

基于 RBF 神经网络算法的连拱隧道围岩变形预测方法研究

肖智旺^{1,2}, 钟登华¹

(1. 天津大学建筑工程学院, 天津 300072; 2. 赣州城市开发投资集团有限责任公司, 江西赣州 341000)

[摘要] 利用径向基函数前馈式神经网络的特性, 构建了连拱隧道围岩变形的预测模型, 并利用 Matlab 工具对模型进行求解。最后的工程实例对文章的方法进行了检验, 其结果表明, 此方法具有求解速度快, 结果更为优化、预测效果更好等优点。

[关键词] 连拱隧道; 围岩变形; 变形预测; 径向基函数(RBF); 神经网络

[中图分类号] U45 [文献标识码] A [文章编号] 1009-1742(2008)07-0077-05

1 前言

在公路隧道新奥法施工过程中, 位移监测对于设计和施工起着极其重要的作用。针对已量测到的围岩变形数据, 通过一定的数值分析方法, 可获得围岩日变形速率以及围岩变形收敛时间等重要参数, 从而为正确把握围岩变形规律, 进而确定二次衬砌的合理时机, 均有重要的现实意义。因此, 如何根据实测数据建立合理的围岩变形时程曲线的数学表达式是正确预测围岩变形参数的关键。事实上, 许多学者针对该问题做了大量的研究工作, 所采用的方法大都是多项式回归分析等统计方法。这些方法一般适合于采用全断面隧道开挖方式时围岩变形时程曲线的简单情况, 但是当采用正台阶(即先拱后墙)开挖方式时, 特别是连拱隧道的分步施工, 由于其变形时程曲线形式较复杂, 从上台阶到下台阶的过渡存在反弯点, 采用前述回归分析方法难以精确描述。

近年来迅速发展的人工神经网络(artificial neural networks, ANN)方法为这一问题的解决提供了新的途径^[1]。利用神经网络模型强大的自学习、自适应及非线性映射能力, 可自动构建具有强非线性关

系的围岩时程变形模型。已有学者提出采用 BP 神经网络方法来对围岩变形时程曲线进行拟合和预测^[2~4]。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(radial basis function, RBF)神经网络是 Moody 和 Darken 根据人脑的局部调节和交叠感受这一特点提出的一种前馈式神经网络^[5]。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较好的逼近效果, 它还具有唯一最佳逼近点的优点, 并采用保证全局收敛的线性优化算法, 从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, 笔者提出了基于 RBF 神经网络的连拱隧道施工围岩变形的预测方法, 并通过实例研究, 验证了该方法的可行性与有效性。

2 围岩变形预测的 RBF 神经网络建模

2.1 RBF 神经网络基本原理

一个典型的 RBF 神经网络包括两层, 即隐层(或径向基层)和输出层。图 1 是径向基函数网络

[收稿日期] 2005-10-20; 修回日期 2005-12-31

[作者简介] 肖智旺(1972-), 男, 江西赣州市人, 天津大学建筑工程学院博士研究生, 主要从事公路工程建设管理工作; 钟登华(1963-), 男, 江西赣县人, 天津大学教授, 主要从事水利工程研究

的结构图。图中所示的网络输入维数为 R , 隐层神经元个数为 S^1 , 输出层神经元个数为 S^2 , 隐层神经元采用径向基函数作为传递函数 ($radbas(\cdot)$), 输出层传递函数为线性函数 ($purelin(\cdot)$)。一般径向基函数最常用的是高斯函数, 因此输入 $X_k = (x_1, x_2, \dots, x_R)$ (第 k 个输入样本) 与隐含层输出 A^1 之间的关系可用下式表示

$$a_i^1 = e^{-\frac{(\|w_i^1 - X_k\|/b_i^1)^2}{2}} \quad (1)$$

$$A^1 = (a_i^1)_{S^1 \times 1}, \quad i = 1, 2, \dots, S^1 \quad (2)$$

式中 a_i^1 为第 i 个隐层神经元的输出; b_i^1 为第 i 个隐层神经元的域值; $w_i^1 = (w_{i,1}, w_{i,2}, \dots, w_{i,R})_{1 \times R}$ 为高斯基函数的中心值 (也是网络的权重); $\|\cdot\|$ 为欧几里德距离范数。

