

MAPAS AUTO-ORGANIZÁVEIS PARA MODELAGEM CHUVA-VAZÃO

Camilo A. S. de Farias¹; Tatiane C. Carneiro² & Artur M. G. Lourenço³

RESUMO – O estabelecimento de estratégias para o uso otimizado dos recursos hídricos está atrelado à existência de séries de dados hidrometeorológicos longas e confiáveis. Modelos chuva-vazão são normalmente utilizados para reconstruir e estender séries de vazão, se tornando indispensáveis em locais onde os dados disponíveis são limitados. Este trabalho investiga a aplicação de mapas auto-organizáveis (do inglês *Self Organizing Maps* – SOM) para (1) detecção de regularidades entre dados mensais de chuva e vazão e para (2) extensão de séries de vazão. Os SOM são redes neurais não supervisionadas que agrupam dados de entrada em classes de acordo com suas semelhanças. Tais modelos são capazes de classificar vetores mesmo quando existem falhas em parte de seus componentes, uma situação corriqueira na modelagem chuva-vazão. O estudo de caso é uma bacia hidrográfica localizada no semiárido paraibano, região carente de dados hidrometeorológicos e caracterizada por períodos de escassez de água. Este estudo sugere que os mapas gerados são poderosos instrumentos de análise por possibilitar a identificação visual das similaridades entre as variáveis do modelo. Os resultados também sinalizam que o modelo SOM apresenta um ótimo potencial para estimativa de vazões, podendo ser utilizado como ferramenta de apoio no gerenciamento dos recursos hídricos.

ABSTRACT – The establishment of strategies for optimal use of water resources is related to the existence of long and reliable hydrometeorological data records. Rainfall-runoff models are typically used for reconstruction and extension of river flow series, being essential for areas where the available data are limited. This paper aims at investigating the application of Self-Organizing Maps (SOM) for (1) detection of regularities between monthly rainfall and runoff data and for (2) extension of river flow data series. The SOM are unsupervised neural networks that cluster data into groups according to their similarities. Such models are able to classify data vectors even when there are missing values in some of its components, a common situation in rainfall-runoff modeling. The case study is a watershed located in semiarid Paraíba, Brazil. This region is devoid of hydrometeorological data and characterized by periods of water scarcity. This study suggests that the generated maps are powerful analytical tools since they enable visual identification of similarities between the model variables. The results also indicate that the SOM model has great potential for estimating river flows. Accordingly, this model may be used as a support tool for water resources management.

Palavras-chave: Mapas auto-organizáveis, modelo chuva-vazão, semiárido.

1) Professor Adjunto II, Universidade Federal de Campina Grande, Unidade Acadêmica de Ciências e Tecnologia Ambiental, Rua Jairo Vieira Feitosa, S/N, Bairro dos Pereiros, Pombal – PB 58840-000, Fone: (83) 3431-4007, e-mail: camiloallyson@yahoo.com.br

2) Aluna de Pós-Graduação do Curso de Mestrado em Ambiente, Tecnologia e Sociedade, Universidade Federal Rural do Semi-Árido, Departamento de Ciências Ambientais e Tecnológicas, Avenida Francisco Mota, 572, Bairro Costa e Silva, Mossoró – RN 59625-900, Fone (84) 9934-3778, e-mail: tatianecarolyne@oi.com.br

3) Aluno de Graduação do Curso de Engenharia Ambiental, Universidade Federal de Campina Grande, Unidade Acadêmica de Ciências e Tecnologia Ambiental, Rua Jairo Vieira Feitosa, S/N, Bairro dos Pereiros, Pombal – PB 58840-000, Fone: (83) 9653-1942, e-mail: libnirvana@gmail.com

1 – INTRODUÇÃO

O crescimento populacional e o desenvolvimento do setor industrial são os principais responsáveis pela crise da água no mundo. Para o atendimento das crescentes demandas, tanto em termos de qualidade como de quantidade, é frequentemente necessário que o sistema hídrico local seja operado e monitorado de forma eficaz (Vajpeyi, 1998; Loucks, 2000; Celeste *et al.*, 2005; Farias *et al.*, 2006; Farias, 2009). Em regiões semiáridas, este manejo se torna ainda mais complexo, devido às altas taxas de evaporação e distribuição irregular de chuvas no tempo e espaço.

Dentre as diversas medidas para mitigação dos efeitos das secas, a determinação de regras ótimas para operação de sistemas hídricos têm se mostrado uma alternativa bastante promissora. Entretanto, para o desenvolvimento dessas regras, é frequentemente necessário que se tenha séries de dados hidrometeorológicos longas e confiáveis. Modelos chuva-vazão são normalmente utilizados para reconstrução e extensão de séries de vazão, sendo extremamente necessários em locais onde os dados são insuficientes ou até mesmo inexistentes, como é o caso do nordeste brasileiro.

Este artigo tem como objetivo desenvolver e verificar a aplicação de mapas auto-organizáveis (do inglês *Self Organizing Maps* – SOM) para (1) detecção de similaridades entre dados mensais de chuva e vazão e para (2) extensão da série de vazão de um rio localizado no semiárido paraibano.

Os SOM são redes neurais artificiais não supervisionadas que agrupam dados de entrada em classes de acordo com suas semelhanças por meio de métodos de treinamento competitivo (Kohonen, 1982; Haykin, 1999; Silva *et al.*, 2010). Também conhecidos como redes auto-organizáveis de Kohonen, as redes SOM foram propostas por Kohonen (1982) e têm sido predominantemente aplicadas na classificação de padrões e agrupamento de dados. Uma das principais vantagens das redes SOM é a capacidade de reduzir um conjunto de dados multidimensionais a uma matriz bidimensional de características, que pode ser utilizada para fins de análise e de previsão (Silva *et al.*, 2010, Adeloje *et al.*, 2011).

