



Inversão de Parâmetros de Aquíferos através de Redes de Funções de Base Radial

Telesson Neves Teles e Emerson Araújo do Carmo

CPGG/DEE/UFBA

ABSTRACT

Usually, the aquifer hydraulic parameters are determined by comparing the field drawdown of the piezometric level curve, measured in a observation well, with the standard one (Theis's curve). In this paper we present the possibility of solving the inverse problem for confined aquifer parameters by using radial base function (RBF) networks. We design, train and test a RBF network by using synthetic modeling data. The results presented here show excellent fitting between estimated and observed data, obtained from estimated and true hydraulic parameters respectively. The proposed procedure shows to be a good strategy for inversion of confined aquifer field data.

INTRODUÇÃO

A determinação das propriedades hidráulicas de aquíferos, em particular o coeficiente de armazenamento e a transmissividade, é de grande importância no dimensionamento de poços para extração de água subterrânea. A técnica utilizada para se determinar tais propriedades é conhecida como ensaio de bombeamento. Nele a água de um poço produtor é bombeada a uma taxa constante enquanto se observa o rebaixamento do nível piezométrico com o tempo em um ou mais poços de observação. Constrói-se, desta forma, uma curva de rebaixamento versus tempo de bombeamento para o aquífero em questão. Esta curva é, então, sobreposta à curva padrão de Theis e um ajuste visual entre as mesmas é realizado (Hantush, 1964). A partir desse ajuste, e com o uso de duas equações adicionais, o coeficiente de armazenamento e a transmissividade são determinadas. Atualmente, as redes neurais artificiais (RNA), pela sua eficiência na solução de problemas complexos (multivariáveis e não lineares), vem sendo utilizadas em diversas aplicações geofísicas (Macias and Sen, 1993; Pimentel e Teles, 1997; Teles and Emerson, 1999) e constituem uma solução alternativa para o problema em referência.

Neste trabalho dimensionamos e aplicamos uma rede neural de funções de base radial (RBF) ao problema da determinação do coeficiente de armazenamento e da transmissividade, a partir de dados do ensaio de bombeamento para aquíferos confinados submetidos a regimes de fluxo não estacionários. Trata-se de uma rede multicamada em que as funções de ativação dos neurônios da camada oculta são funções Gaussianas com centros e variância determinados por treinamento não supervisionado. A camada de saída é um combinador linear das saídas destes neurônios. Os pesos sinápticos da rede são treinados de modo supervisionado através do algoritmo de retropropagação do erro. A modelagem com tais redes encontra precedentes nas redes neurais biológicas, onde são identificadas, em algumas estruturas corticais, células altamente sintonizadas em torno de campos receptivos bem definidos. Os resultados obtidos mostraram-se bastantes satisfatórios, revelando uma boa generalização do problema por parte da rede RBF.

PARÂMETROS DE AQUÍFEROS

Trataremos aqui de aquíferos confinados com poço totalmente penetrante submetido a regime de fluxo não estacionário. Quando um poço é bombeado, ocorre na vizinhança do mesmo uma queda do nível de água denominada de rebaixamento (s). A superfície da água descreve o chamado cone de depressão, centrado no poço produtor. Quando o bombeamento acontece por longos períodos, a expansão e a profundidade do cone de depressão variam.

Em 1935, Theis desenvolveu uma expressão para o cálculo do rebaixamento em função do tempo de bombeamento no poço produtor, conhecida como fórmula do regime não estacionário:

$$s = \frac{Q}{2 \pi T} \int \frac{r^2 S}{4 T t} \frac{e^{-u}}{u} du$$

onde s é o rebaixamento, r é a distância do poço produtor ao poço de observação, Q é a vazão do poço produtor, t é o tempo de bombeamento, T é a transmissividade e S é o coeficiente de armazenamento. Sendo esses dois últimos os parâmetros a serem estimados no presente trabalho. A expressão acima foi utilizada na modelagem direta, isto é, na obtenção dos dados sintéticos (curvas) de rebaixamento x tempo.

REDES NEURAIS DE FUNÇÕES DE BASE RADIAL

Essas redes são caracterizadas pela seguinte topologia: uma camada de entrada, onde os dados de rebaixamento serão aplicados, uma única camada oculta com função de ativação Gaussiana, e uma camada de saída com um combinador linear, de onde o vetor de parâmetros será extraído. A figura 1 ilustra uma rede RBF. As funções Gaussianas são exemplos de funções de base radial, as quais geram respostas significativas somente quando o sinal de entrada se encontra dentro de uma pequena região em torno do centro da função, conforme mostra a figura 2. Essa região é conhecida como campo receptivo.