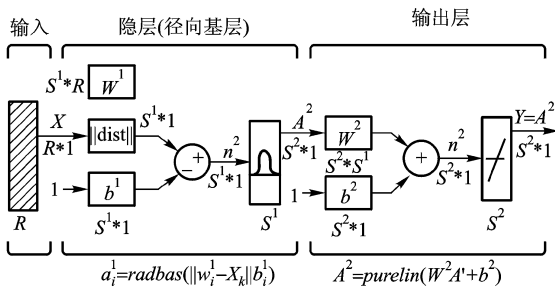


图 1 RBF 神经网络结构图

Fig. 1 Structure chart of RBF neural network

隐含层输出 A^1 与输出层 $Y_k = (y_1, y_2, \dots, y_{S^2})$ (第 k 个输入样本) 之间为线性关系, 可由下式表示:

$$y_j = a_j^2 = \sum_{i=1}^{S^1} w_{i,j}^2 a_i^1 + b_j^2, \quad j = 1, 2, \dots, S^2 \quad (3)$$

式中 $w_{i,j}^2$ 为第 i 个隐层神经元与第 j 个输出单元的连接权重; b_j^2 为第 j 个输出神经元的域值。

由式(1)可知, 隐层单元中的基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。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。由此可看出这种网络具有局部逼近能力, 所以径向基函数神经网络也称为局部感知场网络。

RBF 网络的训练过程主要是: a. 确定隐含层节点个数, 即选择多个基函数; b. 选取合适的基函数中心矢量 w_i^1 ; c. 确定隐含层到输出层的连接权值 $w_{i,j}^2$ 。隐含层到输出层之间的权值可以通过 least-mean-square (LMS) 算法或者其他线性优化算法进

行。笔者选用 orthogonal-least-squares (OLS) 算法^[6], 可在计算连接权的同时, 自适应地确定隐层节点数目。

从理论上而言, RBF 网络和 BP 网络一样可近似任何连续的非线性函数。二者的差别在于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, 不但在理论上它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。

2.2 基于 RBF 神经网络的围岩变形预测步骤

围岩变形预测的前提是建立围岩变形时程曲线的数学模型, 即建立开挖时间 t 与围岩变量 y 之间的关系。这里, 两者的关系是通过 RBF 神经网络建立的。具体地, 利用 RBF 神经网络进行连拱隧道施工期围岩变形预测步骤如下:

1) 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, 对多组训练样本 y, t 进行初始化, 将样本都转化为 (0, 1) 区间的值。

2) 建立 RBF 神经网络模型, 并根据样本进行训练。从理论上讲, 训练样本越多, 网络的非线性逼近能力就越强, 从而模拟的效果就越好, 因而, 应尽可能多地选择样本对网络进行训练。

3) 网络模型检验和应用分析。网络模型是否达到了较好的拟合效果, 是否符合围岩变形客观发展趋势, 需要用实际观测值进行检验。只有当两者都满足条件时, 才可以利用该网络模型进行围岩变形预测分析。

3 实例分析

以赣定高速公路大老地隧道 K119 + 900 断面的围岩变形分析为例, 现有 39 天拱顶沉降和水平收敛的实测数据, 见表 1。利用上文提出的 RBF 神经网络方法对隧道围岩变形量进行拟合和预测, 取前 35 个数据样本作为学习样本集, 后 4 个作为检验样本集, 网络为 1 个输入 (日期), 隐含层单元通过自适应产生, 输出层单元 1 个 (水平收敛值或顶拱沉降值), 采用 Matlab 神经网络工具箱编程计算, 仅经过 9 次学习, 达到误差要求为 0.001。表 1 中给出了拟合的结果以及和实测值的绝对误差、相对误差。图 2、图 3 分别为 RBF 神经网络方法模拟的拱顶沉

