

PREVISÃO DE CHEIAS USANDO REDES NEURAIS ARTIFICIAIS

RESUMO

Há uma tendência progressiva, tanto na área urbana quanto na rural, de ocupação das terras mais baixas. Na área rural esse processo dá-se para a utilização dessas terras para fins agrícolas, enquanto nas áreas urbanas há o interesse imobiliário. As enchentes são fenômenos naturais que ocasionam a inundação dessas áreas ribeirinhas, quando a vazão do rio ultrapassa a capacidade dos canais de escoamento. Neste artigo é apresentado uma metodologia para a previsão de enchentes usando Redes Neurais Artificiais, devido à não-linearidade entre chuva e vazão.

ABSTRACT

Actually there is an increase tendency, not only by urban areas but also by rural inland areas, to use and explore sandbanks. By rural areas they have been used for agricultural purposes and by urban and periurban areas they have been used for economical speculation by real state companies. Floods are natural phenomena that cause inundation at flat alluvial plain on both river banks, when the runoff is over the canal capacity. The major objective of this study was the investigation of a methodology for flood prediction using Artificial Neural Networks, due to the nonlinear relationship between rainfall and runoff.

**Francisco Ricardo
Magalhães Barros**

*Bolsista Iniciação à
Pesquisa - FUNCAP/
UNIFOR*

**Marcos Airton de
Sousa Freitas**

*Prof. e Coord. do Grupo
de Pesquisas em Recursos
Hídricos, Meio
Ambiente e Computação
Aplicada - CCT/NPT -
UNIFOR*

1. INTRODUÇÃO

Na resolução de problemas complexos não-lineares, que por sinal exigem cada vez maior precisão, muito tem-se feito em relação à utilização de sistemas ou programas fundamentados na biologia. Dentre

esses, vale ressaltar as Redes Neurais Artificiais (RNAs), baseadas no funcionamento dos neurônios do cérebro. Tais sistemas procuram imitar o processo de aprendizagem dos neurônios, altamente paralelo e muito

útil na modelagem e previsão de sistemas não-lineares complexos (ALENCAR et al., 1997; FREITAS, 1997).

Neste artigo procurou-se, dentre outros aspectos, modelar e aplicar Redes Neurais Artificiais (RNAs) ao processo de previsão de vazões de rios do semi-árido brasileiro. A seguir, são detalhadas algumas definições e explicações acerca das Redes Neurais Artificiais. Num segundo momento, são mostrados a metodologia empregada, os equipamentos e os softwares utilizados no procedimento de modelagem da previsão. Por fim, são apresentados os resultados e as discussões.

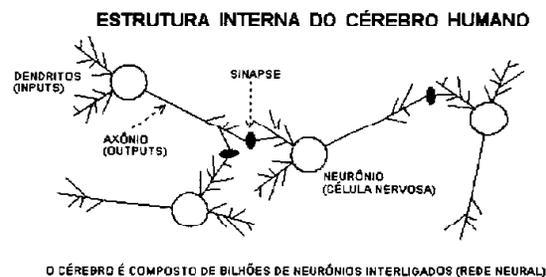
2. REDES NEURAIS ARTIFICIAIS

2.1. Histórico

O trabalho pioneiro na descrição de um modelo artificial de um neurônio biológico deve-se a Warren McCulloch e Walter Pitts (McCULLOCH & PITTS, 1943). Donald Hebb, psicólogo, no livro *Organization of Behavior*, de 1949, descreve, quantitativamente, o processo de treinamento humano e o funcionamento da sinapse (estímulo neuronal). Baseado no estudo de Hebb, Frank Rosenblatt, do MIT (USA), apresenta o modelo da sinapse humana (ROSENBLATT, 1958 e 1962). Ele demonstrou que se ao perceptron fossem acrescentadas sinapses ajustáveis as Redes Neurais Artificiais poderiam ser treinadas para classificar certos tipos de padrões. Porém, em 1969, Minsk & Papert mostram que o modelo de Rosenblatt não tinha a capacidade de resolver problemas linearmente separáveis, isto é, problemas cuja solução pode ser obtida dividindo-se o espaço de entrada em duas regiões através de uma reta. Alguns anos mais tarde, David E. Rumelhart, professor de psicologia da Stanford University, e James L. McClelland, professor de psicologia da Carnegie-Mellon University publicam *Parallel Distributed Processing: Explorations in the Microstructure of Cognition; vol.1: Foundations, vol.2: Psychological and Biological Models*, apresentaram um modelo computacional que permitia o treinamento sistemático dos neurônios artificiais (o modelo backpropagation), revitalizando assim o interesse pelo assunto,

pois contornava os problemas alegados por Minsk & Papert.

