

研究报告

基于 RBF 神经网络的水文地质参数识别

张俊艳¹, 魏连伟¹, 韩文秀¹, 邵景力², 崔亚丽², 张建立²

(1. 天津大学管理学院, 天津 300072; 2. 中国地质大学水资源与环境学院, 北京 100083)

[摘要] 水文地质参数识别问题是水文地质学上的一个难题。针对传统水文地质参数识别方法的局限性, 提出了水文地质参数识别的径向基函数 (RBF) 神经网络方法, 并通过算例验证了它的可行性与有效性, 实现了水文地质参数的自动识别, 提高了计算效率, 比 BP 神经网络具有更好的参数识别效果。

[关键词] 地下水; 水文地质参数; 径向基函数 (RBF) 神经网络; BP 神经网络

[中图分类号] P641.8 **[文献标识码]** A **[文章编号]** 1009-1742 (2004) 08-0074-05

1 引言

地下水水文地质参数的识别问题, 也称地下水水文地质参数反演问题, 是水文地质学上的一个研究热点与难点。传统的水文地质参数识别方法为预测—校正法, 该方法具有很大的人为随机性, 并且在参数分区较多的情况下, 通过人为随机的调节, 要达到理想的结果所耗费的时间和精力都是巨大的。近十几年来, 随着生物学、物理学和人工智能的发展, 产生了一些具有全局优化性能且通用性强的智能方法, 如遗传算法、神经网络等, 由于这些智能方法高效的优化性能、无需问题特殊信息的优点而受到各领域广泛的关注和应用, 国内外一些学者也开始将这些智能方法引入到水文地质参数识别的研究中^[1-6]。目前研究水文地质参数识别问题的神经网络方法大多采用 BP 网络, BP 网络在处理复杂的非线性函数逼近问题时, 尽管理论上是可行的, 但是, 其学习效率低, 收敛速度慢, 易陷于局部极小状态, 并且网络的泛化及适应能力都较差。径向基函数 (RBF, radial basis function) 神经网络是 Moody 和 Darken^[7]根据人脑局部调节和交叠感受的特点提出的一种前馈式神经网络, 该网络

既有生物背景又符合逼近理论, 当中心点集选择适当时, 很少的神经元就可获得很好的逼近效果。它还具有唯一最佳逼近点的优点, 其网络的隐层与输出层的连接权与输出成线性关系, 可以采用保证全局收敛的线性优化算法, 因而大大提高了网络的训练速度。鉴于 RBF 神经网络的这些优良性能, 笔者提出水文地质参数识别的 RBF 神经网络方法, 通过算例研究, 并与 BP 神经网络的水文地质参数识别结果进行比较, 证明 RBF 神经网络具有较好的水文地质参数识别效果。

2 水文地质参数识别的 RBF 神经网络

2.1 水文地质参数识别的神经网络机理

水文地质参数识别属于一类参数控制反问题, 所以也称为水文地质参数反演问题, 它根据地下水动态资料来认识水文地质条件, 确定水文地质参数。具体来说, 在探明含水层范围、区分含水层类型后, 建立描述该含水层水流运动的数学模型, 然后利用在该含水层中观测的地下水位变化过程资料来确定数学模型中的参数。比较重要的水文地质参数有渗透系数和导水系数。Neuman 等把参数识别技术分为直接法和间接法^[8], 直接法是在反演边

