

深基坑变形影响因子分析及预测方法研究

熊春宝¹, 李 郎¹, 马超峰²

(1. 天津大学 建筑工程学院, 天津 300072; 2. 中国铁道科学研究院 铁道建筑研究所, 北京 100081)

摘要:影响基坑变形的因子有很多,有主要因子和次要因子。根据实际工程经验以及相关资料,在较为全面地总结所有影响基坑变形因子的基础上,结合层次分析法,筛选出主要影响因子,建立一定的量化标准。将影响因子作为输入层,构建基于主要影响因子的 BP 神经网络。结合天津市中国铁建国际城 1D 地块深基坑工程,选出围护结构发生明显变形的各时间段,建立 17×10^6 的训练数据,采用黄金分割法对隐含层的节点数进行筛选,以 4 m, 8 m, 12 m, 16 m 处的变形数据为目标层进行训练和仿真。最后,对其它测斜点的变形进行预测,精度满足要求,验证了这种影响因子选择和样本选择方法的有效性,对基坑变形预测有一定的应用指导意义。

关键词:基坑变形预测;影响因子;BP 神经网络;黄金分割法;层次分析法

中图分类号:TU447 **文献标志码:**A **文章编号:**2095-0373(2016)04-0053-07

0 引言

岩土体是一种多相、各向异性和非均质的材料,这也就导致了基坑工程本身的复杂性^[1],给基坑开挖增加了一定的难度。近年来,经常能听到一些关于深基坑发生事故的新闻,事故通常表现为围护结构变形过大、支撑结构内力过大或者地面急剧沉降,人们已经逐渐意识到对基坑进行监测和预测是很有必要的。对于基坑的变形预测,以往学者大都倾向于对地面沉降的预测,近些年国内外也有很多学者^[2]对围护结构的变形进行了监测和预测,取得了一定的进展。由于岩土体是一个复杂的非线性材料,而神经网络可以很好地解决复杂的非线性问题,并且具有自学习、自适应的能力和联想存储功能。从表面上看,深基坑的变形趋势没有什么规律可循,但是,从系统上来说,综合分析深基坑的各种影响因素之后发现其中必然存在一定的规律^[3-4]。1996 年, S. Rajasekaran et al^[5]将误差反向传播的 BP 神经网络应用于基坑周围土体的水平位移预测,取得了比较理想的结果。2005 年, C. G. Chua¹ 和 Anthony T. C. Goh^[6]利用贝叶斯神经网络模型预测了深基坑开挖过程中围护结构的变形以及土结构之间的相互作用,并且提出了一个有意义的误差曲线。2008 年,贺志勇等^[7]结合某深基坑工程,建立 BP 神经网络时间窗口预测模型,预测了围护结构桩体的水平位移。2013 年,李燕等^[8]首次比较详细地建立基于影响因子的 BP 神经网络对基坑的变形进行预测。在此背景下,现通过进一步细化筛选影响因子,优选隐含层节点数和训练数据,提高了模型的精度,验证了这种方法的可行性。

1 分析及预测原理

1.1 BP 神经网络原理

单层神经网络通常只能解决一些线性问题,对于一些非线性问题需要用多层神经网络来解决。BP 网络的信息从输入层传输到输出层,所以是一个多层前馈神经网络。BP 网络的学习过程分为两个阶段^[9-10]:

第一阶段:将学习数据由输入层传入隐含层,通过设置的网络结构和前一次迭代的权值和阈值,最终从输出层得出个神经元的输出;

第二阶段:若输出层没有得到理想的结果,从最后一层向前计算各权值和阈值对总误差的影响,对权

收稿日期:2015-11-05 责任编辑:车轩玉 DOI:10.13319/j.cnki.sjztdxxbzb.2016.04.09

作者简介:熊春宝(1964-),男,博士,教授,主要从事工程结构健康监测的研究和教学。E-mail:lang7256550@163.com

熊春宝,李 郎,马超峰.深基坑变形影响因子分析及预测方法研究[J].石家庄铁道大学学报:自然科学版,2016,29(4):53-59.