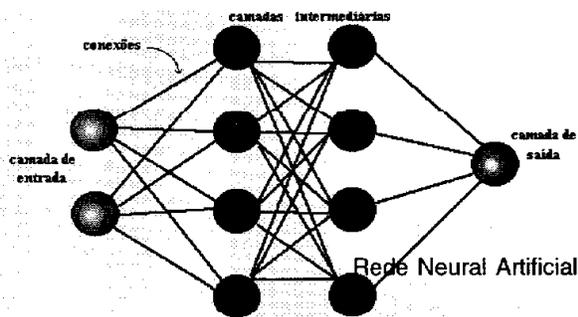
Deste ponto em diante, o desenvolvimento nesta área acelerou-se bastante, aparecendo, porém, alguns problemas no treinamento da rede (a complexidade e a demora). Com isso, novos algoritmos de otimização como o *Simulated Annealing* (Practical Neural Network Recipes in C++, de Timothy Masters) e o *Gradiente Conjugado de Polak* (Computational Methods in Optimization) surgiram facilitando o processo. Já se verifica a utilização de estratégias evolutivas, como os Algoritmos Genéticos (processo darwiniano de seleção natural empregado para encontrar a topologia ótima da rede neural), da Lógica Nebulosa ou 'Fuzzy Logic' (que possibilita trabalhar com dados imprecisos e não-numéricos) etc. Verifica-se hoje a aplicação de RNAs nas diversas áreas do conhecimento, desde as Ciências Tecnológicas até as Ciências Humanas, mostrando ser um instrumental de enorme flexibilidade funcional, além de fazer parte da nova geração tecnológica, que se baseia em programação paralela e distribuída.



2.2. Os Sistemas Tradicionais e as Redes Neurais Artificiais

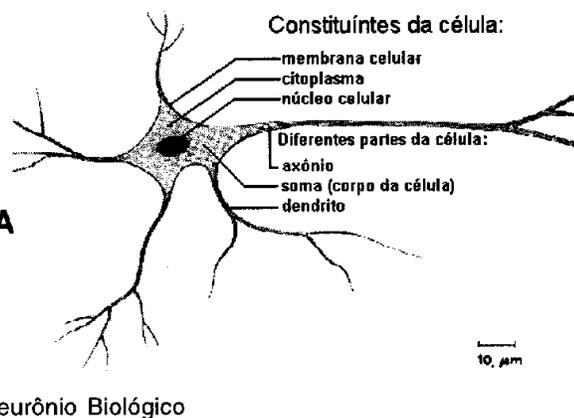
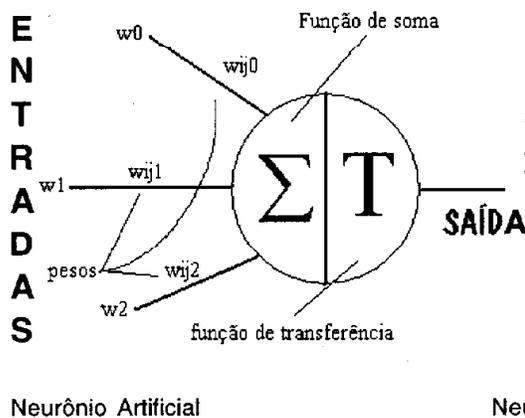
Uma Rede Neural Artificial é um conjunto de elementos de processamento, interligados e que interagem. Esses elementos recebem sinais (estímulos) exteriores do sistema ou de outros elementos, os processam e os enviam de volta. Esse sistema caracteriza-se pelo fato de não funcionar como um sistema tradicional (computação algorítmica convencional baseada em regras ou programas), executando instruções, mas sim, respondendo paralelamente a cada sinal; o resultado não fica armazenado em um endereço de memória, mas

é o próprio estado total da rede depois de atingir uma situação estável (processamento paralelo e distribuído). Assim, verifica-se que o conhecimento na rede é função mais da estrutura em si do que de uma localização em particular no sistema.



