste tipo de RNA como ferramenta matemática capaz de representar as relações dinâmicas não lineares entre variáveis hidrológicas será aqui investigada.

## COMPONENTES TOPOLÓGICOS DE UMA RNA

Tendo sido o princípio de funcionamento das redes de neurônios biológicas o modelo de construção das RNA's, ambas constituem sistemas de processamento de informações que possuem várias características em comum. Alguns componentes básicos de um neurônio biológico relacionados com o fluxo de informações são relevantes para o entendimento do funcionamento das RNA's: os detritos, que recebem os impulsos elétricos

transmitidos pelos outros neurônios; a sinapse, que através de processos químicos transmite esses impulsos, o corpo da célula, que recolhe os sinais recebidos e em função da sua magnitude retransmite-o para as outras células através do Axon.

O desenvolvimento das redes de neurônios artificiais (RNA) como versões generalizadas de modelos matemáticos de representação das propriedades de aprendizado do cérebro humano baseia-se em prerrogativas fundamentais análogas: a) a informação é processada em um elemento singular (o neurônio) que transforma o sinal recebido e o retransmite, a propriedade biológica equivalente é emulada aqui por um parâmetro que, conjugado com uma função de ativação (geralmente não linear), estabelece o limite a partir do qual o sinal é retransmitido; b) essa informação ou sinal é transmitida entre neurônios através de ligações entre estes; c) cada ligação possui um fator de ponderação ou peso associado, que nas equações aparece geralmente como coeficiente de multiplicação do sinal transmitido.

As RNA's são basicamente caracterizadas pela sua arquitetura e função de ativação usada no processamento do sinal. A arquitetura das RNA's é determinada pela disposição dos neurônios e suas interligações. No caso dos perceptrons (redes cibernéticas) a disposição destes é feita em camadas, que no mínimo são em número de 2: uma que recebe o estímulo externo (input) formada pelos chamados neurônios sensores (retina) e uma outra (output) que transforma o sinal, causando a reação desejada. O fluxo de informação aqui ocorre em um único sentido, podendo ainda a rede apresentar uma ou mais camadas intermediárias de neurônios, chamadas camadas escondidas que assim como a camada-output compõe-se de neurônios-motores que processam e retransmitem o sinal.

As funções de ativação podem ser de diversos tipos. Muitas aplicações utilizam a função sigmóide representada pela equação abaixo cuja faixa de variação de valores



assumidos está restrita ao intervalo (0,1). Em geral a adoção de uma determinada função de ativação depende do problema a ser modelado.

$$f(x) = 1 / [1 + \exp(-x)]$$

## EQUACIONAMENTO BÁSICO

Considerando a rede de perceptrons mostrada na Figura 1 com uma camada de neurônios intermediária, a equação representativa da transformação efetuada sobre o vetor-input  $X(x_1, x_2, \dots, x_n)$  no espaço  $R^n$  que leva ao vetor  $Y(y_1, y_2, \dots, y_m)$  no espaço  $R^m$  é dada por:

$$Y = F(X)$$

Uma componente  $k$  qualquer do vetor  $Y$  é determinada como uma combinação linear das componentes do vetor  $H$  como sendo:

$$y_k = f\left(\sum_{i=1}^I w_{j,k}^o h_i - w_k^b\right), k = 1, 2, \dots, m$$

onde  $w_{j,k}^o$  representa o peso para a ligação entre o neurônio  $j$  na camada intermediária e o neurônio  $k$  na camada-output,  $w_k^b$  é o parâmetro que controla a retransmissão de informação e  $f$  é uma função definida em  $R^1$  para  $R^1$ . De uma maneira análoga as componentes do vetor  $H$  podem ser determinadas em função dos parâmetros da primeira camada como sendo:

$$h_j = f\left(\sum_{i=1}^n w_{i,j}^1 x_i - w_j^b\right), j = 1, 2, \dots, I$$

onde  $w_{i,j}^1$  representa o peso para a ligação entre o neurônio  $i$  na camada sensitiva para o nó  $j$  na camada intermediária.




