

Utilização de Técnicas de Mineração de Dados para Previsão do Nível do Rio Paraguai

Yasuo Kono

INPE¹

yasuo@dss.inpe.br

José Carlos Becceneri

INPE²

becce@lac.inpe.br

Rafael Santos

INPE²

rafael.santos@lac.inpe.br

1- Divisão de Sistemas Solo, INPE, 12227-010, São José dos Campos, SP

2- Laboratório Associado de Computação e Matemática Aplicada, INPE, 12227-010, São José dos Campos, SP

Resumo

A previsão do nível de um rio para um tempo futuro pode auxiliar a economia e a população que é servida pelo rio em questão. Pretende-se com este trabalho, um estudo da utilização de técnicas SOM e LVQ para verificar sua utilidade em um processo para prever o nível do rio Paraguai. Os resultados sendo satisfatórios poderão encorajar a utilização dessas técnicas e métodos em outros rios para auxiliar na elaboração de políticas que venham a influenciar a população ribeirinha positivamente, tanto economicamente quanto socialmente, considerando inclusive o aspecto ambiental.

Palavras-chave: data mining, previsão, SOM, aplicação.

1. Introdução

O Brasil é um país de dimensões continentais e de diversidades ambientais que o tornam um território rico em recursos naturais, e que por isso mesmo, necessita de vigilância constante em todos os sentidos dessa palavra. A previsão de cheias ou vazantes ajuda no planejamento e manuseio de recursos sociais, trazendo benefícios econômicos e sociais, pois permite, por exemplo, manusear rebanhos, salvar equipamentos e deslocar famílias que estejam em áreas sob risco de enchentes ou preparar-se para períodos de estiagem mais significativos.

Dentre esses recursos hídricos, dos vários rios e cursos d'água que o país possui, destacaremos o rio Paraguai, que será parte do nosso trabalho.

A previsão do comportamento dele é uma ferramenta muito importante para se saber o que acontecerá em um futuro próximo, tanto que existem vários títulos sobre esse tema, tais como [Muller & Fill, 2003], [Kisi, 2003], [Atiya et al, 1999], [Weigang et al, 1998] e [Phien, Danh & Gupta, 1999]. Neles utiliza-se principalmente Redes Neurais Artificiais para obter previsões sobre o comportamento dos rios.

Um artigo de [Weigang et al, 1998], sobre a utilização de Redes Neurais para previsão do nível do rio Paraguai, informa que conseguiram fazer previsões para períodos com até 4 meses de antecedência, com taxas de erro de

17%. Para esse artigo, utilizou-se uma seqüência de informações sobre o nível do rio Paraguai e que vem se acumulando há mais de 100 anos. Essas informações são de um tipo de observatório localizado no município de Ladário – MS. Essa base de dados contém informações obtidas diariamente, tornando-se num importante conjunto de dados reais. A referência ao rio Paraguai é porque tem grande importância para a região, pois é ele e outros rios afluentes que alimentam o Pantanal Mato-grossense.

O artigo explica como foram realizados os processos para a previsão dos níveis do rio Paraguai, em que utilizou a média mensal dos níveis do rio e Redes Neurais para gerar os valores da previsão, obtendo assim os resultados aceitáveis para determinados períodos, dado um certo período de treinamento.

2. SOM

SOM, *Self Organizing Map*, conhecido também como Mapa de Kohonen, é um método de aprendizado não supervisionado de uma rede neural artificial, que é o aprendizado que provém dos próprios dados sem a intervenção externa para classificações próprias dos dados de treinamento. Para [Beale, 1990], o SOM de Kohonen utiliza aprendizado não-supervisionado para modificar estados internos da rede para modelar as características encontradas nos dados de treinamento.