2.3. Neurônio Biológico x Neurônio Artificial

Um neurônio artificial é uma estrutura lógico-matemática, que busca a simulação de um neurônio biológico em muitos aspectos, desde a forma até as funções que este exerce. Desta maneira tem-se, então, as entradas (input) de um neurônio artificial, como os dendritos para um neurônio biológico. Estas entradas têm as ligações com o corpo celular artificial realizadas através de elementos chamados de peso, que simulam as sinapses do neurônio biológico. Assim sendo, os estímulos captados pelas entradas são processados pela função de soma; o limiar de disparo do neurônio biológico (estímulo) foi substituído pela função de transferência. O conhecimento provém do processamento de neurônios interconectados (rede).



Neurônio Biológico	Neurônio artificial
Dendritos	Entradas e saídas (ligações w_i e j)
Sinapse	Pesos (w_{ij})
Estímulo	Função T (transferência)
Processamento em Milisegundos	Processamento em Nanossegundos

2.4. Formas de Aprendizagem

As Redes Neurais Artificiais possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam. No aprendizado conexionista, ou por redes neurais, não se procura obter regras como na abordagem simbólica da Inteligência Artificial (IA), mas determinar a intensidade de conexões entre neurônios (CARVALHO et al., 1998).

Uma característica fundamental das RNA é, portanto, a capacidade de aprendizado.

Existem diversas formas teóricas de como uma Rede Neural Artificial pode aprender, quais sejam: 1) Acréscimo de novas ligações; 2) Retirada de ligações existentes; 3) Modificação dos valores dos pesos w_{ij} das ligações; 4) Modificação dos valores patamares dos neurônios; 5) Modificação das funções de ativação, propagação e saída; 6) Acréscimo de novos neurônios; 7) Retirada de neurônios. A forma mais largamente utilizada é a modificação dos valores dos pesos das ligações entre os neurônios.

Os diversos métodos para o treinamento de redes podem ser agrupados em duas categorias: Aprendizado Supervisionado e Aprendizado Não Supervisionado. Os algoritmos mais largamente conhecidos de aprendizado supervisionado são a denominada regra delta e sua generalização (algoritmo backpropagation).

2.4.1. A Regra Delta Generalizada (Ajuste dos pesos)

A forma para a alteração dos pesos é dada por:

$$\Delta w_{ij}(t+1) = \eta \times O_i \times \delta_j + \alpha \times \Delta w_{ij}(t)$$

sendo

Δw_{ij} = variação de peso ; δ = saída desejada - saída obtida; η = taxa de aprendizado; α = taxa de momentum [0.2,0.9]; e O_i = saída desejada.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades (neurônios) que podem estar conectadas às unidades da camada posterior. A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos (exemplos), adquirindo, a partir daí, a sistemática necessária

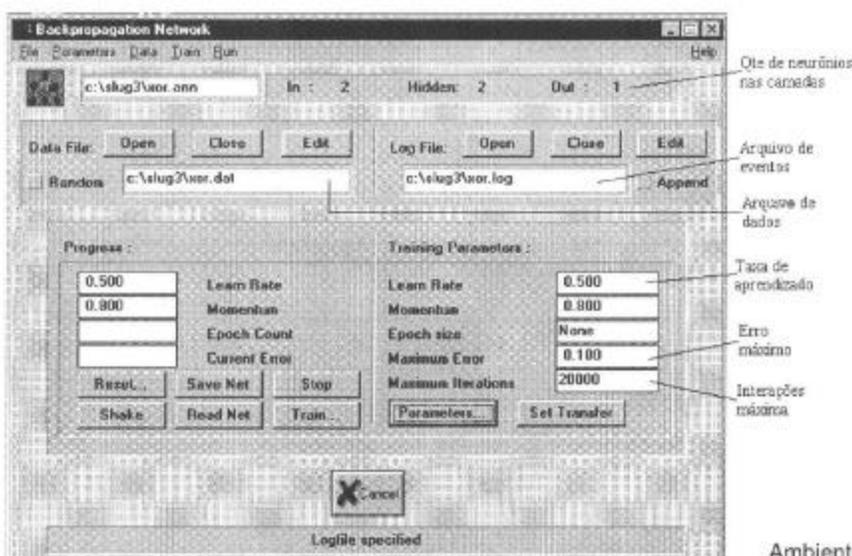
para executar adequadamente o processo de previsão. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de exemplos reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