Figura 1. Rede de Perceptrons com três camadas.

## O processo de aprendizado

Na modelagem dos problemas reais o que se dispõe em termos de dados de entrada são um vetor  $X$ , cujo número de componentes determina a complexidade do problema (expresso como número de graus de liberdade) e um determinado vetor  $D$ , que representa uma série de valores medidos e são o resultado das transformações não lineares que o sistema tratado realiza sobre  $X$ . Os parâmetros devem ser determinados de tal forma que o vetor  $Y$  (componentes calculadas pela rede) seja o mais próximo possível do vetor  $D$  (componentes medidas), ou seja, tal que o erro entre  $Y$  e  $D$  seja mínimo; trata-se portanto de um problema de otimização no hiper-espaço.

Considerando como hipótese um único par de vetores  $(X,D)$  como disponíveis para a chamada fase de treinamento da rede, o erro, como função de um conjunto de parâmetros  $W$  (pesos entre as ligações entre os diversos neurônios que compõem a rede) a ser otimizado, é dado por:

$$e(W) = \frac{1}{2} \|D - Y(W)\|^2 = \frac{1}{2} \sum_{k=1}^m [d_k - y_k(W)]^2$$

A equação acima representa a função objetivo para a qual se deseja determinar o ponto de mínimo. O método mais comum utilizado para essa finalidade é o chamado algoritmo de propagação regressiva dos erros (backward propagation) (Rumelhard e



McClelland, 1986), que corrige iterativamente  $W$  com base no erro entre os valores calculado e observado. Trata-se de um algoritmo do tipo gradiente descendente para o qual o processo de busca do ponto de mínimo parte de um ponto aleatoriamente escolhido e usa para as iterações seguintes o gradiente da função objetivo para identificar a sua direção de maior decrescimento. Assim a matriz  $W$  para o próximo ciclo no processo de treinamento é dada por:

$$[W]_{i,j} = [W]_i + \eta(-grad_w e(W)) \quad (1)$$

onde  $\eta$  é um parâmetro que determina o passo de avanço na direção de decrescimento da função objetivo. No treinamento da rede é evidente que quanto maior o número de pares  $(X,D)$  utilizados, mais eficiente pode se tornar a modelagem. Considerando um número  $n$  de pares  $(X,D)$ , a função erro total a ser minimizada é dada por:

$$E(W) = \sum_{i=1}^n \left\{ \frac{1}{2} \sum_{k=1}^m [d_{i,k} - y_{i,k}(W)]^2 \right\} \quad (2)$$

## Algoritmos de otimização

Funções objetivo como a equação (2) podem apresentar muitos mínimos locais (funções multi-modais) o que devido à natureza de busca dos métodos do gradiente descendente pode tornar ineficiente o algoritmo de propagação regressiva dos erros. Convém neste caso a aplicação de métodos de otimização mais eficientes, como por exemplo: os métodos de gradiente conjugado (Hestenes, 1980), métodos dos anéis simulados (Laarhoven e Aarts, 1987; Corana et al., 1987) ou métodos baseados em otimização genética (Goldberg, 1989; Holland, 1992; Davis, 1991).

Embora os métodos de otimização baseados no gradiente conjugado sejam mais rápidos que os de gradiente descendente, apresentam também a desvantagem de possibilidade de convergência para mínimos

locais. Os métodos dos anéis simulados são otimizadores globais, mas apresentam a desvantagem de serem muito lentos.