2 – ESTUDO DE CASO

A bacia hidrográfica do Rio Piancó situa-se a sudoeste do estado da Paraíba, nordeste brasileiro. Com uma área de drenagem de 9.228 km², apresenta clima semiárido e valores anuais médios de precipitação e temperatura em torno de 821 mm e 24 °C, respectivamente. Nesta bacia encontra-se a maior reserva de água do estado, o sistema Coremas – Mãe d'Água. As vazões afluentes ao sistema são provenientes de três grandes tributários: Riacho Aguiar, Riacho Emas e

Rio Piencó. As vazões do tributário Piencó são medidas no posto fluviométrico Piencó, que possui uma área de drenagem de 4.170 km².

O levantamento dos dados foi feito em oito postos pluviométricos e um posto fluviométrico localizados na bacia do Rio Piencó. Detalhes dos postos estudados são mostrados na Figura 1 e Tabela 1. Os dados foram obtidos no website da Agência Nacional de Águas (ANA, 2010). O período de análise, sabidamente escolhido por apresentar informações mais completas, compreende dados desde janeiro de 1963 a dezembro de 1988, totalizando 26 anos de observações.

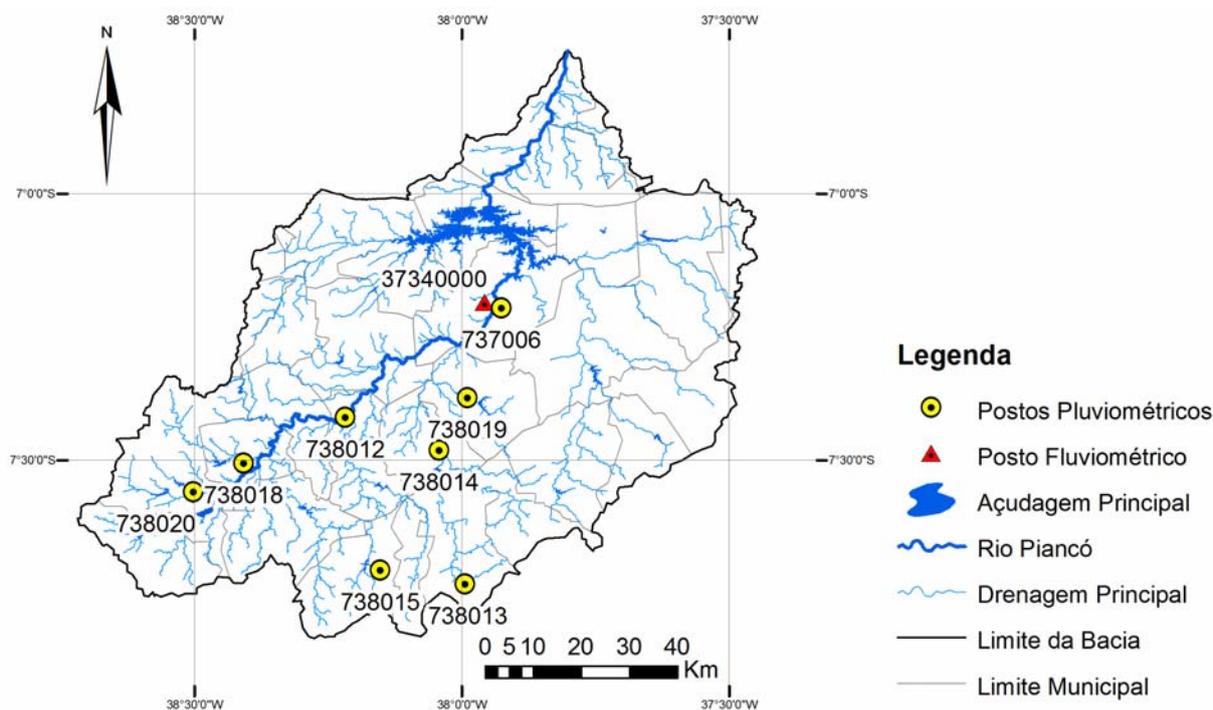


Figura 1- Localização dos postos pluviométricos e fluviométrico estudados na bacia do Rio Piencó.

Tabela 1 – Postos pluviométricos e fluviométrico utilizados.

Código (Identificação)	Nome do posto	Tipo	Município
737006 (P_1)	Piencó	Pluviométrico	Piencó
738020 (P_2)	Conceição	Pluviométrico	Conceição
738015 (P_3)	Manaíra	Pluviométrico	Manaíra
738013 (P_4)	Princesa Isabel	Pluviométrico	Princesa Isabel
738019 (P_5)	Santana dos Garrotes	Pluviométrico	Santana dos Garrotes
738012 (P_6)	Boa Ventura	Pluviométrico	Boa Ventura
738014 (P_7)	Nova Olinda	Pluviométrico	Nova Olinda
738018 (P_8)	Ibiara	Pluviométrico	Ibiara
37340000 (Q)	Piencó	Fluviométrico	Piencó

3 – MODELO SOM

3.1 Arquitetura e treinamento

O principal objetivo dos mapas auto-organizáveis consiste no agrupamento de vetores com características similares em uma mesma classe (neurônio vencedor) ou em classes semelhantes (neurônios vizinhos).

As arquiteturas das redes neurais SOM contêm uma camada de entrada multidimensional e uma camada de saída que normalmente é unidimensional ou bidimensional. Na camada de saída, também conhecida como camada competitiva, os neurônios concorrem entre si e apenas um deles é considerado o vencedor ou, de forma simplificada, a classe mais adequada para um determinado vetor de entrada \mathbf{x} . Nessas redes, cada elemento do vetor de entrada está conectado a todos os elementos da camada de saída. A força das conexões é medida por meio de pesos w_{ij} entre os neurônios de entrada j e os neurônios da camada de saída i .

Durante o treinamento do modelo SOM, são calculadas as distâncias Euclidianas DI_i entre o vetor de entrada e os pesos ligados a cada um dos neurônios de saída, conforme mostrado na Equação (1).

$$DI_i = \sqrt{\sum_{j=1}^J (x_j - w_{ij})^2}; \text{ for } i = 1, 2, \dots, M. \quad (1)$$

onde x_j é o j -ésimo componente do vetor de entrada \mathbf{x} ; J é a dimensão do vetor de entrada \mathbf{x} ; e M é o número total de neurônios na camada de saída.