2.5. Tipos de Redes Neurais Artificiais

Dependendo da dinâmica da rede, bem como dos neurônios e de sua topologia foi desenvolvida uma infinidade de Redes Neurais Artificiais, a saber: o modelo Perceptron (ROSENBLATT, 1962); o modelo Backpropagation (RUMMELHART et al., 1986); o modelo ADALINE (WIDROW & HOFF, 1960); a rede de KOHONEN (KOHONEN, 1984); o modelo HOPFIELD (HOPFIELD, 1982), o modelo ART (CARPENTER & GROSSBERG, 1987), dentre outras.

3. O ALGORITMO BACKPROPAGATION

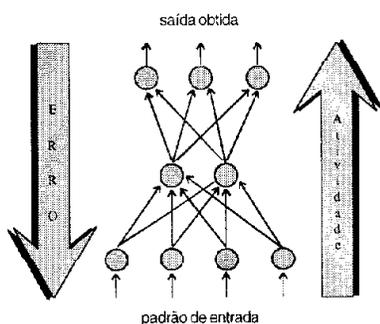
O algoritmo backpropagation procura minimizar o erro obtido pela rede ajustando pesos e limiares para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro. Para isso ele utiliza um método de gradiente descendente (CARVALHO et al., 1998). A modelagem processa-se, portanto, através das fases de treinamento, validação e previsão.



Ambiente de trabalho do Slug3

Um dos softwares de otimização deste tipo de rede é o Slug3 (desenvolvido em linguagem Pascal) com três camadas de neurônios onde se pode implementar a quantidade destes por camada (topologia), bem como modificar a taxa de aprendizagem, o termo de 'momentum', a quantidade de ciclos necessários ao ajuste e a margem de erro que se queira obter. O funcionamento de uma rede é basicamente assentada sob cálculos de pesos entre os neurônios, onde utilizando-se de dados reais (dados de entrada e os respectivos resultados) esta 'aprende' por exemplos a relação (não-linear) existente entre os dados. Tem-se, normalmente, como critérios de parada do processo de treinamento: 1) encerramento após um determinado número de ciclos e 2) encerramento após atingir-se um erro quadrático médio pré-fixado.

O nome backpropagation não é dado por acaso: os dados passados ao software pelo arquivo de entrada, trafegam pelas camadas onde são feitas as operações de alteração e ajustes de pesos entre os neurônios e depois de concluído os cálculos, o resultado é comparado com a saída final (também passada pelo arquivo de dados) de onde é calculado o erro e no caso de não corresponder ao desejado, esses dados são repassados de volta, camada a camada (por isso o nome back = volta, propagation = propagação) para reajuste e novos cálculos dos pesos.



Os dados de aprendizado na rede durante o treinamento e trafegam nos dois sentidos. Durante a previsão observa-se apenas um sentido.

Durante este processo, a taxa de aprendizagem pode ser alterada (inicialmente grande, ela deve ser reduzida quando a rede parar de diminuir o erro quadrático médio), sendo ela quem incrementa o quanto os cálculos dos pesos devem progredir aumentando ou diminuindo os valores que se somam aos pesos, assim aproximando a função do ótimo e diminuindo o erro de aproximação. Vale ressaltar

que a alteração da quantidade de neurônios por camada está diretamente relacionada com o arquivo de dados, ou seja, no caso de ter-se duas colunas de dados para entrada, tem-se dois neurônios na camada de entrada e tendo-se uma coluna para saída, conseqüentemente um neurônio na camada de saída. Quanto à camada intermediária (hidden), esta relaciona-se com os cálculos dos pesos, podendo ter uma quantidade qualquer de neurônios. A experiência mostra, que a quantidade de neurônios da camada intermediária está relacionada à camada de entrada sendo esse número de neurônios igual, o dobro, ou o triplo da quantidade de neurônios da camada de entrada.