A categoria de algoritmos denominados genéticos constitui uma alternativa de otimização global de funções multimodais. Assim como as RNA's esses algoritmos tiveram sua origem em analogias com processos biológicos, sendo aqui o cromossomo e suas propriedades básicas de divisão e mutação, fundamentais para a compreensão da operação de busca do mínimo global. Neste contexto, as informações representadas pelas componentes dos vetores relacionados com a função objetivo são codificadas em forma de cadeias binárias (cromossomos artificiais). Porém em problemas hiper-dimensionais tais como o treinamento de RNA's, os cromossomos podem apresentar cadeias muito longas, tornando a otimização lenta. O que pode ser bastante conveniente é a utilização conjunta de tais métodos com algoritmos locais, aplicando os primeiros como direcionadores iniciais na busca do mínimo global para em seguida aplicar um método, como por exemplo o de propagação regressiva dos erros, para um refinamento da solução.

## APLICAÇÃO

No que concerne a modelagem de séries hidrológicas as aplicações mais recentes estão relacionadas com a previsão de demanda d'água onde as RNA's são combinadas com regras da Lógica Fuzzy (Muster et al., 1994), modelagem estocástica de precipitações (Bardossy et al., 1993), operação otimizada de reservatórios (Weijun e Jing, 1994) e modelagem da condutividade hidráulica em aquíferos (Ranjithan et al., 1993).

A primeira aplicação a ser aqui realizada consiste na reprodução através de uma RNA da relação chuva-vazão para uma bacia localizada na região semi-árida do Nordeste brasileiro, onde a modelagem desse



fenômeno de transformação se torna bastante complexa entre outras razões em função do caráter convectivo dominante nas precipitações da região.

Na segunda aplicação é investigada a habilidade das redes de perceptrons para a previsão de vazões médias diárias na bacia do rio Leine, localizada na região central da Alemanha. Previsões de 1 e 2 dias foram realizadas para o posto Herrenhausen (área de drenagem  $> 3500 \text{ km}^2$ ) a partir da vazão atual naquele posto e nos postos de Popenburg (área de drenagem  $> 2500 \text{ km}^2$ ) e Greene (área de drenagem  $> 2300 \text{ km}^2$ ) localizados a montante.

### Definição da arquitetura das redes

A arquitetura adequada de uma RNA para a modelagem de determinado sistema é aquela que com o menor número possível de neurônios é capaz de reproduzir a relação entre as variáveis envolvidas, com um erro dentro de um limite aceitável. A definição do número de neurônios para as camadas input e output depende do tipo de problema tratado. No caso de fenômenos com muitos graus de liberdade uma análise fatorial de componentes principais pode levar à definição da dimensão do espaço R, cujos eixos correspondem às variáveis que explicam a maior parte da variância do sistema. Na modelagem de sistemas que apresentam uma dinâmica caótica, o número de neurônios nas camadas de input e output correspondem geralmente à dimensão do espaço de fase.

Com relação às camadas intermediárias o procedimento recomendável consiste em experiências com diferentes números de neurônios e observação do comportamento dos erros. Principalmente na modelagem de séries de tempo deve ser observada a regra da necessidade de que a rede tenha o menor número possível de neurônios na camada intermediária, pois o número de parâmetros cresce numa proporção maior e a rede pode apresentar tendência a reproduzir em parte as forças estocásticas.

Nos exemplos a serem aqui apresentados a arquitetura da rede foi definida basicamente por tentativa e erro. No caso da camada-input é muito importante ressaltar que o número de neurônios que a irá compor corresponde teoricamente ao número de variáveis que influenciam no fenômeno em foco, devendo-se portanto manter uma certa coerência com o processo físico quando da determinação deste número, para não incorrer no erro de se incluir entre os valores de entrada variáveis sem influência determinante no sistema modelado.

### Relação chuva-vazão

O problema consiste na determinação da vazão média mensal para a bacia controlada pelo posto Faz. Cajazeiras (área de drenagem:  $1150 \text{ km}^2$ ) localizada no estado do Ceará. A série de vazões disponível é descontínua e apresenta dois intervalos de medições: 1964-70 (84 meses) e 1974-80 (84 meses). O primeiro período foi usado na fase de treinamento com o algoritmo de propagação regressiva dos erros, o segundo foi usado para a validação.

