

MODELOS DE REPRESENTAÇÃO GLOBAL PARA CARACTERIZAÇÃO DE SISTEMAS AQUÍFEROS CÁRSICOS

Luís RIBEIRO⁽¹⁾; Leopoldo CORTEZ⁽²⁾; Fernando DURÃO⁽³⁾; Ana R. LOPES⁽⁴⁾

RESUMO

As características específicas dos aquíferos cársicos tornam inválidas quaisquer relações lineares entre a precipitação e o gradiente hidráulico, impossibilitando a aplicação de simuladores numéricos baseados em modelos clássicos de fluxo de águas subterrâneas.

Pretende-se com esta comunicação efectuar uma breve análise a duas metodologias, ambas baseadas em representações globais de aquíferos, usualmente designadas por modelos de “caixa preta” (função de transferência linear e redes neuronais artificiais), e comparar os resultados obtidos, em termos de estimação do nível piezométrico no sistema aquífero Silves-Querença, tendo como dados de partida a precipitação diária na região Algarvia.

Palavras-chave: sistema aquífero cársico, modelos de transferência, redes neuronais, previsão de níveis piezométricos

¹ Investigador, CVRM /, Instituto Superior Técnico, Av. Rovisco Pais, 1096 Lisboa

² Prof. Associado, CVRM /, Instituto Superior Técnico, Av. Rovisco Pais, 1096 Lisboa

³ Prof. Auxiliar, CVRM /, Instituto Superior Técnico, Av. Rovisco Pais, 1096 Lisboa

⁴ Geóloga, Instituto da Água, Av. Gago Coutinho 30, 1000 Lisboa

1 - INTRODUÇÃO

A aplicação dos modelos clássicos de fluxo de águas subterrâneas em sistemas aquíferos cársicos revelam-se pesados e frequentemente de deficiente adequação, devido às especificidades destes sistemas que tornam inválidas as relações lineares entre a precipitação e o gradiente hidráulico. Contudo, a maior parte dos simuladores numéricos disponíveis no mercado baseiam-se na lei de Darcy, e são frequentemente utilizados para simular estes sistemas aquíferos.

Conforme esperado, os resultados obtidos são normalmente pouco robustos e consequentemente revelam um comportamento erróneo destes sistemas. Este problema torna-se mais grave perante condições climáticas extremas, quer de seca quer de cheias, que são normalmente frequentes.

Pretende-se com esta comunicação apresentar sucintamente algumas metodologias baseadas em representações globais de aquíferos, normalmente classificadas como modelos de *caixa preta* (como as funções de transferência lineares e as redes neuronais artificiais), e comparar os resultados obtidos na estimação do nível piezométrico (output) a partir de dados de precipitação diária (input).

Quando os sistemas físicos são demasiado complexos para serem decompostos e analisados, uma das aproximações possíveis é a utilização de modelos lineares do tipo ARX, ARMAX, modelos Box & Jenkins, etc.. No entanto, para sistemas não lineares, a aplicação de redes neuronais está, hoje em dia, a aumentar, tendo-se desenvolvido, nos últimos anos, alguns estudos sobre esta temática (veja-se por exemplo RAMAN e SUNILKUMAR (1995) e CORTEZ e RIBEIRO (1995)).

As redes neuronais artificiais (*Artificial Neural Networks* - ANN) são igualmente uma aproximação *data-driven*, não precisando de qualquer tipo de modelos *a priori* uma vez que constroem a sua própria representação interna dos sistemas. Constituem por sua vez, aproximações universais, cuja estrutura é inspirada no conhecimento dos sistemas nervosos biológicos, os quais permitem aprender a partir dos exemplos e generalizar para situações desconhecidas. Por outro lado, este método exhibe robustez para a incerteza ou lacunas de informação, em consequência da elevada redundância da sua estrutura.