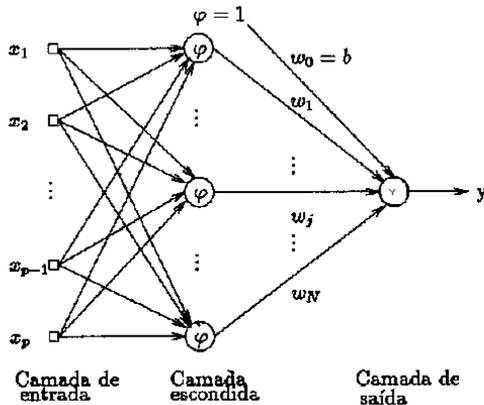


Figura 1: Rede RBF

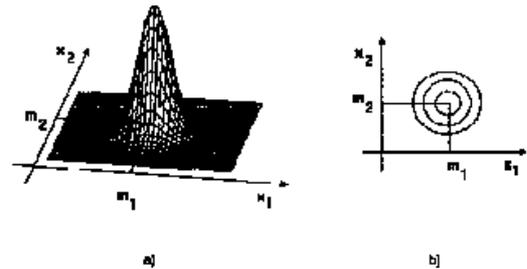


Figura 2: Campo receptivo de um neurônio RBF

A equação do sinal de saída de uma rede RBF é:

$$y = \sum_{i=1}^N \omega_i \varphi(\|x - c_i\|)$$

onde c é o vetor com os centros receptivos das funções Gaussianas, x é o vetor de entrada e ω são os pesos sinápticos da rede.

A etapa crucial que determina o sucesso de qualquer rede neural artificial é o treinamento/aprendizado da mesma, o qual é realizado através de exemplos fornecidos à rede. No nosso caso, o conjunto de exemplos constitui-se de diversas curvas $s \times t$ e seus respectivos parâmetros S e T , mantendo-se fixados r e Q . O desempenho das redes RBF depende da determinação de três parâmetros: os centros receptivos e as variâncias das funções Gaussianas e os pesos sinápticos. Os dois primeiros são determinados através de treinamento não supervisionado, enquanto o último é obtido através de treinamento supervisionado, onde a saída da rede é comparada com a saída desejada para o exemplo corrente e o erro é usado na atualização do vetor de pesos sinápticos, através do algoritmo conhecido como retropropagação do erro. Uma descrição pormenorizada das técnicas de treinamento de redes RBF pode ser encontrada no Haykin (1994). Após treinada, a rede deve ser testada com um conjunto de exemplos distinto do conjunto de treinamento. Tal procedimento visa avaliar a generalização da rede antes da mesma ser aplicada ao problema.

RESULTADOS NUMÉRICOS

Utilizamos um conjunto de 100 modelos (curvas $s \times t$) para o treinamento e um outro conjunto de 20 modelos para testar a rede após esta ter sido treinada. Todos os dados foram gerados sinteticamente com a fórmula do regime não estacionário de Theis, dados os parâmetros S e T , com a vazão e a distância poço-piezômetro fixados nos valores $Q=56,6 \text{ m}^3/\text{h}$ e $r=76 \text{ m}$, respectivamente. Os parâmetros S e T foram selecionados aleatoriamente dentro dos seguintes intervalos: $0,00199 < S < 0,0000407$ e $12,3 < T < 53,2 \text{ m}^2/\text{h}$. Para avaliarmos o desempenho da rede, calculamos o índice de ajuste entre as curvas dos dados observados (gerada sinteticamente) e dos dados estimados (obtida com os parâmetros estimados pela rede), através da seguinte expressão:

$$fit = \frac{2 \sum_{i=1}^n s_{obs} s_{est}}{\sum_{i=1}^n s_{obs}^2 + \sum_{i=1}^n s_{est}^2}$$

Onde n é o número de rebaixamentos observados. Apresentamos na tabela a seguir os resultados para o melhor e o

pior modelo estimado pela rede para o conjunto de teste.