Uma implementação do algoritmo de Kohonen geralmente resulta em uma matriz de duas dimensões, como a Figura 1 mostra uma rede típica do mapa de Kohonen. Notamos na figura, que os neurônios representados pelos círculos N_1 , N_2 , N_n , estão em plano único bi-dimensional, não estão arranjados ou organizados em planos diferentes (somente em um único plano), todos as entradas (X_0 , X_1 , X_n) estão conectadas aos nós (neurônios) da rede, e não existe um plano de saída, ou seja cada nó da rede é a própria saída do resultado gerado pelo neurônio, e a realimentação das informações é limitada às conexões laterais dos nós vizinhos.

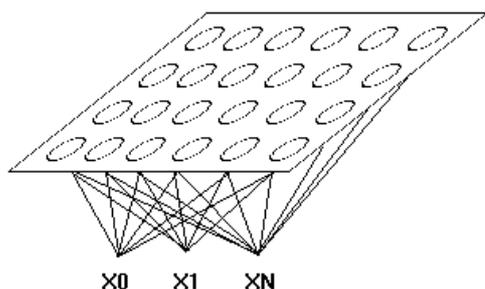


Figura 1 - Esquema do Mapa de Kohonen

O objetivo básico do SOM é classificar os dados de entrada. Nesse objetivo, um algoritmo SOM encontra os nós que combinam ao máximo com as entradas de treinamento, melhorar a similaridade desses nós e enquadrar as entradas na vizinhança mais próxima desses nós. Para isso, o algoritmo de aprendizado organiza os nós de uma rede em vizinhanças locais, que funciona de certo modo como classificador dos dados de entrada. Assim, gera um mapa topológico organizado autonomamente por processo cíclico de comparação dos dados de entrada com os dados armazenados nos vetores em cada nó. E isso sem a necessidade de especificar respostas ou resultados às informações de entrada. Se os dados de entrada corresponderem aos vetores nos nós, indica que a área do mapa topológico que o contém será otimizado seletivamente, para representar a média dos dados de entrada para aquela classe. Isto é representado em uma grade com uma área destacada no mapa auto-organizado, a partir de conjunto de nós organizado aleatoriamente.

Inicialmente todas as conexões que vão das entradas aos nós são inicializadas com valores baixos e aleatórios. Cada nó tem um único vetor peso e o número de componentes de entrada define a sua dimensão. O treinamento consiste em inserir conjuntos de dados representativos das classes de entrada. A reação da rede ao estímulo apresentado pode ser comparado a uma função do tipo “vencedor-leva-tudo”. Da comparação que ocorre entre cada um dos dados de entrada e os vetores peso, obtém-se o nó vencedor ou neurônio vencedor, isto é, o nó que mais se aproxima do padrão dos dados de entrada e este modifica seu vetor peso através do vetor de entrada. Dessa forma, este nó torna-se sensível a este tipo de entrada de treinamento e dará ótimos resultados à rede quando for aplicada após a fase de treinamento.

Outro fato importante é que a rede tende a criar regiões que respondam melhor aos dados de treinamento de entrada. O ciclo de treinamento fará que os nós próximos ao nó vencedor tenham similaridades indicando uma representação de classes de entrada distintas. Como consequência, vetores semelhantes aos de treinamento serão classificados corretamente, mesmo que nunca tenham sido utilizados anteriormente na rede.

O processo de adaptação dos pesos e o conceito de vizinhança dos nós são os pontos centrais da aprendizagem auto-organizada adaptativa da rede de Kohonen.

Sobre os vetores peso, já mencionados anteriormente, eles influenciam na taxa de aprendizagem da rede, ou seja, são valores que controlam o decremento do número de ciclos utilizando os dados de treinamento. No processo de treinamento, primeiro cria-se alguma forma de ordenar um mapa de nós orientados de forma aleatória, e tenta-se então criar grupos de nós para destacar as classes encontradas nos dados de treinamento. É um mapeamento inicial em que descobre-se quais e quantas são as classes da rede e quais são as relações existentes entre eles.

Para isso é necessário uma taxa de adaptação alta para permitir alterações significativas do vetor peso e assim estabelecer um mapa de vizinhança mais rapidamente. Ao se estabilizar uma situação, um processo de sintonia conduz a redução do valor de alteração dos vetores peso de todos os nós, e conseqüentemente a evolução do ciclo de treinamento será reduzido. Portanto percebemos com isso, a influência dos vetores peso para o treinamento e aprendizado da rede.