As metodologias mencionadas foram aplicadas ao sistema aquífero Silves-Querença, tendo como dados de partida duas séries piezométricas bem como os registos de precipitação diária de uma estação climatológica, localizada nas proximidades do sistema aquífero.

2 - CARACTERIZAÇÃO HIDROGEOLÓGICA

O sistema aquífero Silves-Querença, do Lias-Dogger, está situado no Algarve e é constituído predominantemente por dolomitos, calcários calciclásticos, calcários oolíticos e pisolíticos, calcários microcristalinos e conglomerados.

Entre o Paleozóico (xistos e grauvaques) e as formações do Lias-Dogger, surge o bordo norte do sistema aquífero, do Triássico, constituído por arenitos, argilas e sedimentos vulcânicos. O bordo sul do sistema aquífero, do Jurássico superior, é formado por margas e margas calcárias, e constitui por sua vez uma barreira impermeável à circulação da água devido à menor permeabilidade destas formações.

No que concerne à espessura das formações do Lias, estas podem atingir os 300 m e cobrem grande parte da área em estudo. O Dogger aflora numa forma descontínua e apresenta menor área de afloramento, contudo a sua espessura máxima atinge os 500 m.

A área em estudo está coberta por 22 piezómetros, dos quais 6 estão equipados com limnígrafos, e inclui registos diários do nível da água desde 1982, com poucas lacunas de informação. No que respeita à precipitação existem igualmente medições numa base diária, desde a mesma data. Verifica-se assim, séries razoáveis de dados de base que permitem ter uma ideia da dinâmica espaço-temporal do fluxo subterrâneo do sistema aquífero.

Num estudo recente (LOPES, 1995), foi analisada a evolução dos padrões piezométricos do sistema aquífero Silves-Querença utilizando-se geoestatística, estatística não paramétrica e outros métodos da análise de dados. Uma das principais conclusões, foi a delimitação de duas áreas com características hidrogeológicas distintas, região E e região W, significando diferentes respostas do sistema à precipitação. Neste contexto, seleccionou-se para o presente estudo as estações AL (na área W) e CL (na área E) representativas de cada uma das áreas consideradas, e que se encontram nas proximidades da estação climatológica de S. Brás de Alportel.

De acordo com CUSTODIO e LLAMAS (1976), para o estudo da correlação entre a precipitação e os níveis piezométricos é mais correcto utilizar, em vez dos valores da precipitação, os seus desvios acumulados relativamente ao valor médio global. Esta nova variável, utilizada no presente estudo, tem a seguinte expressão:

$$d(j) = \sum_{i=1}^j r(i) - j\bar{r} \quad (1)$$

sendo $d(j)$ o desvio acumulado no tempo j , $r(i)$ a precipitação no tempo i e \bar{r} o valor médio global da precipitação para o período considerado.

Estabeleceu-se para o presente trabalho um período de 237 dias de condições hidroclimáticas normais e para validação um período de 60 dias, diferente do anterior e de precipitação intensa. Esta estratégia permite estudar a capacidade de generalização dos modelos considerados e avaliar a sua representatividade para prever situações anómalas.

3 - MODELOS DE FUNÇÕES DE TRANSFERÊNCIA

3.1 - Modelos de funções de transferência lineares

Atendendo que duas séries temporais discretas, $y(t)$ e $u(t)$, $t = T, 2T, nT^1$, estão relacionadas por um sistema linear, as relações de entrada/saída descritas num domínio temporal entre dois sinais pode ser escrito (LJUNG,1987):

$$y(t) = G(q)u(t - n_k) + v(t) \quad (2)$$

sendo q o operador de transferência, $G(q)$ a função de transferência do sistema, $v(t)$ a perturbação aditiva não mensurável e n_k expressa o atraso temporal do input para o output expresso como múltiplo do período de amostragem T . A perturbação $v(t)$ é descrita usualmente como ruído branco filtrado:

$$v(t) = H(q)e(t) \quad (3)$$

sendo $e(t)$ a série da variável estocástica independente, ruído branco, com valor médio 0 e variância λ .