降和水平收敛变形的时程曲线。从分析结果可见，很好地反映隧道围岩变形的客观规律。该方法模拟的时程曲线不仅拟合误差很小，而且能

表1 连拱隧道围岩变形观测值与RBF神经网络方法拟合值的比较表

Table 1 Comparison between measured values and RBF fitting values of wall rock deformation

样本分类	日期/天	水平收敛/cm				顶拱沉降/cm			
		观测值	拟合值	绝对误差	相对误差/%	观测值	拟合值	绝对误差	相对误差/%
学习样本集	1	0.3	0.25	-0.05	-16.67	0.2	0.22	0.02	10.00
	2	0.4	0.61	0.21	52.50	0.5	0.43	-0.07	-14.00
	3	0.8	0.94	0.14	17.50	0.5	0.65	0.15	30.00
	4	1.2	1.25	0.05	4.17	1.1	0.87	-0.23	-20.91
	5	1.6	1.54	-0.06	-3.75	1	1.1	0.1	10.00
	6	1.9	1.85	-0.05	-2.63	1.4	1.36	-0.04	-2.86
	7	2.4	2.19	-0.21	-8.75	1.5	1.67	0.17	11.33
	8	2.6	2.62	0.02	0.77	2.1	2.03	-0.07	-3.33
	9	3.1	3.13	0.03	0.97	2.5	2.45	-0.05	-2.00
	10	3.6	3.69	0.09	2.50	3	2.88	-0.12	-4.00
	11	4.2	4.15	-0.05	-1.19	3.2	3.28	0.08	2.50
	12	4.4	4.45	0.05	1.14	3.5	3.6	0.1	2.86
	13	4.7	4.65	-0.05	-1.06	3.8	3.83	0.03	0.79
	14	4.9	4.83	-0.07	-1.43	4	3.98	-0.02	-0.50
	20	5.2	5.35	0.15	2.88	4.2	4.26	0.06	1.43
	21	5.5	5.38	-0.12	-2.18	4.4	4.27	-0.13	-2.95
	27	5.7	5.73	0.03	0.53	4.7	4.79	0.09	1.91
	28	5.9	5.98	0.08	1.36	5.2	5.08	-0.12	-2.31
	29	6.4	6.31	-0.09	-1.41	5.4	5.42	0.02	0.37
	30	6.6	6.63	0.03	0.45	5.7	5.72	0.02	0.35
31	6.9	6.87	-0.03	-0.43	5.8	5.93	0.13	2.24	
32	7	7.02	0.02	0.29	6.4	6.09	-0.31	-4.84	
33	7.2	7.14	-0.06	-0.83	6.1	6.32	0.22	3.61	
34	7.2	7.26	0.06	0.83	6.7	6.68	-0.02	-0.30	
35	7.4	7.42	0.02	0.27	7	7.09	0.09	1.29	
36	7.5	7.62	0.12	1.60	7.6	7.43	-0.17	-2.24	
检验样本集	37	8	7.83	-0.17	-2.13	7.7	7.65	-0.05	-0.65
	38	8	8.01	0.01	0.12	7.8	7.77	-0.03	-0.38
	39	8.1	8.14	0.04	0.49	7.7	7.84	0.14	1.82

为比较RBF神经网络方法的优越性,笔者还分别采用应用广泛的BP神经网络和传统的多项式回归方法来拟合拱顶变形。

BP神经网络方法同样取前35个数据作为学习样本,后4个作为检验样本,利用Matlab工具箱中Levenberg-marquardt训练方法进行拟合预测,隐含层单元数取5个,经过37次学习,达到误差要求

0.001。其拱顶最大水平收敛和最大沉降时程变形拟合预测情况分别如图4和图5实线所示。

多项式回归表达式如下:

$$y = b_0 + b_1t + b_2t^2 + b_3t^3 + b_4t^4 \quad (4)$$

式中y为变形量,m;t为时间,d。

用式(4)来拟合最大水平收敛时程变形曲线,在置信度为95%时,通过fisher检验,其误差平方和




图2 RBF网络模拟的拱顶最大沉降时程曲线
Fig.2 Maximal settlement-time curve of arch crown from RBF simulation