A vizinhança estabelece regiões de similaridade das classes dos dados de entrada. Em um processo análogo ao modelo biológico, em que as células neurais afetam com maior intensidade suas vizinhas que têm contatos físicos (axiônios), os nós mais próximos ao nó que tem maior correspondência aos dados de entrada, devem ter também essa similaridade representada em algum grau. É isso que o algoritmo tenta organizar, ou seja, arrumar os nós que tem características semelhantes em regiões cada vez mais próximas, se não juntos. [Beale, 1990] exemplifica os efeitos das interconexões laterais dos axiônios pela função “*Mexican hat*”, estudado por Kohonen. Disso vem o modelamento em redes interconectadas localmente com restrição das adaptações dos pesos para vizinhanças localizadas.

A idéia de vizinhança topológica introduzida por Kohonen, é a de uma área em que os limites ou fronteiras são alterados dinamicamente, que indica a influência das modificações dos pesos dos nós vencedores nos nós vizinhos. Como exemplo, [Beale, 1990] indica que inicialmente cada nó da rede tem uma vizinhança correspondente à toda a rede. Quando um nó é selecionado como semelhante a algum dado de entrada, esse nó terá seu peso ajustado para sensibilizar-se melhor às entradas, embora todos os nós da vizinhança possam também se adaptar pelo mesmo valor. Então, à medida que ocorre o treinamento, o tamanho da vizinhança será reduzido paulatinamente por um valor predefinido. Assim ao atingir o limite de número de nós restantes estabelecidos anteriormente, indicam que os nós pertencentes à região estarão adaptados para representar a extensão média dos dados de treinamento da classe escolhida.

O algoritmo de treinamento gera agrupamentos de todos os tipos de classes que existirem nos dados de treinamento, e tanto a seqüência quanto o número de convergências dependem do modo como os dados de treinamento foram inseridos na rede. O treinamento ocorre à medida que a rede aprende sobre os dados de treino, os ciclos são

reduzidos e os valores dos pesos são alterados utilizando uma taxa de adaptação, e assim desenvolver a rede. Para [Beale, 1990], isto indica que o agrupamento forma uma representação precisa dos dados de treinamento assim como a rede converge para uma solução em um tempo predefinido. E cita que Kohonen sugere utilizar para a taxa de adaptação dos pesos, uma função de decremento linear do número de execuções dos dados de treinamento.

Apesar de ser um método de aprendizado não supervisionado, ao efetuar uma rotulação manual para identificar os agrupamentos e suas classes obtidas na fase de treinamento, consegue-se classificar e identificar os dados desconhecidos inseridos na rede auto-organizada. Essa rotulação manual será efetuada após treinamento total da rede.

Em poucas palavras, um algoritmo de aprendizagem SOM organiza os nós (neurônios) em vizinhanças locais como um classificador dos dados de entrada, gerando um mapa topológico que será auto-organizado por processos cíclicos de comparação entre esses dados de entrada e os valores dos vetores-peso já treinados de cada nó (neurônio). A auto-organização indica que os nós da área próximo ao nó que mais corresponder ao dado de entrada terão os valores otimizados para representar melhor a classe do dado de entrada. No final teremos uma matriz que exhibe em um mapa característico, a representação local auto-organizada do conjunto de nós antes organizados aleatoriamente.

3. Dados utilizados

As informações que compõem o conjunto de dados são os valores medidos com uma régua de medição do nível do rio Paraguai, obtidos diariamente desde 1900 compoendo uma base de dados com mais de 100 anos de medidas. Essa régua de medição está localizada no município de Ladário que está situada às margens do rio Paraguai [IBGE].

O rio Paraguai tem uma extensão de 2.621 km até sua foz no rio Paraná, sendo 1620 km no Brasil. É o principal dreno coletor das águas da Bacia do Alto Paraguai (BAP) (Figura 2), que compreende o Pantanal e os planaltos adjacentes. Assim, comporta-se tal qual um corredor de águas do Pantanal.