Em consequência da alta variabilidade das precipitações na região (origem convectiva) e da qualidade dos dados disponíveis adotou-se como dado de entrada para a rede, além da precipitação mensal correspondente ao mês para o qual se deseja calcular a vazão média mensal, as precipitações ocorridas nos dois meses anteriores, totalizando assim três neurônios na camada de entrada. O número de neurônios na camada intermediária foi determinado por tentativas, tendo-se obtido melhores resultados para 4 neurônios.

A Figura 2 mostra os resultados obtidos na fase de treinamento na rede. A validação da RNA para o período 1974-79 é mostrada na Figura 3a e na Figura 3b é apresentada uma calibração do modelo chuva-vazão MODHAC (Lanna e Schwarzbach, 1988) com passo de cálculo diário, para o mesmo período.




Figura 2. Treinamento da rede. Período 1964-69. Posto Faz. Cajazeiras.






Figura 3. a) Validação da rede para o período 1974-79. Posto Faz. Cajazeiras.




Figura 3. b) Calibração do MODHAC para o período 1974-79. Posto Faz. Cajazeiras.



A Figura 4 mostra a diferença absoluta entre os valores calculados e observados para o mesmo período para as situações mencionadas nas Figuras 3a e 3b. Os erros absolutos médios no referido período foram de 18,3 mm e 21,8 mm para a validação da rede e calibração do MODHAC, respectivamente.




Figura 4. Erro absoluto entre os valores calculados e observados para os meses chuvosos no período 1974-1979 mostrado nas Figuras 3a e 3b.

Um princípio elementar do uso das RNA's na modelagem de séries hidrológicas consiste na necessidade de se dispor de séries de tempo que envolvam eventos hidrológicamente heterogêneos. A ocorrência de eventos extremos no período de validação sem par no período de calibração conduz a erros consideráveis como é o caso da cheia de 1974 no Nordeste. A rede não pode reproduzi-los se ela não foi treinada com eventos semelhantes.

### Previsão de vazões médias diárias

Conforme ressaltado, as previsões consideraram além da vazão média diária no posto de jusante (Herrenhausen), as vazões em outros dois postos de jusante, totalizando assim 3 neurônios na camada input. A camada output possui apenas 1 neurônio, correspondente a vazão prevista para o posto Herrenhausen. O número de neurônios na camada intermediária foi determinado por tentativas, tendo se mostrado mais adequado um número de 4 neurônios.

A rede foi treinada com o algoritmo de propagação regressiva dos erros com a série

de vazões médias diárias de 1951 a 1971. Na validação tomou-se o período de 1972 a 1980. O erro médio relativo de previsão com 1 dia de antecedência foi inferior a 6%, para 2 dias 13%. As Figuras 5a e 5b mostram a performance da rede na previsão de um dia de antecedência para eventos nos quais o pico de vazões foi maior do que 3 vezes a média. A previsão para 2 dias para os mesmos eventos pode ser observada nas Figuras 6a e 6b.

### CONCLUSÕES

É sempre importante ressaltar que a aplicação de RNA's na modelagem de fenômenos naturais encontra justificativa mais consistente naqueles casos para os quais não se dispõe de uma formulação matemática explícita, capaz de reproduzir as relações entre as diversas variáveis envolvidas. Para o primeiro exemplo aqui mostrado, em momento algum propõe-se uma avaliação comparativa do modelo MODHAC com as redes de neurônios, pois estas, em sua estruturação teórica, ao contrário do MODHAC, nada têm a ver com a modelagem física do problema, e neste caso apresentado, tão pouco contribuem para entendimento do complexo fenômeno de transformação de chuva em vazão. A comparação entre os resultados gerados por um e outro método, objetiva apenas enfatizar o potencial das redes de neurônios como aproximadores universais.