界值问题上把模型参数当成因变量；间接法是基于一个输出误差标准，参数估计一直迭代直到模型响应与实测的输出接近为止。在利用直接求解法进行水文地质参数识别时，由于描述地下水流运动的数学模型往往是一个偏微分方程，因而很难得到水文地质参数与地下水位（或降深）的反函数关系（或映射关系），所以，试图通过对地下水数学模型求逆来直接计算水文地质参数是很困难的。在地下水系统参数识别问题中，如果能够找到一组地下水位（或降深）与渗透系数、导水系数的函数关系，那么只要得到实测水位，就可以直接识别出渗透系数和导水系数，实现参数的直接求解。神经网络最大的优点是具有强大的非线性函数逼近能力，在人工神经网络模型中，如果给网络的输入、输出赋予特定的物理意义，通过对网络的充分训练可以获得输出端物理量与输入端物理量之间的映射关系^[9]。利用神经网络进行水文地质参数识别的思路是首先通过地下水数值计算得到神经网络的训练样本，然后利用得到的训练样本对神经网络进行训练。当神经网络结构满足一定的训练精度后，利用已经训练好的神经网络和根据水文地质勘测得到的实际地下水位值，可以识别出待估计的水文地质参数。

2.2 RBF 神经网络基本原理

RBF 神经网络结构如图 1 所示，输入层节点只是传递输入信号到隐层，隐层节点（也称 RBF 节点）由像高斯核函数^[10]那样的辐射状作用函数构成，而输出层节点通常是简单的线性函数。隐层节点中的作用函数（核函数）对输入信号将在局部产生响应，也就是说，当输入信号靠近核函数的中央范围时，隐层节点将产生较大的输出。由此可见，这种网络具有局部逼近能力，所以 RBF 神经网络也称为局部感知场网络。

虽然有各种各样的核函数，但最常用的是高斯




图 1 RBF 神经网络结构图

Fig.1 Structure of radial basis function neural networks

核函数^[10]：

$$u_j = \exp[-(\mathbf{X} - C_j)^T(\mathbf{X} - C_j)/2\sigma_j], \quad (1)$$

$$j = 1, 2, \dots, N_h,$$

其中 u_j 是第 j 个隐层节点的输出， $\mathbf{X} = (x_1, x_2, \dots, x_n)^T$ 是输入样本， C_j 是高斯函数的中心值， σ_j 是标准化常数， N_h 是隐层节点数。由式 (1) 可知，节点的输出范围在 0 和 1 之间，且输入样本越靠近节点的中心，输出值越大。采用高斯核函数，具有以下优点：**a.** 表示形式简单，即使对于多变量输入也不增加太多的复杂性；**b.** 径向对称；**c.** 光滑性好，任意阶导数都存在；**d.** 由于该核函数表示简单且解析性好，因而便于进行理论分析。

RBF 网络的输出为隐层节点输出的线性组合，即

$$y_i = \sum_{j=1}^{n_h} w_{ij}u_j - \theta = \mathbf{W}_i^T \mathbf{U}, \quad i = 1, 2, \dots, m, \quad (2)$$

其中 $\mathbf{W}_i = (w_{i1}, w_{i2}, \dots, w_{iN_h}, -\theta)^T$ 为输出层权值； $\mathbf{U} = (u_1, u_2, \dots, u_{N_h}, 1)^T$ 为隐层节点输出。

RBF 神经网络的学习过程分为两阶段。第一阶段，根据所有的输入样本决定隐层各节点的高斯核函数的中心值 C_j 和标准化常数 σ_j ；第二阶段，在决定好隐层的参数后，根据样本，利用最小二乘原则，求出输出层的权值 \mathbf{W}_i 。有时在完成第二阶段的学习后，再根据样本信号，同时校正隐层和输出层参数，以进一步提高网络的精度。

RBF 网络和 BP 网络一样在理论上可近似任何连续的非线性函数。二者的差别在于各使用不同的作用函数，BP 网络中的隐层节点使用的是 Sigmoid 函数，其函数值在输入空间中无限大的范围内为非零值；而 RBF 网络中的作用函数则是局部的。RBF 网络与 BP 网络相比，不但在理论上是前向网络中的最优网络，并且由于该网络输出层是对隐层的线性加权，避免了像反向传播那样冗长的计算，因而具有较高的运算速度。