Dentre os vários postos de medição de níveis de água do Rio Paraguai, destaca-se o do Ladário, vizinho de Corumbá, por ser o que mais dispõe de dados de toda uma rede instalada no Pantanal. O observatório de medição de Ladário acumula informações de registros diários desde o ano 1900 a 2000 sem falhas e se destaca também porque por ali passa 81% de vazão média do volume de água da Bacia do Alto Paraguai que sai do território brasileiro para o território paraguaio.

Dessa forma, essa régua de medição dos níveis do rio Paraguai, instalada no 6º Distrito Naval da Marinha Brasileira (em Ladário) constitui-se no principal referencial do regime hidrológico da Bacia do Alto Paraguai (Figura

2), possibilitando até caracterizar um dado período de seca ou de cheia. Considera-se ano de cheia quando o nível máximo do rio Paraguai em Ladário supera o nível de alerta de enchente, historicamente em 4,0 metros, caso contrário, ano de seca se ficar abaixo de 2,0 metros.



Figura 2 - Bacia do Alto Paraguai (Ministério dos Transportes)

Vale observar que as cheias do Pantanal devem-se às características do relevo e à concentração das chuvas durante o verão na região da Bacia do Alto Paraguai. O relevo, na parte elevada da bacia possui altitudes entre 200 e 700 metros. O Pantanal, por sua vez, apresenta uma declividade de 0,7 a 5 cm/km no sentido norte-sul e entre 7 a 50 cm/km no sentido leste-oeste, isto é, praticamente plano como podemos ver na Figura 3, em que se observa a declividade do rio Paraguai em relação à sua extensão desde Cáceres (MT) até sua foz no Rio Paraná. Soma-se a isso, o volume de água que vem do planalto (parte elevada da bacia) e o volume das chuvas locais. Tem-se então as enchentes, pois o escoamento das águas é muito lento, favorecendo inundação em áreas extensas [Embrapa, 2003].

Nessas ocasiões o ecossistema do Pantanal pode chegar a 135 mil km² dos 366 mil km² que a bacia do rio Paraguai ocupa de acordo com o Plano de Conservação da Bacia do Alto Paraguai [Pesca, 2003].



Figura 3 – Declividade do Rio Paraguai (Ministério dos Transportes¹)

Faixa	nível inicio	nível fim
A	-1	-0,5
B	-0,49	0,01
C	0	0,49
D	0,5	0,99
E	1	1,49
F	1,5	1,99
G	2	2,49
H	2,5	2,99
I	3	3,49
J	3,5	3,99
K	4	4,49
L	4,5	4,99
M	5	5,49
N	5,5	5,99
O	6	6,49
P	6,5	6,99
Q	7	7,49
R	7,5	7,99
S	8	8,49

As medidas obtidas em Ladário geraram os dados, que é exemplificado na Tabela 1:

- Dia, mês e ano: informam a data em que foi realizada a observação da régua de medição do nível do rio Paraguai;
- Altura da coluna de água: informa a medida observada do nível do rio Paraguai;

Tabela 1 – Exemplo das informações tabuladas dos dados de Ladário – MS

Níveis do rio Paraguai na estação Limnimétrica de Ladário (MS) 1900-2005			
DIA	MES	ANO	Altura da Coluna de água
1	1	1900	1,86
2	1	1900	1,85
3	1	1900	1,85
4	1	1900	1,85
5	1	1900	1,85
6	1	1900	1,85
7	1	1900	1,85
8	1	1900	1,85
9	1	1900	1,85
10	1	1900	1,85
⋮	⋮	⋮	⋮
5	4	2005	3,00
6	4	2005	2,99

5. Experimentos e resultados obtidos

Os experimentos objetivam gerar os dados de entrada para a aplicação de software SOM. Resumidamente, deseja-se criar um mapa com padrões gerados pelos algoritmos e classificá-los de forma automática, para que qualquer outro conjunto de dados (do mesmo rio) possa gerar previsão com erros menores dos que foram obtidos em [Weigang et al, 1998].