	Melhor modelo ($fit=1.00$)		Pior modelo ($fit=0.99$)	
	S	T	S	T
Real	0,0017	39,7662	0,0014	35,0179
Estimado	0,0017	39,7696	0,0014	35,4957
Diferença	0,0000	0,0034	0,0000	0,4778

Podemos observar a ótima generalização alcançada pela rede. Podemos observar também, que o parâmetro melhor ajustado foi o coeficiente de armazenamento S. Acreditamos que tal fato se deve a uma dependência não linear fraca entre o rebaixamento e o parâmetro em questão. A figura 3 mostra curvas de rebaixamentos observados e estimados para dois outros modelos do conjunto de teste. Pode-se observar o perfeito ajuste entre as curvas.

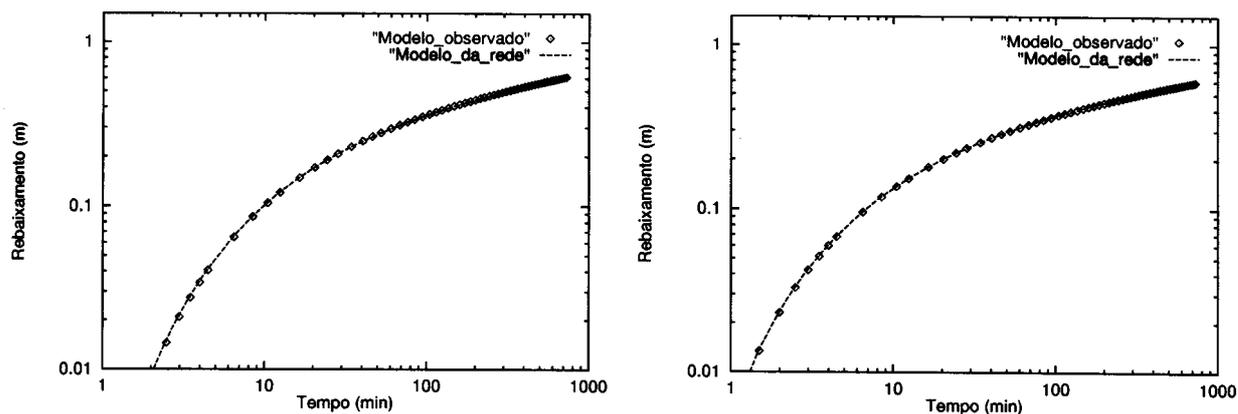


Figura 3 : Curvas de rebaixamento a partir de dados observados e estimados.

CONCLUSÃO

Aplicamos uma rede neural de funções de base radial ao problema de inversão de parâmetros de aquíferos confinados com poço totalmente penetrante submetido a regime de fluxo não estacionário. A rede foi treinada e testada com dados sintéticos obtidos para um amplo intervalo de valores dos parâmetros transmissividade e coeficiente de armazenamento. Os resultados obtidos mostraram uma excelente generalização da rede ao problema em questão. O procedimento de inversão através de redes RBF se apresenta como uma boa estratégia para a determinação de parâmetros de aquíferos.

REFERÊNCIAS

- Cichoki, A. And Unbehauen, R., 1993. *Neural Networks for optimization and signal processing*, John Wiley & sons.
- Hantush, M.S., 1964, *Hdraulics of Wells*, in *Advances in Hydroscience*, primeira edição, Academic Press, New York
- Haykin, S., 1994. *Neural Networks – a comprehensive foundation*, Prentice-Hall.
- Kashyap, D. et al., 1988, *An Optimaztion Model for Analyses of Test Pumping Data*, *Ground Water*, volume 26, num.3, pag. 273-408.
- Macias, C.C. and Sen, M.K., 1993. *Geophysical interpretation by artificial neural system: a feasibility study*, 1993 *International Exposition and SEG annual Meeting*, Expanded Abstracts.
- Pimentel, A.L. e Teles, T.N., 1997, *Interpretação de parâmetros hidráulicos de aquíferos através de redes neurais artificiais*. 5° CISBGf, Resumos Expandidos, vol. 1, 468-470, São Paulo-SP.
- Teles, T.N. and Carmo, E.A., 1999. *DC resistivity data inversion using neural networks*, 1999 *International Exposition and EAGE Conference*, Extended Abstracts (submitted).

ACKNOWLEDGMENTS

Os autores agradecem ao CPGG/UFBA e ao DEE/UFBA. O segundo autor agradece ao CNPq pelo apoio financeiro durante a realização desta pesquisa.