2.3 基于 RBF 神经网络的水文地质参数识别步骤

利用 RBF 神经网络进行地下水水文地质参数识别的步骤如图 2。

1) 利用随机抽样方法产生 n 组水文地质参数 k （渗透系数）和 S （导水系数）。根据实际的水文地质条件和经验，确定渗透系数和导水系数的大概变化范围，然后在此范围内利用随机抽样的方法产




图2 水文地质参数识别的RBF神经网络流程
Fig.2 Process of hydrogeological parameters identification based on RBF neural networks

生 n 组渗透系数和给水度。

2) 利用地下水数值模拟程序产生 n 组计算水位值 h_{sij} (地下水位)。对每一组渗透系数和导水系数调用地下水数值模拟程序, 得到与每一组水文地质参数相对应的地下水位。

3) 训练样本初始化。为了消除不同量纲的影响以及得到更好的网络训练效果, 对训练样本进行初始化, 将样本都转化为 $[0, 1]$ 区间的值。

4) 建立 RBF 神经网络模型, 根据训练样本进行训练。训练样本越多, 网络的非线性函数逼近能力就越强, 从而参数识别的结果就越好, 因而, 在这一步骤中选择足够多的训练样本对网络进行训练。

5) 对训练好的神经网络进行检验。网络是否达到了较好的参数识别效果, 需要用一些理论上的水文地质参数值进行检验, 如果用于检验的水文地质参数识别效果较好, 则可以利用该网络进行实际的水文地质参数识别。

6) 将实测水位 h_{rij} 加载到已训练好的 RBF 神经网络, 得出水文地质参数的估计值。

3 算例研究

以图3为例, 计算区为一不规则潜水含水层, 模拟面积 150 km^2 , 含水层底板水平, 标高 -10 m , 地面标高 20 m 。该含水层西边界为定水位边

界, 水位为 15 m ; 东边界为流量边界, 模拟期为 20 d 。前 10 d 单宽流量为 $0.5 \text{ m}^3/\text{d}\cdot\text{m}$, 后 10 d 无流量, 南北边界均为隔水边界。此外, 后 10 d 平均降水补给强度为 0.05 m 。区内有一口井, 前 10 d 抽水量为 $2000 \text{ m}^3/\text{d}$, 后 10 d 无抽水。将计算期分为 2 个抽水时期, 各 10 d 。抽水井位于 5 号节点上。将区域剖分为 33 个三角单元, 共 25 个结点。




图3 计算区示意图
Fig.3 The computed area

3.1 地下水数值模拟模型

地下水数值模拟模型是地下水系统参数识别问题的基础, 通常地下水数值模拟模型是在地下水水文地质概念模型的基础上建立起来的数学模型。现将上述研究区概化为非均质、各向异性、单层结构、平面二维非稳定潜水的地下水流, 则可用如下的定解问题来描述:

$$\begin{cases} \frac{\partial}{\partial x} \left(k_x (H - B) \frac{\partial H}{\partial x} \right) + \frac{\partial}{\partial y} \left(k_y (H - B) \frac{\partial H}{\partial y} \right) + Q + \epsilon = S \frac{\partial H}{\partial t} & (x, y) \in \Omega, t \geq 0, \\ H(x, y, t) |_{t=0} = H_0(x, y) & (x, y) \in \Omega, t \geq 0, \\ H |_{\Gamma_1} = H_1 & (x, y) \in \Gamma_1, t \geq 0, \\ k_n (H - B) \frac{\partial H}{\partial n} |_{\Gamma_2} = q(x, y, t) & (x, y) \in \Gamma_2, t \geq 0. \end{cases} \quad (6)$$

式中 H 为潜水含水层的水位标高 (m), k_x, k_y 为潜水含水层 x 方向和 y 方向上的渗透系数 (m/d), k_n 为渗透导数, B 为潜水含水层的底板标高 (m), Q 为潜水含水层的开采强度 (m^3/d), ϵ 潜水含水层的垂向补排强度 (m^3/d) (包括降水入渗量、河流入渗补给量、泉流量等垂向补排量), $q(x, y, t)$ 为潜水含水层流量边界的单宽流量 (m^2/d), S 为潜水含水层的重力给水度, Ω 是潜水含水层的