图4 BP神经网络和多项式方法模拟的最大水平收敛时程曲线
Fig.4 Maximal horizontal convergence-time curves from BP and polynomial regression simulation




图3 RBF网络模拟的最大水平收敛时程曲线
Fig.3 Maximal horizontal convergence-time curve of arch crown from RBF simulation




图5 BP神经网络和多项式方法模拟的最大垂直沉降时程曲线
Fig.5 Maximal vertical convergence-time curves from BP and polynomial regression simulation

为0.0197,多项式各参数分别为 $b_0 = -0.003427$, $b_1 = 0.004608$, $b_2 = -5.6E-5$, $b_3 = -2.7E-6$, $b_4 = 6.58E-8$ 。

用式(4)来拟合最大沉降时程变形曲线,在置信度为95%时,上述模型通过fisher检验,其误差平方和为0.0182,各参数分别为 $b_0 = -0.00285$, $b_1 = 0.003598$, $b_2 = -4E-5$, $b_3 = -2.3E-6$, $b_4 = 6.2E-8$ 。

多项式回归方法拟合的拱顶变形曲线如图4和图5中的虚线所示。

与RBF神经网络方法拟合结果对比,BP方法虽然学习拟合误差也较小,但外推预测结果要差于RBF方法;而多项式方法则在学习拟合和外推预测

两方面都差于RBF方法,且其发展趋势与实际的围岩变形规律相去甚远,因此用该方法进行围岩变形预测是不妥的。

3 结语

连拱隧道施工(正台阶开挖方式)情况下,围岩变形时程曲线从上台阶到下台阶的过渡存在反弯点,传统回归统计方法对于该种情况的模拟具有难度。采用基于RBF神经网络的连拱隧道围岩变形时程曲线,较之BP神经网络具有更形似的预测结果,能更好地描述复杂的围岩快的收敛速度,为分析连拱隧道施工围岩日变形速率以及围岩变形收敛时间等参数提供了一条新的途径。

参考文献

[1] Chen Tianping, Chen Hong. Approximation capability to functions

- of several variables, nonlinear functions and operator by radial basis function neural network [J]. IEEE Trans. on Neural Networks, 1995, 5(6): 904-910
- [2] Ching P T, Tsong L L. Back-propagation neural network in tidal-level forecasting [J]. Journal of Waterways, Port Coastal, and Ocean Engineering, 1992, 125(4): 195-202
- [3] 周建春, 魏 琴. 公路隧道围岩变形时程曲线拟合的 BP 算法 [J]. 湖南大学学报, 2002, 29(4): 79-84
- [4] 马万权, 王新平, 程崇国. 神经网络技术在阳宗隧道围岩变形预测中的应用 [J]. 公路交通技术, 2003, (2): 56-59
- [5] Moody J, Darken C. Fast learning in networks of locally tuned processing [J]. Neural Computation, 1989, (1): 281-289
- [6] Chen S, Cowan C FN, Grant P M. Orthogonal least squares learning algorithm for radial basis function networks [J]. IEEE Transactions on Neural Networks. 1991, 2(2): 302-309

RBF-ANN-Based forecast method of transmutation of wall rock on multi-arch tunne

Xiao Zhiwang^{1,2}, Zhong Denghua¹

(1. School of Civil Engineering, Tianjin University, Tianjin 300072, China;

2. Ganzhou Urban Development & Investment Group Co, Ltd Ganzhou, Jingxi 341000, China)

[Abstract] The key of forecasting transmutation of wall rock correctly is to construct the reasonable mathematics model of time-distance curve from measuring data when distorting, which is hard to describe accurately with traditional method of recursive analysis. According to the characteristics of feed forward neural network of radial basis function to construct the forecast model of deformation of wall rock in multi-arch tunnel and also uses Matlab tool to solve the optimal problem. The engineering case at the end of this paper validates the method. For its fast solving the problem, more optimal results, and better forecasting effects, this method shows its advantages and feasibility.

[Key words] multi-arch tunnel; deformation of wall rock; deformation forecast; radial basis function (RBF); artificial neural network (ANN)