值和阈值进行修改。

以上两个阶段反复交替进行,直到结果收敛为止。图 1 给出了多层前向网络的一部分内容,表示两种信号在流通。

理论证明,在不限制隐含层节点数的情况下,两层的 BP 神经网络可以解决任何非线性问题。如图 2 所示是 3 层 BP 神经网络的拓扑结构。

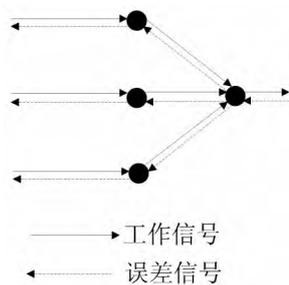


图 1 前向工作信号与反向误差信号

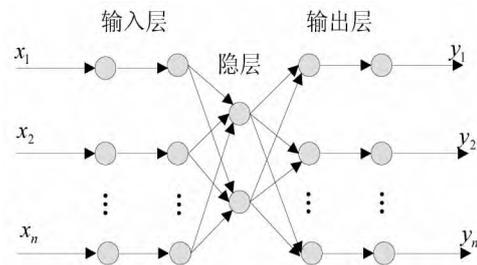


图 2 3 层 BP 神经网络的拓扑结构

1.2 层次分析法原理

层次分析法^[12] (Analytic Hierarchy Process, 简称 AHP) 是一种利用数学分析,把分析指标层次化、数量化,并且把定性指标量化分析的方法。它可以把一些虽然独立,但是相互制约的影响因素综合起来考虑,并把这种综合用数值的方法显示出来。

层次分析法的基本步骤为建立层次结构、构建判断矩阵、层次单排序及一致性检验、层次总排序及一致性检验。

2 影响因子选取及赋值

2.1 建立层次结构

对于深基坑变形影响因素的探讨,以往学者通常从施工条件、设计因素和水文地质 3 个方面进行分析。同时,对于大体积混凝土结构,往往忽略了温度对围护结构和支撑结构产生的影响^[13]。为了判断哪些是主要因素哪些是次要因素,同时为了提高 BP 神经网络的训练数据的有效性,本研究将从设计因素、围护支撑结构、施工条件、水文地质条件、超载条件 5 个方面进行分类,并建立相应的层次结构如表 1 所示。

表 1 深基坑变形影响因子层次结构

目标层	准则层	指标层
影响因子 A	设计因素 B_1	基坑重要性等级 C_{11} 基坑开挖深度 C_{12}
	围护支撑结构 B_2	支撑位置及道数 C_{21} 入土深度 C_{22} 支撑刚度 C_{23} 围护结构刚度 C_{24} 支撑预应力 C_{25}
	施工条件 B_3	支撑安装时间 C_{31} 基坑暴露时间 C_{32} 基坑底暴露时间 C_{33} 被动土体加固 C_{34} 施工顺序 C_{35} 时空效应 C_{36}
	水文地质条件 B_4	土体参数 C_{41} 墙土摩擦 C_{42} 水文条件 C_{43} 环境温度 C_{44}
	超载条件 B_5	周围静载 C_{51} 周围动载 C_{52}

2.2 构建判断矩阵及层次总排序

在层次分析法中,某一层次所有因素的相对重要性权重是通过专家打分构建矩阵的方式来确定的,这样就可以很好的比较本层次各因素之间的相对重要性。在参考相关资料并且咨询多名专家老师的前提下,结合 1~9 比例标度表,建立表 2~表 7 的判断矩阵计算相对权重。

表 2 准则层 A 判断矩阵及相对权重

指标	B_1	B_2	B_3	B_4	B_5	W
B_1	1	1/5	1/4	1/3	1/3	0.058 9
B_2	5	1	2	3	3	0.406 5
B_3	4	1/2	1	2	2	0.249 0
B_4	3	1/3	1/2	1	1	0.142 8
B_5	3	1/3	1/2	1	1	0.142 8

一致性检验: $\lambda_{\max}=5.056 7, CI=0.014, RI=1.12, CR=CI/RI=0.013<0.1$,一致性良好。

表 3 设计因素 B_1 判断矩阵及相对权重

指标	C_{11}	C_{12}	W
C_{11}	1	1/3	0.250
C_{12}	3	1	0.750

一致性检验: $\lambda_{\max}=2, CI=0, RI=0, CR=CI/RI=0$,完全一致。

表 4 围护支撑结构 B_2 判断矩阵及相对权重

指标	C_{21}	C_{22}	C_{23}	C_{24}	C_{25}	W
C_{21}	1	1/4	1/3	1/3	1/5	0.058 9
C_{22}	4	1	2	2	1/2	0.249 0
C_{23}	3	1/2	1	1	1/3	0.142 8
C_{24}	3	1/2	1	1	1/3	0.142 8
C_{25}	2	3	3	1	0.406 5	