O neurônio de saída i que possuir a menor distância Euclidiana ao vetor de entrada é considerado o neurônio vencedor. Os pesos conectados a este neurônio i^* e aos neurônios dentro de um certo raio de vizinhança V_{i^*} são então atualizados pela regra de Kohonen (Beale *et al.*, 2012), conforme apresentada na Equação (2).

$$w_{ij}(n) = w_{ij}(n-1) + \alpha \cdot [x_j(n) - w_{ij}(n-1)]; \text{ para } i \in V_{i^*} \text{ e } j = 1, 2, \dots, J. \quad (2)$$

onde α é a taxa de aprendizagem e n é um índice que representa a sequência de apresentação das amostras a rede.

A regra de Kohonen força os pesos ligados ao neurônio vencedor e seus vizinhos a se deslocarem na direção do vetor de entrada apresentado à rede, fazendo com que a distância Euclidiana se torne cada vez menor e com que estes neurônios aprendam a classificar vetores similares.

A apresentação dos vetores de entrada a rede também pode ser feita utilizando-se todo o conjunto de dados antes de qualquer atualização de pesos. Esta forma de apresentação é conhecida como modo de lote. Neste caso, a busca pelo neurônio vencedor é efetuada para cada vetor de entrada e então o vetor peso é movido para uma posição específica calculada pela média dos vetores de entrada para o qual o neurônio foi o vencedor ou vizinho do vencedor. Os pesos tendem a se estabilizar após várias apresentações do conjunto de dados de entrada. É importante ressaltar que o treinamento desta rede neural é do tipo não supervisionado, pois não existem saídas desejadas.

Para fins de determinação da vizinhança, as distâncias entre os neurônios da camada de saída podem ser definidas de várias maneiras (Beale *et al.*, 2012). Comumente, em uma camada de saída bidimensional, esses neurônios são imaginados como formas retangulares ou hexagonais e as distâncias são estabelecidas pelo número de passos entre eles. A Figura 2 mostra como as distâncias entre neurônios hexagonais são obtidas para fins de determinação da vizinhança.

O treinamento ocorre em duas fases: fase de ordenação e fase de ajustes. Na primeira fase, o treinamento é limitado por um determinado número de apresentações do conjunto de dados e o raio da vizinhança é iniciado com uma dada distância que decresce até o valor unitário. Esta medida permite que os pesos dos neurônios se organizem no espaço de entrada de forma consistente com as suas posições. A fase de ajustes dura o restante do número de apresentações definido para o treinamento. Nesta fase, o raio da vizinhança fica abaixo da unidade, fazendo com que haja atualização somente no peso do neurônio vencedor. Durante a fase de ajustes espera-se que os pesos se modifiquem de forma relativamente uniforme no espaço de entrada, mantendo a topologia definida na fase de ordenação (Beale *et al.*, 2012).

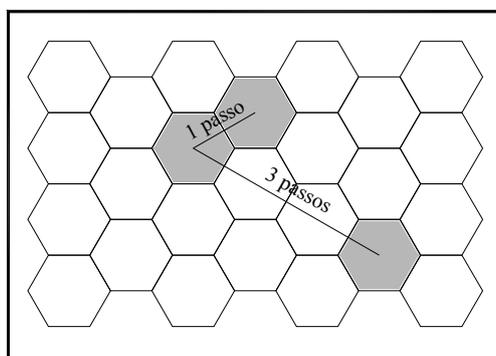


Figura 2 - Distâncias entre neurônios de um modelo SOM para determinação da vizinhança.

3.2 Previsão com o modelo SOM

Depois de treinadas, as redes SOM podem ser utilizadas como ferramentas de previsão. Para tal, deve-se considerar o vetor de entrada com a ausência da variável a ser prevista por meio dos seguintes passos:

- 1) Calcular as distâncias Euclidianas entre os vetores de entrada e pesos ligados aos neurônios de saída desconsiderando o elemento j a ser previsto. Isto pode ser feito através da inclusão de uma variável booleana m_j , conforme mostrado na Equação (3). A variável m_j é usada para incluir ($m_j = 1$) ou excluir ($m_j = 0$) a contribuição de um dado elemento j do vetor de entrada no cálculo das distâncias Euclidianas;
- 2) Determinar o neurônio vencedor com base na menor distância Euclidiana;
- 3) Usar o peso do neurônio vencedor ligado ao elemento ausente j do vetor de entrada como a previsão.

$$DI_i = \sqrt{\sum_{j=1}^J m_j (x_j - w_{ij})^2}; \text{ para } i = 1, 2, \dots, M. \quad (3)$$

4 – APLICAÇÃO E RESULTADOS

4.1 Aplicação do modelo SOM

Neste estudo, os vetores da camada de entrada possuem 27 neurônios representando os valores mensais passados e correntes de vazão, $Q(t-2)$, $Q(t-1)$ e $Q(t)$, e chuva, $P_1(t-2)$, ..., $P_8(t-2)$, $P_1(t-1)$, ..., $P_8(t-1)$, $P_1(t)$, ..., $P_8(t)$. Optou-se por uma camada de saída bidimensional com neurônios hexagonais. Com base nas diretrizes sugeridas por García & Gonzáles (2004), utilizou-se uma malha de 10×10 neurônios, fornecendo um total de 100 neurônios. A Figura 3 apresenta a estrutura da rede SOM deste trabalho e um exemplo com um neurônio vencedor e seus vizinhos.

Os dados de entradas foram convenientemente escalonados para melhorar a eficiência no treinamento do modelo SOM. O processo de escalonamento consistiu em normalizar os dados de forma que a média fosse igual a zero e o desvio padrão unitário (Beale *et al.*, 2012).