Utilizamos nos experimentos, valores de nível de rio discretizados, de forma empírica, como é mostrado na Tabela 2.

Tabela 2 - Valores discretizados do nível do rio Paraguai

A Tabela 2 mostra os valores dos níveis do rio Paraguai discretizados em faixas (de A até S), realizados empiricamente de 0,5 m em 0,5 m. Esses valores foram utilizados nos experimentos deste trabalho para continuar o processo de avaliação dos resultados, e em outros experimentos, utilizou-se faixas de 1,0 em 1,0 m que não serão apresentados neste trabalho, sendo somente mencionados como experimentos já realizados.

Uma parte dos resultados obtidos de um experimento pode ser observada na Tabela 3.

Tabela 3 - Parte dos resultados de um experimento

média 1	média 2	média 3	média 4	média 5	...	média 14	média 15	Faixas
1,85	1,85	1,86	1,91	2,04	...	2,65	2,77	D
2,87	2,99	3,1	3,21	3,29	...	3,91	4,04	F
4,12	4,18	4,23	4,25	4,26	...	4,16	4,09	F
4,03	3,97	3,92	3,86	3,8	...	2,63	2,47	D
2,3	2,03	1,86	1,82	1,79	...	1,96	2,01	D
2,01	2,01	2	2	2,04	...	3	3,11	E
3,23	3,34	3,44	3,54	3,63	...	4,34	4,37	F
4,39	4,39	4,36	4,33	4,31	...	3,68	3,59	E
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2,54	2,35	2,16	1,96	1,81	...	1,64	1,68	C
1,69	1,71	1,71	1,69	1,89	...	2,7	2,7	D

Esta tabela, ordenada pela coluna da previsão denominada Faixas, exhibe os resultados tabulados das médias obtidas de 5 em 5 medidas sequenciais. Assim cada linha contém 15 células com as médias calculadas e também a célula com valor discretizado da previsão. Esse valor discretizado, foi obtido através da média das 3 medidas consecutivas após a última medida do período em processamento. Em outras palavras, cada célula da tabela contém a média simples das medidas em que a primeira medida de cada célula pode ser calculada como uma progressão aritmética de regra 5 em que o primeiro elemento é A1. O valor da célula da previsão de cada linha somente será calculado e discretizado utilizando a Tabela 2, quando todas as 15 médias da linha forem calculadas. Para este exemplo, utilizamos como parâmetro, 15 médias, mas poder-se-ia optar por outro valor de parâmetro. Nota-se que

¹ <http://www.transportes.gov.br/bit/hidro/figuras/perfil-paraguai.jpg>

a previsão citada acima pode ser considerada como a tendência dos valores anteriores a ela.

Observa-se que o aplicativo é totalmente parametrizado, podendo-se, portanto realizar os experimentos através da mudança de parâmetros tais como: número de amostras, número de dimensões, tipo de processamento, e até os valores das faixas, aumentando-se ou diminuindo o número das mesmas. O número de faixas dos valores discretizados pode ser alterado também, como já mencionado acima. Pode-se, por exemplo, aumentar o número de faixas reduzindo o intervalo entre cada faixa.

Com os dados obtidos no experimento 2, utilizou-se outro aplicativo para gerar os valores da Tabela 4, que utiliza técnicas SOM. Neste experimento foram utilizados como parâmetros: dimensão igual a 15, isto é, número de pesos para cada posição (neurônio) da matriz; altura igual a 10 e largura igual a 10, para gerar uma matriz de 10 x 10 posições e outros parâmetros que poderiam ser alterados para melhorar os resultados.