一致性检验: $\lambda_{\max}=5.056 7, CI=0.014, RI=1.12, CR=CI/RI=0.013<0.1$,一致性完好。

表 5 施工条件判断矩阵 B_3 及相对权重

指标	C_{31}	C_{32}	C_{33}	C_{34}	C_{35}	C_{36}	W
C_{31}	1	4	1	3	2	5	0.295 9
C_{32}	1/4	1	1/4	1/2	1/3	2	0.070 2
C_{33}	1	4	1	3	2	5	0.295 9
C_{34}	1/3	2	1/3	1	1/2	3	0.111 6
C_{35}	1/2	3	1/2	2	1	4	0.180 1
C_{36}	1/5	1/2	1/5	1/3	1/4	1	0.046 3

一致性检验: $\lambda_{\max}=6.080 9, CI=0.016, RI=1.24, CR=CI/RI=0.013<0.1$,一致性良好。

表 6 水文地质条件判断矩阵 B_4 及相对权重

指标	C_{41}	C_{42}	C_{43}	C_{44}	W
C_{41}	1	5	3	4	0.546 2
C_{42}	1/5	1	1/3	1/2	0.083 8
C_{43}	1/3	3	1	2	0.232 3
C_{44}	1/4	2	1/2	1	0.137 7

一致性检验: $\lambda_{\max}=4.051 1, CI=0.017, RI=0.90, CR=CI/RI=0.019<0.1$,一致性良好。

表 7 超载条件判断矩阵及相对权重

指标	C_{31}	C_{32}	W
C_{31}	1	2	0.666 7
C_{32}	1/2	1	0.333 3

一致性检验: $\lambda_{\max}=2, CI=0, RI=0, CR=CI/RI=0$,完全一致。

在确定各指标层 C 的相对权重之后,结合准则层得到各因子的综合权重。按照综合权重,对各影响因子进行总排序,排除时空效应和墙土摩擦对变形产生的影响,将其他 17 个影响因子作为影响基坑变形的主要影响因子进行建模。

2.3 建立量化标准

通过构建判断矩阵,结合层次总排序,筛选出其中的前 17 个主要影响因子作为神经网络的输入层训练数据,建立表 8 所示的量化标准。

3 构建 BP 神经网络模型

3.1 工程概况

工程位于河北区金钟河大街以北、月牙河以西的开发空地内,是天津地铁 6 号线民权门车站与国际城 1D 地块的合建工程,总面积约为 19 100 m²。国际城 1D 地块基坑开挖深度约 20.4 m,分 4 层土方进行开挖,围护结构选用 1 000 mm 厚地下连续墙+环板支撑的围护结构形式。主体结构底板位于粉质黏土层中,土质较均匀。2014 年 4 月 1 日开工,2015 年 6 月 28 号竣工,总工期 454 d。地块围护结构布置 11 个测斜管,周围布置 10 个水位监测点。工程于 5 月 3 日开挖第一层土方,8 月 3 日开挖第二层土方,10 月 8 日开挖第三层土方,12 月 20 开挖第四层土方。

表 8 影响因子赋值标准

编号	影响因子	量化标准
C_{25}	支撑预应力	大于 90%设计值(1);介于 70%~90%(2);介于 50%~70%(3);小于 50%(4);无预应力(5)。
C_{22}	入土深度	$t > 0.8H$ (1); $0.6H < t < 0.8H$ (2); $0.3H < t < 0.6H$ (3); $0.1H < t < 0.3H$ (4); $0 < t < 0.1H$ (5)。
C_{51}	周围静载	弱(1);较弱(2);一般(3);较强(4);强(5)。
C_{41}	土体参数	岩石类(2);砂土类(3);粘土粉土等(4);其他砂土和杂填土(5)。
C_{31}	支撑安装时间	快(1);较快(2);一般(3);较慢(4);慢(5)。
C_{33}	基坑底暴露时间	小于 24 h(1);介于 24 h 和 36 h(3);大于 36 h(5)。
C_{23}	支撑刚度	较强(混凝土支撑)(2);一般(混凝土与钢支撑)(3);较弱(钢支撑)(4)。
C_{21}	支撑位置及道数	密(上疏下密)(2);较密(上密下疏)(3);一般(4);稀疏(5)。
C_{52}	周围动载	弱(1);较弱(2);一般(3);较强(4);强(5)。
C_{35}	施工顺序	先撑后挖、分层均匀开挖(1);先挖后撑、分层均匀开挖(3);不均匀开挖、超挖等(5)。
C_{12}	基坑开挖深度	根据实际开挖深度赋值。
C_{43}	水文条件	根据实际水位变化速率赋值。
C_{34}	被动土体加固	中间支撑以下土体至设计标高以下 4 m。
C_{24}	围护结构的刚度	桩墙式支护(2);挡墙式支护(3);锚式支护(4);无支护(5)。
C_{44}	环境温度	冬季(2);春季(3);秋季(4);夏季(5)。
C_{32}	基坑暴露时间	根据实际暴露时间赋值。
C_{11}	基坑重要性等级	一级(1);二级(3);三级(5)。