O treinamento do modelo ocorreu em modo de lote e, para garantir uma aprendizagem consistente, o conjunto de dados foi apresentado à rede neural SOM 1000 vezes. Na fase de ordenação, optou-se por 100 apresentações do conjunto de dados e por um raio da vizinhança inicial igual a três passos. A fase de ajustes contou com as 900 apresentações restantes. O modelo SOM foi implementado em MATLAB R2012a utilizando o *Neural Network Toolbox* (Beale *et al.*, 2012).

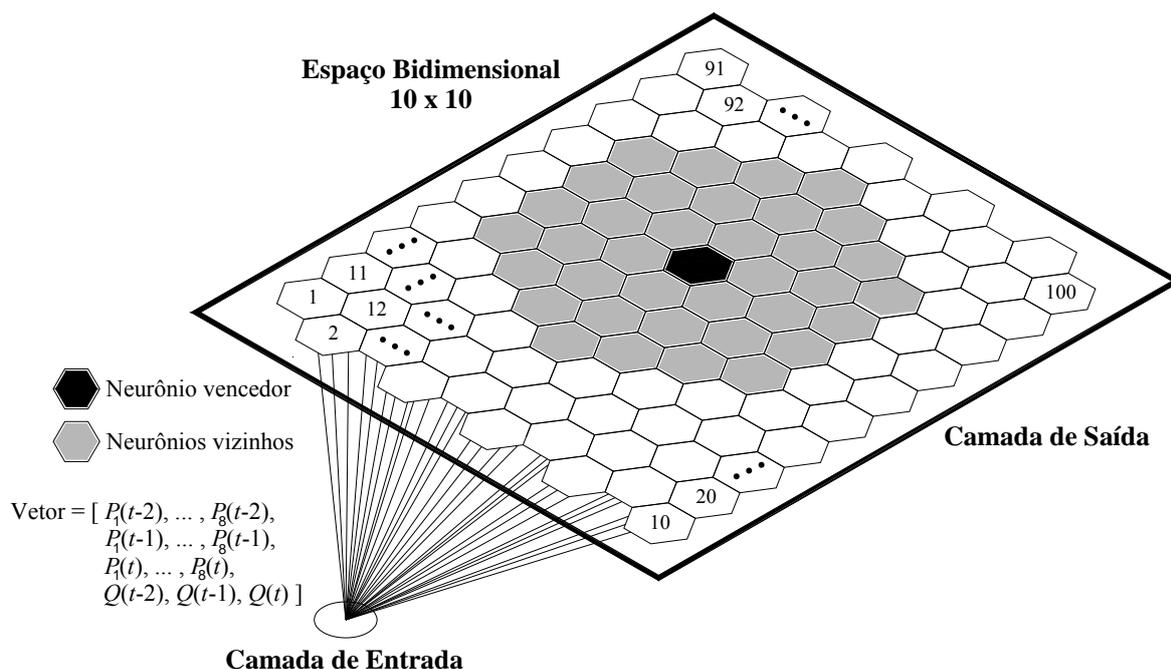


Figura 3 - Estrutura do modelo SOM e exemplo com um neurônio vencedor e seus vizinhos.

Os dados utilizados para treinamento e teste do modelo SOM compreendem os períodos de 1963 – 1985 e 1986 – 1988, respectivamente.

4.2 Detecção de similaridades

A detecção de similaridades entre as variáveis envolvidas nesta modelagem pode ser realizada visualmente por meio dos planos dos componentes mostrados na Figura 4. Esses planos ou mapas representam os pesos associados a cada variável de entrada. Para facilitar a interpretação dos resultados, uma escala de cor foi exibida com as dimensões originais dos pesos, que na verdade são os valores das variáveis em estudo para os distintos neurônios ou classes. Os maiores valores correspondem às zonas amarelas e os menores às regiões em cor preta.

Correlações podem ser identificadas por meio dos gradientes de cores em cada plano de componente. Duas variáveis com gradientes paralelos mostram uma correlação direta enquanto gradientes antiparalelos evidenciam uma correlação inversa (García & Gonzáles, 2004). A análise da Figura 4 permite a extração de diversas informações. Nesta pesquisa, buscou-se interpretar similaridades para três situações: (1) relação entre dados de chuva dos oito postos pluviométricos estudados no mesmo período de tempo; (2) relação entre as vazões observadas no posto fluviométrico de Piancó e vazões de meses anteriores; e (3) relação entre as vazões observadas no posto fluviométrico de Piancó e chuvas do mesmo período e de meses anteriores dos oito postos.