Nas aplicações deste método para variáveis hidrológicas como chuva e vazão em regiões semi-áridas a extensão da série requerida para a fase de treinamento da rede é bastante superior àquela que seria adequada para bacias de rios perenes, pois tais séries hidrológicas de regiões semi-áridas apresentam uma notória concentração de chuvas e vazões em um único semestre, enquanto que para o restante do ano observam-se praticamente valores nulos. Na aplicação aqui apresentada uma considerável parcela das séries de chuva e vazão observadas consistem de valores nulos, ou seja, na fase



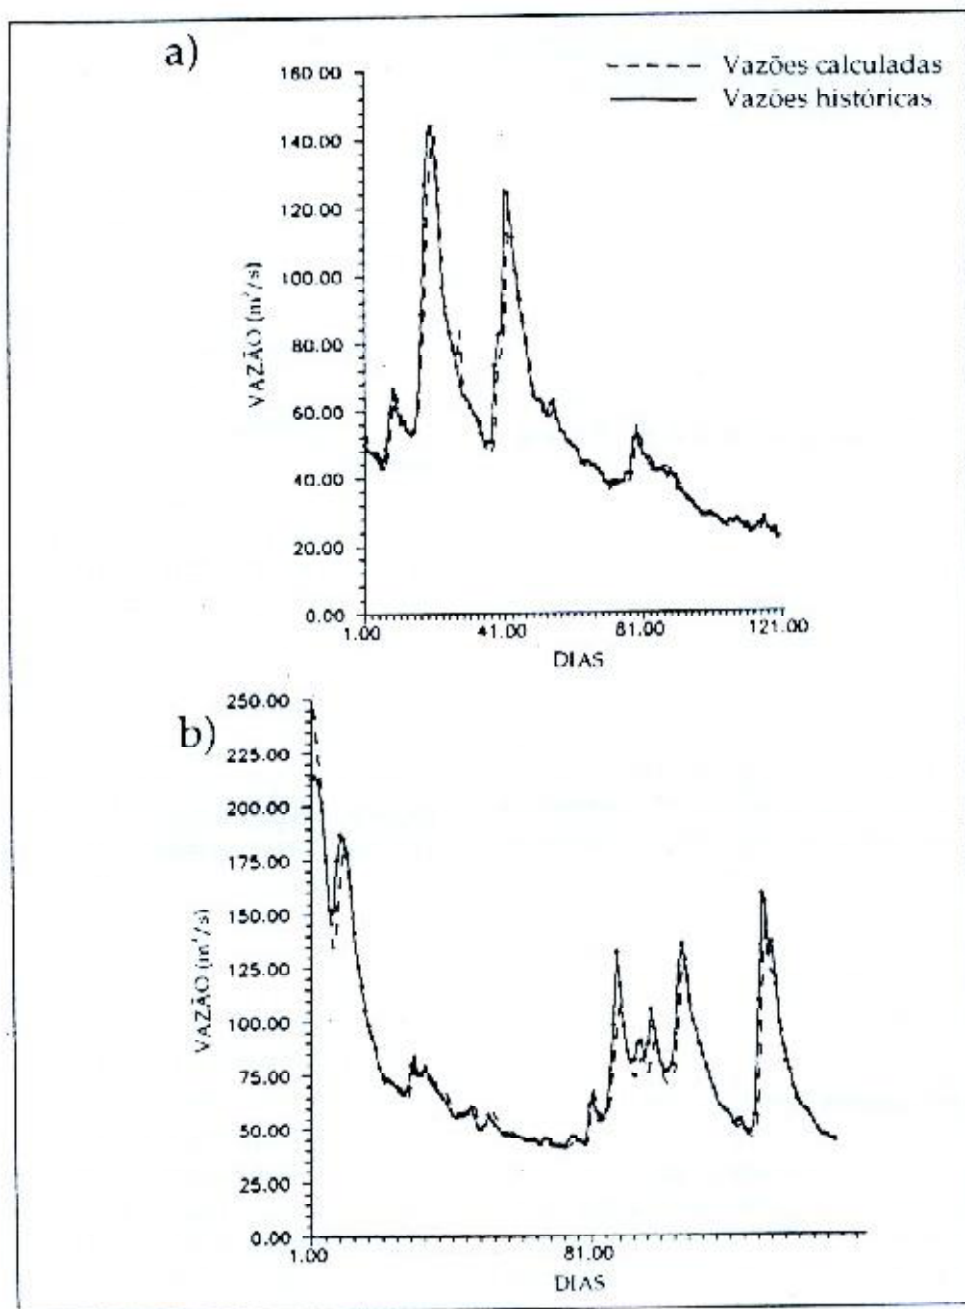


Figura 5. a) Previsão para 1 dia (evento 1-4/74); b) Previsão para 1 dia (evento 1-5/75). Posto Fluviométrico Herrenhausen.






Figura 6. a) Previsão para 2 dias (evento 1-4/74); b) Previsão para 2 dias (evento 1-5/75). Posto Fluviométrico Herrenhausen.



de treinamento esse tipo de evento é apresentado à rede com uma frequência muito maior do que os demais e isso não acrescenta nenhuma informação para a modelagem no período úmido. No que concerne a previsão de vazões médias diárias a ordem de grandeza dos erros associados com as previsões com 1 e 2 dias de antecedência utilizando apenas dois postos de montante atesta a viabilidade e o potencial do método para esta finalidade. De uma maneira geral a inclusão de postos fluviométricos que controlem sub-bacias com influência mais determinante no processo de formação de cheias irá certamente contribuir para um aperfeiçoamento das previsões.