As funções $G(q)$ e $H(q)$ podem ser descritas como funções racionais do operador de atraso, sendo a estrutura geral do modelo, designado por Box-Jenkins dada por:

$$y(t) = \frac{B(q)}{F(q)}u(t - n_k) + \frac{C(q)}{D(q)}e(t) \quad (4)$$

Os dois modelos estruturais mais comuns, casos especiais de (4) são a estrutura ARX:

$$y(t) = \frac{B(q)}{A(q)}u(t - n_k) + \frac{1}{A(q)}e(t) \quad (5)$$

e a estrutura ARMAX:

$$y(t) = \frac{B(q)}{A(q)}u(t - n_k) + \frac{C(q)}{A(q)}e(t) \quad (6)$$

Os termos $A(q)$, $B(q)$, e $C(q)$ são polinómios do operador de atraso q^{-1}

$$\begin{aligned} A(q) &= 1 + a_1q^{-1} + \dots + a_{na}q^{-na} \\ B(q) &= b_1 + b_2q^{-1} + \dots + b_{nb}q^{-nb+1} \\ C(q) &= 1 + c_1q^{-1} + \dots + c_{nc}q^{-nc} \end{aligned} \quad (7)$$

sendo na , nb e nc a ordem dos respectivos polinómios e a_i ($i=1,2,\dots,na$), b_i ($i=1,2,\dots,nb$), c_i ($i=1,2,\dots,nc$) os parâmetros do modelo ajustados.

3.2 - Modelos de redes neuronais não lineares

As redes neuronais são modelos computacionais constituídos basicamente por elementos não lineares ou nós (os simulados “neurónios”) com memória associada, fortemente ligados, actuando em paralelo e ordenados numa ou mais camadas, que processam a informação através duma resposta dinâmica ao estímulos externos.

Numa ANN em multicamadas os neurónios de cada camada estão ligados com os das camadas adjacentes, mas nunca com os do mesmo nível, através de ligações ou conexões com pesos ajustáveis. Dentro duma mesma camada, cada elemento efectua o somatório ponderado de todas as saídas da camada anterior, passa-o através de uma função de transferência não linear e origina um *output* que, multiplicado pelo peso apropriado, é transmitido a todos os neurónios da camada seguinte. Frequentemente é adicionado um elemento “bias” com *output* limitado. Com o intuito de prever séries temporais usando a ANN, deve ser definida uma sequência apropriada. A metodologia mais comum é escolher a ANN como uma rede de atraso temporal, utilizando séries temporais históricas para operar a rede, e um algoritmo de retro-propagação anterior (“back operation”), um método típico de optimização não linear. A aprendizagem deste paradigma é, normalmente a mais utilizada nos modelos ANN, e encontra-se bem documentada em RUMELHART *et al.* (1986).

A aplicação desta metodologia inclui as seguintes etapas:

- a) Escolha da arquitectura do ANN, dos parâmetros iniciais da sequência e dos pesos da rede;
- b) Selecção do atraso temporal de entrada e dos valores de *output* pretendidos para a previsão;
- c) Treino da ANN com séries de entrada/saída correlacionadas e actualização dos pesos de acordo com o algoritmo de retro-propagação até a função de erro atingir um nível aceitável;
- d) “Congelar” os pesos atribuídos e validar a ANN com dados conhecidos. Se a validação atingir os resultados pretendidos, a ANN está pronta a ser utilizada, senão deve-se continuar o treino e testar novamente.

4 - RESULTADOS

4.1 - Modelos de funções de transferência linear

Os modelos de transferência linear para duas séries temporais de *input/output* - desvio acumulado da precipitação (P)/níveis piezométricos AL e CL (P/AL e P/CL) - foram determinados usando o *System Identification Toolbox* (LJUNG,1995), que possibilita de uma forma fácil a utilização de interface gráfica cobrindo a maior parte das respectivas funções. Para cada série temporal de *input/output*, os dados de base utilizados e dos dados para validação foram importados para a interface, após translação das séries para a origem 0. As Figuras 1 e 2 representam as séries temporais utilizadas no cálculo e na validação.