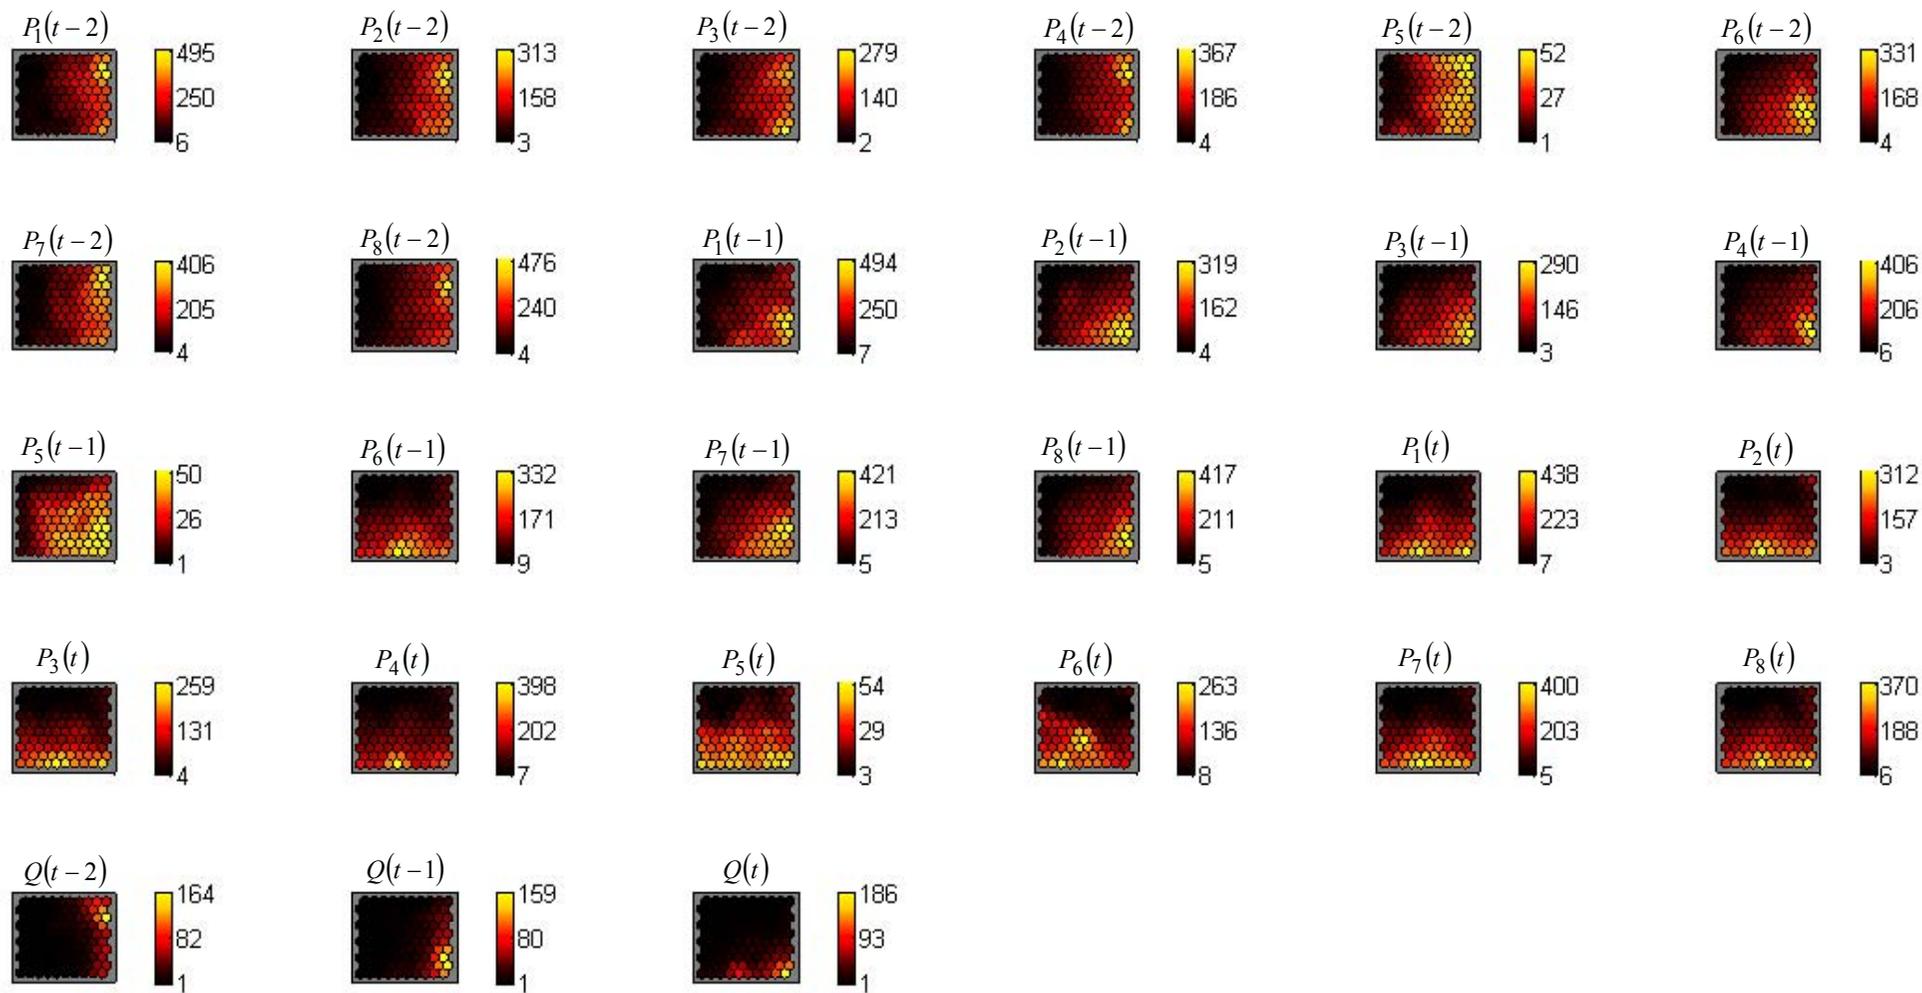


Figura 4 - Planos dos componentes obtidos pelo modelo SOM para dados de chuva [mm] e vazão [m³/s] na bacia do Rio Piancó.

Com relação à situação (1), foi possível verificar visualmente nos planos que baixos e altos valores de chuvas eram classificados em categorias similares para todos os postos investigados, com exceção do posto de Boa Ventura, que apresentou um comportamento diferenciado. Com base neste resultado, entende-se que é razoável utilizar informações de postos pluviométricos vizinhos para o preenchimento de falhas nas séries de chuvas da região estudada.

Ao analisar a situação (2), observou-se que no plano de $Q(t)$ as maiores vazões apresentavam-se na parte inferior do mapa, sendo que os valores mais extremos encontram-se nos elementos inferiores direitos. Ao comparar as vazões com magnitudes médias (células vermelhas) e altas (células amarelas), percebe-se que o mapa de $Q(t)$ possui pouca similaridade com o mapa de $Q(t-1)$ e praticamente nenhuma semelhança com o mapa que representa a vazão $Q(t-2)$.

A investigação dos mapas com foco na situação (3) sugere que, de forma geral, os dados de vazão são fortemente correlacionados com as chuvas no mesmo período de tempo. Apesar da menor expressão, as vazões também se mostraram razoavelmente correlacionadas com as chuvas do mês anterior. Isto é evidenciado pela identificação de que as regiões com baixas (células pretas), médias e altas vazões possuem cores semelhantes nos planos de chuva, com especialidade no posto pluviométrico de Piancó. Diferentemente do comportamento das vazões observado no plano de $Q(t)$, a maioria dos planos das chuvas no período $t-2$ mostram altos índices na parte superior direita dos mapas, indicando a inexistência de relações diretas significantes entre essas variáveis.