Além da definição da arquitetura da rede para solução de determinado problema, um outro ponto importante consiste na escolha do método de otimização da função objetivo. É recomendável considerar uma composição entre métodos de otimização global e local, reduzindo assim os riscos de obtenção de soluções associadas a mínimos locais. Por outro lado tal composição diminui o tempo de processamento, visto que o refinamento a solução seria feito com um método de otimização local, portanto mais rápido. Considerando a finalidade demonstrativa do presente trabalho foi utilizado nos exemplos mostrados apenas o algoritmo de propagação regressiva dos erros, sendo portanto recomendável a averiguação de um possível refinamento do processo de busca fazendo-se uso da combinação de algoritmos acima mencionada.

Em ambas as aplicações o algoritmo de propagação regressiva dos erros utilizado apresentou resultados satisfatórios para um número de ciclos superior a 700, sendo o erro total na fase de treinamento praticamente constante para um número de ciclos superior a 1000. O parâmetro responsável pelo passo de avanço na direção do mínimo da função objetivo (parâmetro  $\eta$  na equação 1) forneceu resultados mais estáveis para valores bastantes reduzidos. Na maioria dos algoritmos computacionais apresentados na literatura este parâmetro assume valores no intervalo  $[0,1]$ . A experiência de calibração das

redes aqui tratadas mostrou que valores de  $\eta$  inferiores a 0,2, embora exija maior tempo de cômputo, conduz a uma convergência mais segura, ou seja, a função objetivo apresenta a cada ciclo um valor inferior ao anterior.