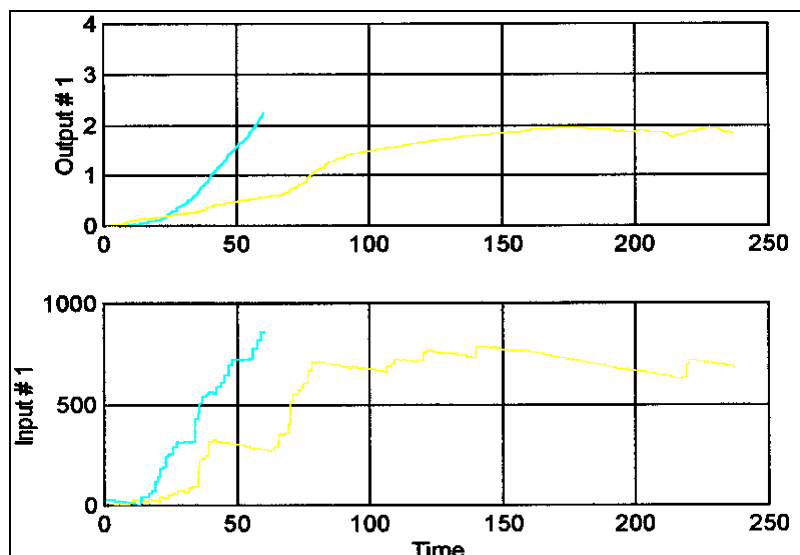


Figura 1 - Séries de treino (série curta) e validação (série longa) para a chuva/AL

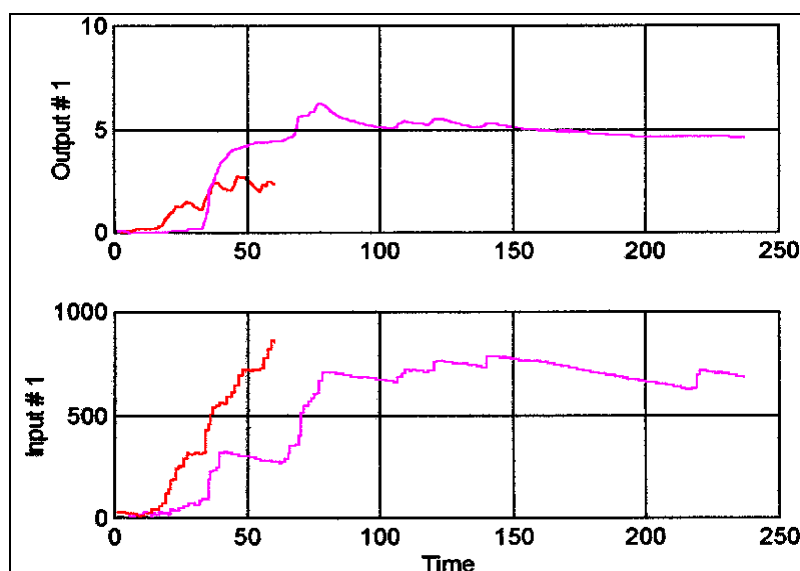


Figura 2 - Séries de treino (série curta) e validação (série longa) para a chuva/CL

Aplicaram-se no presente estudo os dois modelos estruturais mais utilizados. Assim, o modelo estrutural ARX (2) foi o primeiro a ser aplicado, de modo a determinar a ordem mais apropriada dos polinómios A e B, bem como para obter uma estimaco do atraso entre o *input* e o *output*.

No Quadro 1 expressa-se a ordem e o atraso determinados para os dois pares de sries temporais estudadas.