4.3. Modelagem chuva-vazão

A avaliação do desempenho do modelo SOM para estimativa de vazões foi realizada com base nos seguintes índices: correlação (R), viés relativo (VR) e eficiência de Nash-Sutcliffe ($NASH$). A correlação mede o grau de dependência linear entre as previsões e os valores observados de vazão, expressando na realidade um valor potencial de bom ajuste. O viés relativo, por sua vez, mostra se o sistema de previsão de vazões possui uma tendência a subestimar ou superestimar as vazões observadas. O índice de eficiência $NASH$, que pode variar entre $-\infty$ e 1, é tradicionalmente utilizado para expressar aderência entre vazões simuladas e observadas. Esse índice considera tanto os erros sistemáticos quanto os erros randômicos, indicando que o ajuste é cada vez melhor à medida que o seu valor aproxima-se da unidade.

Valores altos de correlação não significam, por si só, previsões com alta precisão. Por exemplo, um sistema com um viés muito alto, mesmo que possua correlação igual à unidade ($r = 1$), fornecerá previsões de vazões de baixa precisão, embora seja possível remover este viés através de modelos estatísticos. Um sistema perfeito de previsão teria $r = 1$ e $VR = 0$. As equações para cálculo destes índices podem ser encontradas em Lettenmaier & Wood (1993).

A Figura 5 mostra um comparativo entre as estimativas mensais de vazão obtidas com o modelo SOM, considerando os passos descritos na Seção 3.2, e os valores observados de vazão para o posto fluviométrico investigado durante para o período de treinamento.

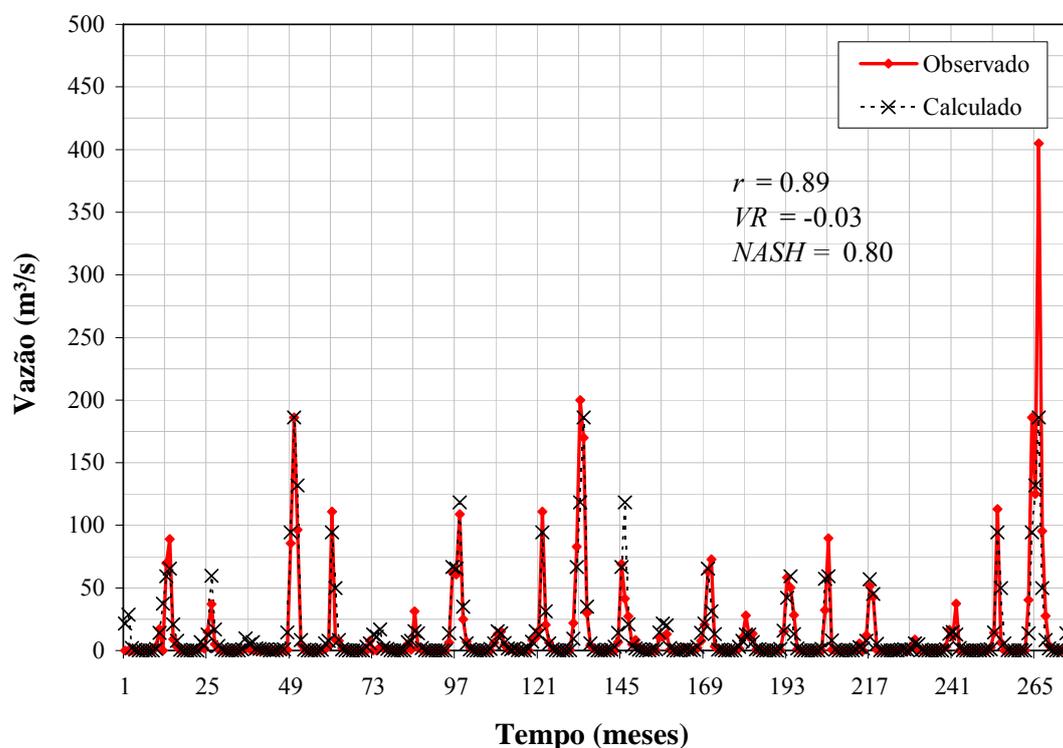


Figura 5 - Comparação entre vazões mensais obtidas com o modelo SOM e os valores observados no posto fluviométrico de Piancó durante os 23 anos do período de treinamento (1963–1985).

Os resultados de correlação, viés relativo e *NASH* mostram que o modelo SOM conseguiu classificar com boa qualidade as vazões do conjunto de dados de treinamento. Pode-se notar que no conjunto de dados disponíveis existe uma amostra com valor de vazão muito superior a todas as outras e que o modelo não conseguiu representar com a qualidade esperada. Isto ocorreu porque os modelos de redes neurais, como é o caso das redes SOM, aprendem através de exemplos e, portanto, necessitam de uma quantidade razoável de eventos com as várias magnitudes para obterem sucesso. Para alcançar melhores resultados nessa faixa de vazão, seria necessário que mais dados dessa magnitude fossem apresentados no treinamento, algo que tende a melhorar à medida que se dispõem de mais dados observados.

O modelo SOM também foi avaliado para um período de teste representado por uma série de dados totalmente independente daquelas utilizadas para o treinamento do modelo. Para isto, foram escolhidos e testados seis conjuntos de variáveis de entrada para previsão das vazões no Rio Piancó, como mostra a Tabela 2.

Tabela 2 – Dados de entrada para previsão de vazão utilizando o modelo SOM para seis simulações.