注:括号内数值为赋值大小, t 为入土深度, H 为围护结构深度。

3.2 数据准备

BP 神经网络需要选择典型的样本数据进行训练。样本数太少,网络精度不够,样本数太多,增加训练的时间。笔者选取基坑围护结构发生明显变形的时间段进行考虑,对于该工程,选取 2014 年 7 月 20 日~2014 年 8 月 13 日,2014 年 10 月 8 日~2014 年 10 月 24 日,2014 年 11 月 1 日~2014 年 11 月 10 日,2014 年 12 月 1 日~2014 年 12 月 28 日,2015 年 2 月 1 日~2015 年 2 月 10 日,2015 年 3 月 1 日~2015 年 3 月 13 日,总共 106 d 的数据进行分析,其中 2014 年 11 月和 2015 年 2 月是季节变化的典型时间点,其他均是基坑土方开挖的前后时间段,2015 年 3 月 13 号之后,基坑变形趋于稳定。选取 QX4 进行模拟训练,然后选取 QX5 进行泛化能力测试。

3.3 程序设计

根据表 9,对 QX4 的影响因子进行赋值,将其作为网络的训练数据 P ,其中 P 是 17×106 的矩阵,分

别以 QX4 点 4 m, 8 m, 12 m, 16 m 处的实测变形数据为目标数据 T , 其中 T 是 1×106 的矩阵, 建立 4 个训练模型。首先, 利用 `mapstd` 函数对 P 、 T 进行归一化处理, 加快网络的预测速度。然后, 利用 `newff` 函数构建神经网络, 传输函数为 `tansig` 和 `purelin`, 学习函数为 `traingdx`。由于后期有专门的测试数据和验证数据, 所以网络训练不需要对其数据进行自动分类, 其中用到了 `divideFcn` 函数。隐含层神经元需要结合黄金分割法进行选取, 学习速率 lr 为 0.05, 动量因子 mc 为 0.9, 训练次数为 100 000, 目标误差取为 $1e-5$ 。最后, 利用 `mapstd('reverse', ...)` 对其进行反归一化处理。训练过程以训练次数达到 100 000 或者目标误差 `goal` 达到 $1e-5$ 时结束训练。

3.4 确定隐含层节点数

根据前人经验, 通常采用经验公式设计隐含层节点数

$$n = \sqrt{n_i + n_o} + a \tag{1}$$

式中, n 为隐层节点数; n_i 为输入节点数; n_o 为输出节点数; a 为 1~10 之间的常数。

这种方法选择的隐含层节点数精确度较低, 有不少学者在此基础上找到了一些更为有效的方法^[14], 其中基于黄金分割原理的筛选方法是比较有效的。这种方法指出比较理想的隐含层节点数通常存在于 $[a, b]$ 这个区间, 其中 a 和 b 通过如下的公式求得

$$a = \frac{n_i + n_o}{2} \leq n_h \leq (n_i + n_o) + 10 = b \tag{2}$$

同时, 利用黄金分割原理找到这个区间的延伸区间 $[b, c]$ (其中 $b = 0.618 \times (c - a) + a$), 然后分别在这两个区间内利用黄金分割法找到疑似最优节点数, 结合一定的误差判断标准进行选择。设神经网络的总误差为

$$E = \frac{1}{2} \sum_{i=1}^n (T_i - T_j)^2 \tag{3}$$

式中, T_i 为实测数据; T_j 为仿真数据, 当 E 最小时即为最优节点。

在该模型中, n_i 为 17, n_o 为 1, 即 $a = 9, b = 28, c = 40$ 。结合黄金分割法, 全部的疑似最优节点为 9、17、20、23、25、28、33、35、40, 结合已经建立好的神经网络, 求出的 4 m, 8 m, 12 m, 16 m 处的总误差如表 9 所示。