4. MATERIAIS E MÉTODOS

O procedimento de modelagem não exige grandes equipamentos ou materiais sendo, de certa forma, simplificado e rápido, dividindo-se em duas etapas: 1) na etapa de organização dos dados e projeto da rede, utilizou-se de um computador tipo PC, com processador Pentium Pro Intel 200Mhz, com 64Mb (megabytes) de memória RAM e HD de aproximadamente 2.2 Gb (gigabytes), sob plataforma Microsoft Windows NT Server 4.0. Os softwares envolvidos na organização dos dados estatísticos foram a planilha eletrônica Excel 97 e o Bloco de Notas; 2) no procedimento de construção e treinamento da rede utilizou-se o Slug3.

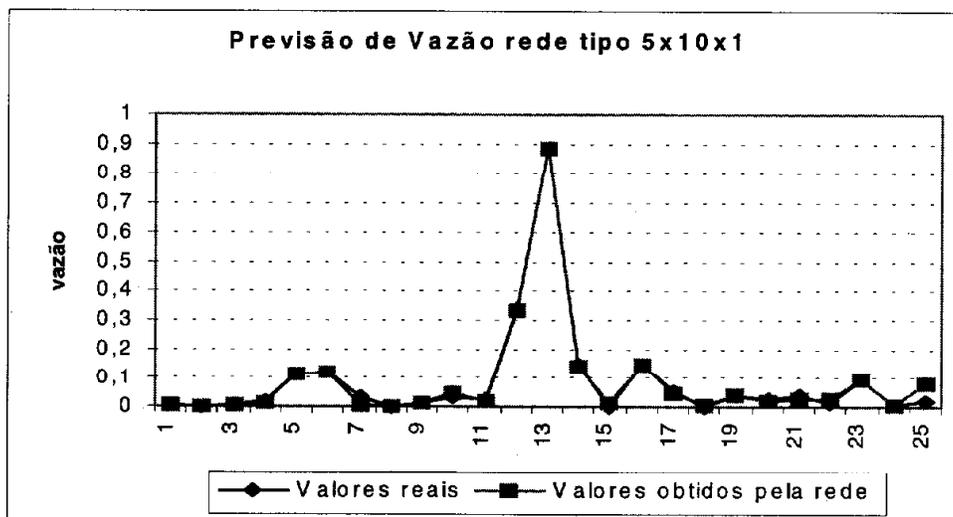
Para a realização experimental, na etapa de elaboração e modelagem dos dados estatísticos, o levantamento destes se fez através de pesquisa bibliográfica (teses, relatórios e dissertações), tendo como critério de seleção a adequação dos dados ao objetivo do experimento, ou seja, procurou-se apresentar à rede diversos exemplos de comportamento chuva-vazão ocorridos na bacia hidrográfica analisada. Na escolha do tipo de rede, a opção pelo tipo backpropagation deveu-se à relativa simplicidade de operação do sistema, além do fato de que para o alcance do objetivo da aplicação não se faz necessário o uso de um tipo de rede mais complexo. Em relação a estrutura da rede, sua concepção deu-se baseada em trabalhos já realizados (observações anteriores do sistema aplicado a outros problemas) de onde se avaliou a melhor topologia.

4.1. A previsão de vazão por Redes Neurais Artificiais

O conhecimento do regime dos rios, em especial de seus valores extremos, é de fundamental importância no gerenciamento dos recursos hídricos em regiões semi-áridas, dado que esses valores (secas e cheias) ocasionam inúmeros impactos econômicos, sociais e ambientais. Assim, devido às características das Redes Neurais Artificiais, aplicou-se tal modelo na previsão de cheias (vazão média diária) em uma bacia típica do semi-árido nordestino.

5. RESULTADOS OBTIDOS

Utilizando-se o modelo chuva-vazão, em nível diário, através de uma topologia de rede 5 x 10 x 1 (cinco neurônios na camada de entrada; dez na camada intermediária e um na camada de saída) obteve-se o gráfico a seguir (os valores de vazão foram escalonados para a faixa 0-1):



Pode-se ainda observar o ajuste da rede neural artificial, quando aplicados a valores de precipitação, com a finalidade de se modelar a vazão observada em determinada seção da bacia hidrográfica. Ou seja, trata-se de uma previsão tipo chuva-vazão. Os resultados apresentados com uma rede de topologia 5x10x1 mostram o bom nível de eficácia do sistema, tendo em vista que o erro obtido no período de treinamento foi inferior a 10%.