Simulação	Dados de Entrada
SIM #1	$P_1(t-2), \dots, P_8(t-2), P_1(t-1), \dots, P_8(t-1), P_1(t), \dots, P_8(t), Q(t-2)$ e $Q(t-1)$
SIM #2	$P_1(t-1), \dots, P_8(t-1), P_1(t), \dots, P_8(t), Q(t-2)$ e $Q(t-1)$
SIM #3	$P_1(t-2), \dots, P_8(t-2), P_1(t), \dots, P_8(t), Q(t-2)$ e $Q(t-1)$
SIM #4	$P_1(t-2), \dots, P_8(t-2), P_1(t-1), \dots, P_8(t-1), Q(t-2)$ e $Q(t-1)$
SIM #5	$P_1(t-2), \dots, P_8(t-2), P_1(t-1), \dots, P_8(t-1), P_1(t), \dots, P_8(t)$ e $Q(t-1)$
SIM #6	$P_1(t-2), \dots, P_8(t-2), P_1(t-1), \dots, P_8(t-1), P_1(t), \dots, P_8(t)$ e $Q(t-2)$

A Figura 6 apresenta os resultados de estimativa de vazões para todas as simulações. A simulação SIM#1 mostra que as estimativas do modelo SOM e os valores observados possuem alta correlação e um valor de viés relativo razoavelmente baixo. O valor do *NASH* também foi muito próximo de um, o que indica que as estimativas mensais de vazão possuem boa qualidade. Os índices obtidos para as outras simulações, em que algumas variáveis de entrada foram suprimidas, mostram que o modelo SOM pode produzir estimativas confiáveis mesmo quando existem falhas nos dados de entrada, bastando, para isso, seguir o procedimento sugerido na Seção 3.2. Estes resultados são justificados pela poderosa capacidade de classificação das redes SOM, mesmo nos casos em que alguns dos elementos do vetor de entrada não estejam presentes (Beale *et al.*, 2012).

A simulação SIM#4, que não contou com os dados de chuva do período corrente, foi a que apresentou os resultados menos expressivos. Ao verificar as vazões estimadas pelas simulações SIM#5 e SIM#6, observa-se que a retirada das vazões passadas do conjunto de dados de entrada praticamente não prejudicou o desempenho do modelo. Esses resultados ratificam as análises realizadas durante a detecção de similaridades descrita na Seção 4.2.

5 – CONCLUSÃO

Este artigo apresentou um modelo de mapas auto-organizáveis (SOM) para detecção de similaridades entre dados mensais de chuva e vazão e verificou sua aplicabilidade para extensão de séries mensais de vazão em um posto fluviométrico no Rio Piancó, semiárido paraibano.

O modelo desenvolvido foi avaliado por meio de um estudo comparativo relacionando vazões estimadas pelo modelo SOM com dados observados na região. Esta comparação, utilizando um período de teste independente dos dados utilizados no treinamento do modelo, mostrou que o modelo SOM apresentou ótimo desempenho para estimativa de vazões mensais.