Tabela 4 - Parte dos resultados – experimento – SOM

linha	coluna	peso 1	peso 2	peso 3	peso 4	peso 5	...	peso 14	peso 15	qtde resultados
0	0	3,94	3,84	3,73	3,61	3,47	...	1,71	1,56	7
0	1	3,67	3,57	3,47	3,36	3,24	...	2,06	1,99	5
0	2	3,87	3,78	3,68	3,57	3,46	...	2,36	2,26	5
0	3	3,69	3,85	4,01	4,18	4,35	...	6,21	6,27	3
0	4	3,27	3,41	3,54	3,7	3,9	...	5,17	5,18	7
0	5	2,59	2,64	2,75	2,89	3,09	...	6,6	6,63	1
.
.
.
9	7	1,43	1,46	1,47	1,58	1,69	...	3,18	3,28	2
9	8	2,5	2,5	2,51	2,52	2,53	...	2,71	2,7	6
9	9	2,13	2,16	2,19	2,19	2,22	...	3,05	3,17	6

Cada linha da Tabela 4 contém nas colunas 3 a 17 (peso 1, peso 2,..., peso15), valores para gerar um gráfico. A primeira coluna contém o número da linha da matriz que contera o gráfico e a segunda coluna contém o número da coluna na matriz, observando que neste trabalho, a matriz inicia com linha 0 e coluna 0. As outras colunas contêm os valores dos pesos dos neurônios, exceto a última coluna que contém o valor da quantidade de resultados positivos das comparações para o gráfico na matriz resultado.

Os experimentos foram realizados mediante execução de pré-processamento para gerar os dados de entrada do aplicativo SOM. Nessa fase, foram gerados valores com médias de 5 em 5 medidas, 10 em 10 medidas, de 15 em 15 medidas e até de 30 em 30 medidas.

Os parâmetros foram variados para ter maior diversidade de experimentos. Esses parâmetros são: taxa de aprendizado, taxa mínima de aprendizado, taxa de decaimento do aprendizado, taxa de atualização da área da vizinhança local (raio), taxa de decaimento do raio e taxa mínima de atualização do raio.

As variações dos experimentos realizados, que podem ser parcialmente vistos na Tabela 5, foram principalmente nas taxas de aprendizagem, taxa de decaimento do raio (da vizinhança local), além de, em algumas oportunidades, variar-se também as taxas mínimas de atualização do raio.

Na Tabela 5, visualiza-se parte dos experimentos realizados, assim como os números de passos de treinamento realizados pelo aplicativo.

Tabela 5 - Parte dos experimentos realizados

	médias de médias	num registros	num de médias por registro	dimensão	altura	largura	taxa de aprendizado	tx min aprendiz	tx decaimento aprendiz	tx atual raio	tx decaimento raio	tx min atualização raio	num passos de treinamento
A	5 em 5	512	15	15	10	10	0,9	0,01	0,01	8	0,1	1	448
A1	5 em 5	512	15	15	10	10	0,9	0,001	0,001	8	0,1	1	8900
A2	5 em 5	512	15	15	10	10	0,9	0,0001	0,0001	8	0,1	1	91031
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
0	15 em 15	170	15	15	10	10	2	0,001	0,001	50	0,1	1	7598
01	15 em 15	170	15	15	10	10	2	0,001	0,001	50	0,01	1	7598
02	15 em 15	170	15	15	10	10	2	0,001	0,001	50	0,001	1	7598
03	15 em 15	170	15	15	10	10	2	0,001	0,001	50	0,0001	1	39112
04	15 em 15	170	15	15	10	10	2	0,001	0,001	50	0,00001	1	390676

6. Conclusões

Pelas observações dos resultados gerados pelas diversas experiências, percebeu-se que ao variar para menor a taxa de decremento do raio da vizinhança local, ocorreu uma certa variação nos resultados gerados pelos neurônios.

Ao se variar o valor da taxa de aprendizado, aumenta-se o número de passos de treinamento, refletindo em maior diferenciação pelos neurônios das classes existentes nos dados de treinamento.

O tamanho da dimensão do mapa, ou seja, da matriz, contribuiu para melhorar ainda mais a classificação dos elementos de treinamento.