6. CONCLUSÕES E RECOMENDAÇÕES

Conclui-se dos resultados obtidos, que as Redes Neurais Artificiais (tipo backpropagation) são um método de apreciável eficiência na previsão de vazões (em tempo real) de rios intermitentes do semi-árido brasileiro, podendo ainda ser incorporado a um sistema de previsão de cheias, como auxílio à defesa civil. Nesse caso, recomenda-se a utilização de dados espaciais da bacia hidrográfica através de Sistemas de Informações Geográficas (SIG).

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ALENCAR, P.F. RIBEIRO, A.V.R. & FREITAS, M. A. S. Modelos Computacionais Baseados na Biologia: Algoritmos Genéticos e Redes Neurais Artificiais, *Revista Tecnologia - UNIFOR*, V. 18, pág. 92-98 1997.
- CARPENTER, G. A. & S. GROSSBERG. Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine, *Computer Vision, Graphics, and Image Processing*, V. 37, 54-115 1987.
- CARVALHO, A. C.P.L.F. A. P. BRAGA & T.B. LUDERMIR, 1998: *Fundamentos de Redes Neurais Artificiais*, DCC/IM, COPPE/Sistemas, NCE/UFRJ, Rio de Janeiro.
- FREITAS, M. A. S., *Regionale Dürreanalyse anhand statistischer Methoden und Neuro-Fuzzy-Systemen mit Anwendung für Nordost-Brasilien*, Tese (Doutorado), Inst. für Wasserwirtschaft, Hydrologie und landwirtschaftlichen Wasserbau, Univ. Hannover. 1997.

- FREITAS, M.A.S. & M.H.A. BILLIB. *Drought Prediction and Characteristic Analysis in Semi-arid Ceará - Northeast Brazil*, Symposium "Sustainability of Water Resources Under Increasing Uncertainty", IAHS Publ. N° 240, pág. 105-112, Rabat, Marrocos. 1997.
- FREITAS, M.A.S. A Decision Support System for Drought Forecasting and Reservoirs Management in Northeast-Brazil, *X Congresso Brasileiro de Meteorologia & VII Congresso Latino-Americano e Ibérico de Meteorologia* (aceito para apresentação). 1998.
- HAYKIN, Simon. *Neural Networks: A comprehensive foundation*. Ed. Prentice Hall. 1994.
- HEBB, D.O. *The Organization of Behavior*, Wiley. 1949.
- HOPFIELD, J. J., *Neural Networks and Physical Systems with Emergent Collective Computational Abilities*, Proc. of the National Academy of Science, USA, Biophysics, 79, 2554-2558. 1982.
- KOSKO, B., *Neural Networks and Fuzzy Systems*, Prentice Hall. 1992.
- MCCULLOCH, W.; W. PITTS. *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics, 5, 115-133. 1943.
- MINSKY, M. ; S. PAPERT. *Perceptron: Na Introduction to Computational Geometry*, MIT Press, Massachusetts. 1969.
- ROSENBLATT, F. *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*, Psychol. Ver., 65, 386-408. 1958.
- ROSENBLATT, F. *Principles of Neurodynamics*, Spartan Books, New York. 1962.
- RUMMELHART, D. E.; G. E. HINTON & R. J. WILLIAMS. *Learning Representations by Back-propagations Errors*, Nature, 323(9), 533-536. 1986.
- SCHWEFEL, H.-P. *Numerical Optimization for Computer Models*, John Wiley, Chichester, UK. 1981.
- SERAPHIN, M. *Neuronale Netze und Fuzzy-Logik: Verknüpfung der Verfahren, Anwendungen, Vor- und Nachteile*, Simulationsprogramm, München, Franzis Verlag. 1994.
- TAFNER, M.A.; M. XEREZ & I. W. RODRIGUES FILHO. *Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação*, Editora Eko - Ed. da FURB, Blumenau, 199p. 1995.
- WIDROW, B. & M. E. HOFF, 1960: *Adaptive Switching Circuits*, IRE WESCON Convention Record, New York, 96-104.
- ZELL, A. *Simulation Neuronaler Netze*, Addison Wesley. 1994.