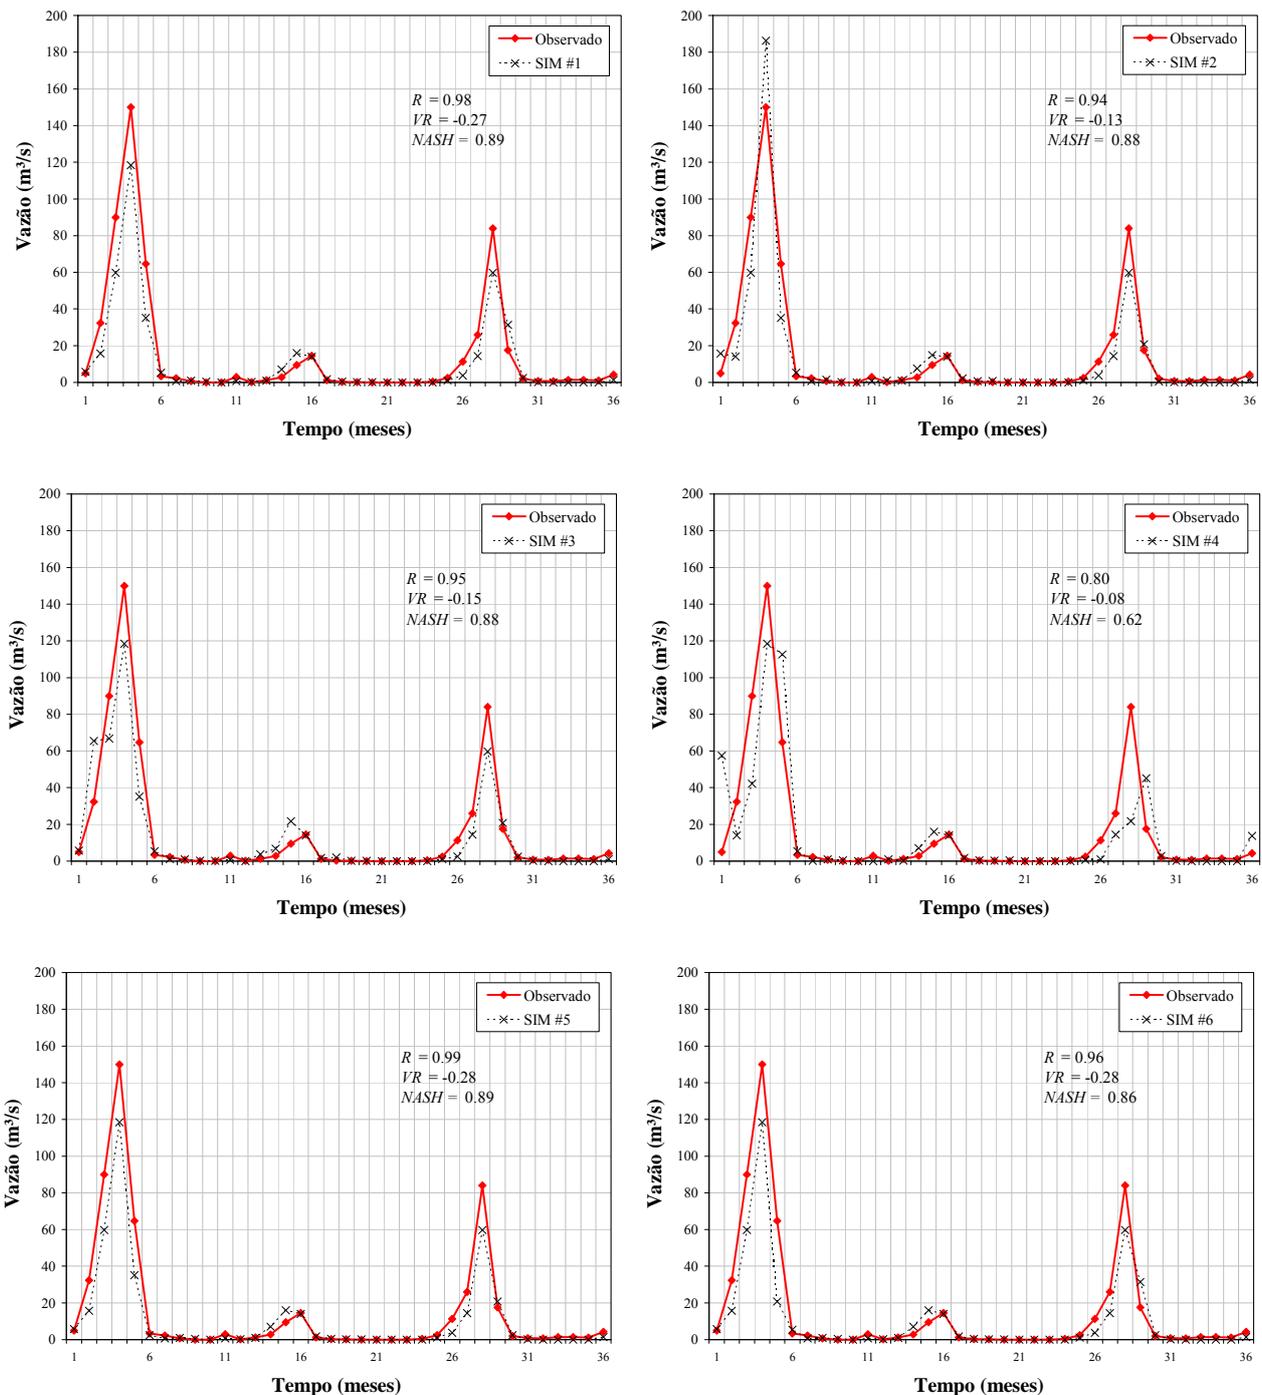


Figura 6 - Comparação entre estimativas mensais de vazão obtidas com o modelo SOM e os valores observados no posto fluviométrico Piancó para várias configurações dos dados de entrada durante os três anos do período de teste (1986–1988).

Os planos de componentes gerados pelo modelo SOM mostraram-se poderosos instrumentos de análise por possibilitar a identificação visual das similaridades entre as variáveis envolvidas na modelagem. Simulações utilizando várias configurações de entradas também indicaram que o modelo SOM pode produzir estimativas confiáveis mesmo quando existem falhas nos dados de entrada, uma situação corriqueira quando se lida com dados hidrometeorológicos.

Os bons resultados obtidos para o posto fluviométrico do Rio Piancó sugerem que este tipo de modelagem pode ser utilizado para extensão de séries de vazões em locais carentes de informações hidrometeorológicas.

AGRADECIMENTOS

Este trabalho foi realizado com apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (Processo n.º 475778/2010-3).

BIBLIOGRAFIA

ADELOYE A. J.; RUSTUM, R.; KARIYAMA, D.(2011). “*Kohonen self-organizing map estimator for the reference crop evapotranspiration*”. Water Resources Research 47, W08523, pp. 1-19.

ANA – Agência Nacional de Águas. Disponível em <http://hidroweb.ana.gov.br/>, acessado em 27/09/2010.

BEALE, M.; HAGAN, M.; DEMUTH H. (2012). *Neural Network Toolbox 7.0.3: User's Guide*. The MathWorks Inc, Natick, USA, 404 p.

CELESTE, A. B.; SUZUKI, K.; KADOTA, A.; SANTOS, V. S. (2005). “*Derivation of reservoir operating rules by implicit stochastic optimization*”. Annual Journal of Hydraulic Engineering – JSCE 49(2), pp. 1111–1116.

FARIAS, C. A. S.; CELESTE, A. B.; SAKATA, Y.; KADOTA, A.; SUZUKI, K. (2006). “*Use of Monte Carlo optimization and artificial neural networks for deriving reservoir operating rules*”. Annual Journal of Hydraulic Engineering – JSCE 50(1), pp. 25-30.

FARIAS, C. A. S. (2009). *Derivation of hedging rules and forecasts by artificial neural networks for optimal real-time management of an integrated water resources system*. Tese de Doutorado, Ehime University, Matsuyama - Japão, 127 p.

GARCÍA, H. L.; GONZÁLEZ, I. M. (2004). “*Self-organizing map and clustering for wastewater treatment monitoring*”. Engineering Applications of Artificial Intelligence, v. 17, n. 3, pp. 215–225.

HAYKIN, S. (1999). *Neural Networks: a Comprehensive Foundation*. Prentice Hall, Upper Saddle River, USA, 842 p.

KOHONEN, T. (1982). “*Self-organized formation of topologically correct feature maps*”. Biological Cybernetics 43, pp. 59-69.

LETTENMAIER D. P., WOOD, E. F. (1993). “*Hydrologic Forecasting*” in *Handbook of Hydrology*. Org. by Maidment, D. R., McGraw-Hill Inc., New York, USA, pp. 26.1–26.30.

LOUCKS, D. P. (2000) "*Sustainable water resources management*". Water International, IWRA 25(1), pp. 3-10.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO R. A. (2010). "*Redes neurais artificiais para engenharia e ciências aplicadas*", Artliber, São Paulo, 399 p.

VAJPEYI, D. K. (1998). "*Water Resource Management: A Comparative Perspective*", Praeger Publishers, Westport, USA, 177 p.