Quadro 1
Resultados das sries temporais estudadas

	P/AL	P/CL
na	3	8
nb	2	6
nk	1	1

Estimações pontuais dos parâmetros do modelo obtiveram-se como uma solução de mínimos quadráticos lineares. A estimação do erro do desvio padrão dos parâmetros foi igualmente calculado. O modelo estimado foi determinado por comparação entre os outputs dos modelos simulados e previstos, com os correspondentes outputs observados, que foram utilizados para validação. O horizonte temporal de previsão foi 5 passos (5T). Os resultados obtidos encontram-se expressos nas Figuras 3 a 6. Verifica-se assim, que a estrutura do modelo ARX ajustado é bastante aceitável como ferramenta de previsão.




Figura 3 - Séries de output (chuva/AL) observadas (A) e simuladas (B)




Figura 4 - Séries de output (chuva/AL) observadas (A) e estimadas (B)




Figura 5 - Séries de output (chuva/CL) observadas (A) e simuladas (B)




Figura 6 - Séries de output (chuva/CL) observadas (A) e estimadas (B)

Os resultados obtidos com o modelo ARMAX (3) foram muito semelhantes aos do ARX, pelo que a sua apresentação não é relevante.

4.2 - Modelos de redes neurais não lineares

Utilizando as mesmas séries para treino e validação dos modelos de transferência linear, usou-se um ANN de 10-15-10, considerando uma “janela” de 10 dias de “desvio acumulado de precipitação” e um período de previsão estabelecido de 5 dias para os níveis piezométricos AL e CL. Nas Figuras 7 e 8 apresentam-se os resultados obtidos.




Figura 7 - Séries de output (chuva/AL) observadas (A) e estimadas para os 5 dias seguintes.




Figura 8 - Séries de output (chuva/CL) observadas (A) e estimadas para os 5 dias seguintes.

O erro quadrático médio final após um treino de 3 000 iterações foi inferior a 0,01.

Conforme esperado, apesar do comportamento complexo e não linear do piezômetro CL, o ajuste das curvas de previsão pela ANN é bastante bom.

5 - CONCLUSÕES

Os resultados obtidos neste estudo preliminar indicam que ambos os modelos são potencialmente robustos e revelam-se como importantes ferramentas de previsão do comportamento de sistemas aquíferos cársicos. Salienta-se ainda a sua utilidade como auxiliares nas decisões de planeamento e gestão de águas subterrâneas.

O estudo irá continuar numa perspectiva de testar outras aproximações.

AGRADECIMENTO

Este trabalho é suportado financeiramente pela JNICT e integra-se no projecto intitulado *Metodologias para a Análise e Gestão de Sistemas Aquíferos Cársicos*.

BIBLIOGRAFIA

CORTEZ, L.; RIBEIRO, L. - "Contribution of Neural Networks for the Space-Time Characterization of Karstic Groundwater Systems". *Proc. Intern. Symp. On Mathematical Methods in Geology*, Pribram, 1995.

CUSTODIO, E. ; LLAMAS, M. R. - "Hidrologia Subterranea", Barcelona, Omega, 1976.

LJUNG, L. - "System Identification. Theory for the User". Prentice Hall, 1987

LJUNG, L. - "System Identification Toolbox User's Guide". The Mathworks Inc., 1995.

LOPES, A. R., - “Contribuição da Geomatématica para o Estudo da Dinâmica Espaço-Temporal do Sistema Aquífero Lias-Dogger do Algarve Central”, *Dissertação de Mestrado*, Universidade Técnica de Lisboa, 1995.

RAMAN, H.; SUNILKUMAR, N. - “Multivariate Modelling of Water Resources Using Artificial Neural Networks”, *Hydrological Sciences*, 40, 2, 1995,145-163,.

RUMELHART, D. ; HINTON, G. ; WILLIAMS, R. - “Learning Internal Representations by Error Propagation”, *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, 1, MIT Press, 1986, 319-364.