渗流区域， Γ_1 为潜水含水层水位边界， Γ_2 为潜水含水层流量边界， $H_0(x, y)$ 为潜水含水层的初始水位分布， H_1 为潜水含水层的水位边界值。对于上述地下水数值模拟模型的求解过程是将渗流区域按一定的规律剖分成许多小的子区域，将非均质的含水层按子区域均质化，按特定要求在子区域上定义一个点，称为结点，把整个渗流区域上的连续水头分布离散化为在全部结点上由几个数所组成的数组，然后在离散化基础上，将偏微分方程同边界条件转化为线性方程组，最后解线性方程组求出水头分布。

3.2 参数识别结果

利用 RBF 神经网络对图 3 所示的人工算例进行水文地质参数识别，并与 BP 网络进行比较。网络的输入层为 25，输出层为 9，训练样本为 290，检验样本为 3，参数识别的结果见表 1，地下水的实测水位和计算水位见表 2，检验样本误差见表 3，其中 k_{xi} , k_{yi} , ($i = 1, 2, 3$) 分别为 i 区潜水含水层 x, y 方向上的渗透系数。从参数识别结果和相对误差可以看出，RBF 网络的水文地质参数识别结果的精度明显优于 BP 网络的水文地质参数识别结果。

4 结论

1) 研究了基于 RBF 神经网络的水文地质参数识别问题。利用神经网络方法进行 9 个水文地质参数识别仅仅需要几十秒钟的时间就可以得到较满意的参数识别结果，但传统的预测——校正法需要几个小时甚至几天的时间，因而神经网络方法大大提高了水文地质参数的识别效率。

表 1 BP 网络与 RBF 网络的参数识别结果

Table 1 The result comparison of BP and RBF neural networks

参数	参数标准值	网络的计算值		网络的相对误差/%	
		BP	RBF	BP	RBF
$k_{x1}/m \cdot d^{-1}$	20	19.11	20.16	5	-0.8
$k_{y1}/m \cdot d^{-1}$	10	10.48	10.58	-5	-5.8
S_1	0.1	0.15	0.09	50	10
$k_{x2}/m \cdot d^{-1}$	40	39.35	40.00	2	0
$k_{y2}/m \cdot d^{-1}$	40	38.73	40.01	3	-0.03
S_2	0.18	0.18	0.18	0	0
$k_{x3}/m \cdot d^{-1}$	30	35.37	31.02	-18	-3.4
$K_{y3}/m \cdot d^{-1}$	30	29.87	30.07	0.4	-0.2
S_3	0.14	0.15	0.15	7	7

表 2 地下水计算水位与实测水位

Table 2 The computed water level and the real water level

节点	实测水位		计算水位	
	节点	/m	节点	/m
1	150.000 0	150.000 0	14	149.747 0
2	150.000 2	150.000 2	15	150.029 1
3	149.999 7	149.999 6	16	150.000 0
4	150.000 0	150.000 0	17	150.017 9
5	150.000 2	150.000 1	18	150.005 7
6	149.999 3	149.999 3	19	150.007 9
7	149.999 7	149.999 9	20	150.000 0
8	150.000 0	150.000 0	21	149.999 4
9	149.998 3	149.998 2	22	149.998 6
10	150.006 9	150.007 1	23	149.998 9
11	150.003 3	150.003 9	24	150.000 3
12	150.000 0	150.000 0	25	150.000 3
13	150.013 8	150.013 7		