Por outro lado, o número de médias utilizadas para gerar as entradas influencia no detalhamento do resultado, isto é, se for um valor muito reduzido, pode-se gerar resultados sem expressividade, como foi observado com médias de 5 em 5 medidas, mas se aumentar muito o número de medidas utilizadas para realizar as médias, como de 30 em 30 medidas, os resultados também podem ser distorcidos.

Resumindo as conclusões, o número de medidas utilizadas para gerar os valores de entrada é importante para definir o detalhamento dos resultados desejados. Quanto maior o número de medidas utilizadas para gerar as médias, melhor será a diferenciação que os neurônios serão capazes de realizar. Mas para que essa diferenciação seja perceptível, será necessário que a dimensão do resultado, isto é, a matriz que será gerada pelo algoritmo SOM, seja também detalhada. Isto significa que a rede deve estar preparada para gerar um mapa com pelo menos 20x20 neurônios. Outro ponto observado é que o número de passos de treinamento também reflete na qualidade dos resultados que os neurônios podem fornecer.

Novos experimentos ainda serão realizados, com outras variações dos parâmetros mencionados anteriormente. Também serão realizados experimentos utilizando-se algoritmo de LVQ (Learning Vector Quantization) [Beale, 1990][Fausett, 1994] nos próximos passos, para a conclusão do Curso de Mestrado, de onde foi baseado esse trabalho.

7. Referências

- [Atiya et al, 1999] Atiya, Amir F., El-Shoura, Suzan M., Shaheen, Samir I. and El-Sherif, Mohamed S., A Comparison Between Neural-Network Forecasting Techniques – Case Study: River Flow Forecasting, IEEE Transactions on Neural Networks, vol.10, no.2, march 1999.
- [Beale, 1990] BEALE, R, JACKSON, T., Neural Computing An Introduction, Adam Hilger, 1990
- [Becceneri et al, 2004] Becceneri, Jose C, Kono, Yasuo, Gatto, Rubens C., Santos, Rafael., Avaliação de Árvores de Decisão para Data Mining de Dados Meteorológicos, SPOLM 2004.
- [Embrapa, 2003] Galdino, Sérgio, Resende, Emiko Kawakami, Previsão de Cheias e Secas da Embrapa Auxilia Pantaneiros, <http://www.cpap.embrapa.br/publicacoes/online/ADM004>, 26.07.2005
- [Fausett, 1994] FAUSETT, Laurene, Fundamentals of Neural Networks – Architectures, Algorithms, and Applications, Prentice Hall International, 1994
- [IBGE] Instituto Brasileiro de Geografia e Estatística/Cidades, Estimativa Censo 2004 - 19.08.2005
- [Kisi, 2003] Kisi, Özgür, Daily River Flow Forecasting Using Artificial Neural Networks and Auto-Regressive Models, Istanbul Technical University, Faculty of Civil Engineering, Istanbul-Turkey, 2003
- [Muller & Fill, 2003] Muller, Mauricio, Fill, Heinz Dieter, Redes Neurais Aplicadas na Propagação de Vazões, XV Simpósio Brasileiro de Recursos Hídricos, 2003
- [Pesca, 2003] Agência Brasil, Pantanal Vive Situação Atípica de Seca e Cheia Simultâneas, 20/08/2003, <http://www.pesca.com.br/noticias/noticias/lista.asp> - 29.07.2005
- [Phien, Danh & Gupta, 1999] Phien, Huynh Ngoc, Danh, Nguyen Tan, Gupta, Ashim Das, Neural Network Models for River Flow Forecasting, Asian Institute of Technology, Thailand, 1999
- [SAS, 2005] Sas, Corina, Machine Learning, Computing Department, Lancaster University, <http://www.comp.lancs.ac.uk/computing/users/dixa/teaching/MScHCI/notes-2004/Machine-Learning.pdf> - 05.07.2005
- [Weigang et al, 1998] Weigang, Li, Abreu Sá, Leonardo D. de, Galvão, Geraldo P., Bevilaqua, Rute M., Prediction of the level of Paraguay River using Neural Networks, Pesq.Agropec.Bras. – Número Especial, 1998