## REFERÊNCIAS

- BÁRDOSY, A. et al. (1993) Knowledge based Classification of circulation patterns for stochastic precipitation modeling. Stochastic and Statistical Methods in Hydrology and Environmental Engineering, International Conference, University of Waterloo, Canada.
- CARPENTER, G. A., GROSSBERGER, S. 1985. Category Learning and Pattern Recognition, a Neural Network Model. Proceedings of the Third Army Conference on Applied Mathematics and Computation, ARO Report 86-1, p. 37-56.
- CORANA, A. et al. (1987) Minimizing Multimodal Functions of Continuous Variables with the 'Simulated Annealing' Algorithm. ACM Trans. on Math. Software 13, no. 3, p. 262-280.
- DAVIS, L. (1991) Handbook of Genetic Algorithms. New York: Van Nostrand Reinhold.
- GOLDBERG, D. (1989) Genetic Algorithms in Search, Optimization, and Machine Learning. Reading, Mass.: Addison-Wesley.
- GRIEGER, B., LATIF, M. (1993) Reconstruction of the 'El Niño' Attractor with Neural Networks. Max-Planck- Institut für Meteorologie, Report N° 112.
- HESTENES, M. (1980) Conjugate Direction Methods in Optimization. New York: Springer-Verlag.
- HOLLAND, J. (1992) Genetic Algorithms. Scientific American, 6, p. 66-72.
- HOPFIELD, J. J. 1982. Neural Network and Physical Systems with Emergent Collective Computational Abilities. Proc. Natl. Acad. Sci. USA 79, p. 2554-58.
- HOPTRUFF, R.G. (1993) The Principles and Practice of Time Series Forecasting and Business Modelling Using Neural Nets. Neural Comput & Applic, p 59-66.
- LAARHOVEN, P., AARTS, E. (1987) Simulated Annealing: Theory and Applications. Dordrecht: D. Reidel Publishing Co.
- LANNA, A. E.; SCHWARZBACH, M. 1988. MODHAC - Modelo Hidrológico Auto-



- Calibrável. IPH - Instituto de Pesquisas Hidráulicas da UFRGS
- McCULLOCH, W. S., PITTS, W. 1943. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 5, p. 115-133
- MUSTER, H.; et al. (1994) Adaptive Neuro-Fuzzy Modeling of a non-stationary Hydrologic variable. *Proc. International Symposium Water Resources Planning in a Changing World*, p. 221-230.
- NYCHKA, D., ELLNER, S., GALLANT, A. R., McCAFFREY, D. (1992) Finding Chaos in Noisy Systems. *J. R. Statist. Soc. B*, 54, N°. 2, p. 399-426.
- RANJITHAN, S., EHEART, J. W., GARRETT, J. H. (1993) Neural Network-based Screening for Groundwater Reclamation Under Uncertainty. *Water Resources Research*, Vol. 29, no. 3, p. 563-574.
- REININGER, H., WOLF, D. (1990) Nonlinear Prediction of Stochastic Processes Using Neural Networks. *Signal Processing V: Theories and Applications*, Elsevier Science Publishers B. V., p 1623-1626.
- ROSENBLATT, F. 1958. The Perceptron: a Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65, p. 386-408.
- RUMELHART, D. E., McCLELLAND, J. L. (1986) *Parallel Distributed Processing. Exploration in the Microstructure of Cognition*, Vol. 1: Foundations, MIT Press.
- WEIJUN, H., JING, D. (1994) An artificial Neural Network for Reservoir Operation. *Proc. International Symposium Water Resources Planning in a Changing World*, p.133- 140.

*associated which the network architecture definition in relation to the nature of the modelling problem. To show the applicability of this technique to modelling hydrological variables, we present two case studies, which consist of the simulation of the monthly rainfall-runoff relationship in a basin of the semi-arid N-E Brazil and the forecast of daily streamflow with a lead interval of 1 and 2 days using a streamflow series from the Leine River (Germany). In the first case the historical runoff is series divided into two sub-series, which are used to train and test the network. The output from the test-running is compared with that from the calibration of the MODHAC rainfall-runoff model. In the second application, daily streamflows in a downstream station are predicted with a specified timelag (days) considering the recorded daily mean streamflow at this and at two other upstream stations. The quality of the result shows the property of the perceptron networks as universal approximators.*

### **Hydrological time series modelling using neural networks**

#### **ABSTRACT**

*This paper gives a brief classification of artificial neural networks in the context of General System Theory. It also presents the basic mathematical formulation of the cybernetic networks category, considering the optimisation parameter. Local and global optimisation algorithms and their efficiency to the considered purpose are also discussed. The paper also comments own aspects*