表 3 检验样本的误差

Table 3 The error of the test sample

参数	1 组			2 组			3 组		
	标准值	识别值	误差/%	标准值	识别值	误差/%	标准值	识别值	误差/%
$k_{x1}/m \cdot d^{-1}$	19.58	19.78	-1	19.61	19.284	2	19.66	19.32	1
$K_{y1}/m \cdot d^{-1}$	18.67	19.14	-2	15.42	15.724	-2	7.02	5.89	16
S_1	0.18	0.19	-5	0.06	0.064	-7	0.23	0.26	-13
$k_{x2}/m \cdot d^{-1}$	40.15	40.19	0.1	40.23	40.22	0.02	40.67	40.45	0.5
$K_{y2}/m \cdot d^{-1}$	49.51	49.46	0.1	35.32	35.26	2	37.73	38.17	-1
S_2	0.28	0.28	0	0.12	0.12	0	0.09	0.089	1
$k_{x3}/m \cdot d^{-1}$	23.91	23.12	3	30.65	33.42	-9	24.42	29.54	-21
$K_{y3}/m \cdot d^{-1}$	22.84	22.932	0.4	33.33	32.59	2	35.84	37.14	-2
S_3	0.14	0.14	0	0.28	0.28	0	0.17	0.18	-6

2) 通过 RBF 与 BP 神经网络的比较表明, RBF 具有更好的水文地质参数识别结果, 并且可省去确定隐含层节点数的困扰。

3) 利用神经网络进行水文地质参数识别, 不能完全代替传统的水文地质参数识别方法, 必须与实际情况的水文地质条件分析相结合, 才会使该方法具有更加实际的应用价值。

参考文献

- [1] Zio E. Approaching the inverse problem of parameter estimation in groundwater models of artificial neural networks[J]. Progress in Nuclear Energy, 1997, 31(3): 301~315
- [2] Balkehair K S. Aquifer parameters determination for large diameter wells using neural network approach [J]. Journal of Hydrology, 2002, 265: 118~128
- [3] 刘国东, 丁晶. 应用人工神经网络求算含水层参数 [J]. 工程勘察, 1997, (1): 25~28
- [4] 邵景力, 魏加华, 崔亚莉. 用遗传算法求解地下水管理模型 [J]. 地球科学, 1998, 23(5): 532~536
- [5] Giacobbo F, Marseguerra M, Zio E. Solving the inverse problem of parameter estimation by genetic algorithms: the case of a groundwater contaminant transport model [J]. Analysis of Nuclear Energy, 2002, 29: 967~981
- [6] Prasad K L, Rastogi A K. Estimating net aquifer recharge and zonal hydraulic conductivity values for Mahi Right Bank Canal project area, India by genetic algorithm [J]. Journal of Hydrology, 2001, 243: 149~161
- [7] Moody J, Darken C. Fast learning in networks of locally tuned processing [J]. Neural Computation, 1989, (1): 281~289
- [8] Neuman S P. Calibration of distributed parameter groundwater flow models viewed as a Multiple-objective decision process under uncertainty [J]. Water Resources Research, 1973, 9(4): 1006~1021
- [9] 刘国东. 新理论新方法在水科学中的应用 [D]. 成都: 四川联合大学, 1997
- [10] 飞思科技产品研发中心. MATLAB 6.5 辅助神经网络分析与设计 [M]. 北京: 电子工业出版社, 2003. 72~74

Hydrogeological Parameter Identification Based on the Radial Basis Function Neural Networks

Zhang Junyan¹, Wei Lianwei¹, Han Wenxiu¹, Shao Jingli², Cui Yali, Zhang Jianli²

(1. School of Management, Tianjin University, Tianjin 300072, China;

2. School of Water Resources and Environment, China University of Geosciences, Beijing 100083, China)

[Abstract] The problem of hydrogeological parameter identification is actually a complex one. With the limit of identifying the parameter by traditional methods, the radial basis function neural networks (RBF) is applied into this area. Not only the parameter identification is automatically realized, but also the problem of local optimization is solved. The feasibility and effectiveness have been proved by the examples.

[Key words] groundwater; hydrogeological parameter; radial basis function (RBF) neural networks; BP neural networks