表 9 隐含层最优节点数选择

深度/m	9	17	20	23	25	28	33	35	40	最优节点
4	4.91	3.29	5.01	3.99	6.15	7.19	3.54	4.04	3.72	17
8	4.70	5.74	3.75	8.00	6.72	6.14	9.66	7.00	5.60	20
12	6.84	8.71	8.76	9.92	7.07	6.45	6.52	11.02	9.44	28
16	9.70	8.96	9.15	8.14	6.82	10.48	7.29	10.96	11.55	25

3.5 网络训练及仿真

利用设计好的程序, 输入求得的最优节点数, 对网络进行仿真训练。以 QX4-4 m 处的神经网络模型为例, 对其进行仿真训练, 如图 3 所示为实测数据与仿真数据的对比图, 可见实测数据与仿真数据的拟合是比较好的。误差性能曲线如图 4 所示。利用同样的方法可以对 8 m, 12 m, 16 m 处的网络进行训练。

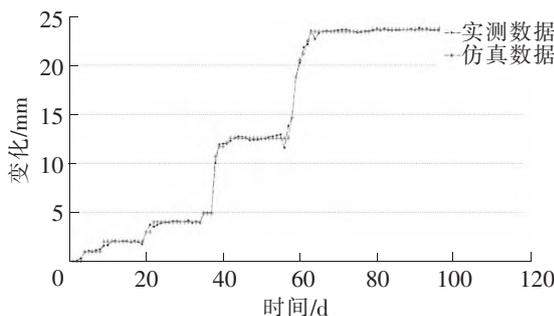


图 3 QX4-4 m 深处仿真数据与实测数据对比图

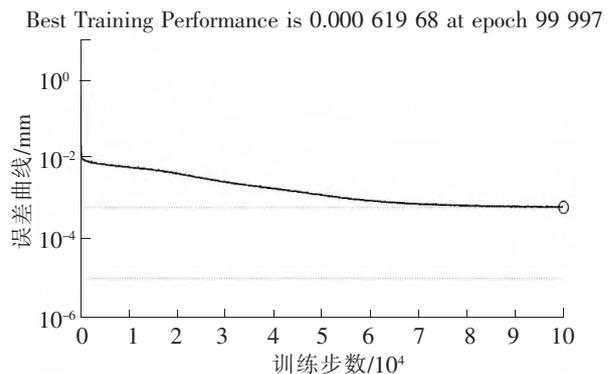


图 4 QX4-4 m 深处网络训练的误差性能曲线

3.6 网络验证

由于神经网络的训练数据是选的 QX4 的各个时间段相互独立的数据,所以首先需要对 QX4 样本内和样本外的数据对网络进行验证。以 8 月 9 日,9 月 10 日,10 月 15 日,10 月 25 日,11 月 5 日,11 月 11 日,12 月 15 日,2015 年 1 月 7 日,2015 年 2 月 5 日,2015 年 2 月 15 日,2015 年 3 月 5 日,2015 年 3 月 14 日 12 组数为例对其进行验证。计算结果如图 5 所示。

从图 5 中可以看出,各深度处神经网络的预测变形相对误差基本都小于 5%。2014 年 8 月 9 日第二层土方正在开挖,实测变形比较小,相对误差大于 5%,影响不大。16 m 深处由于 10 月 8 日之前没有变形,所以相对误差为零。样本内数据的仿真结果与实测结果拟合比较好,样本外数据预测也都在误差所允许的范围内。

3.7 泛化能力测试

训练 BP 神经网络的主要作用是将其进行推广应用。为了验证网络的泛化能力,利用 QX4 已经训练好的网络,分别对 QX5 的 12 个时间点 4 m,8 m,12 m 和 16 m 的变形值进行预测。预测值与实测值的对比如图 6 所示。

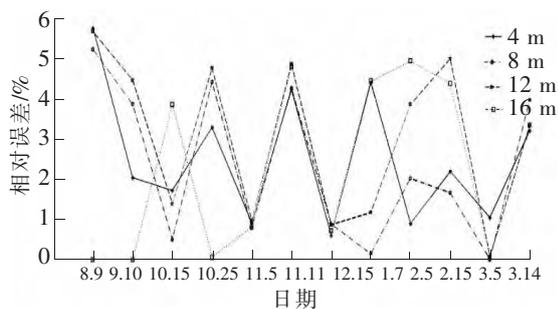


图 5 QX4 处 4 m、8 m、12 m、16 m 的预测相对误差

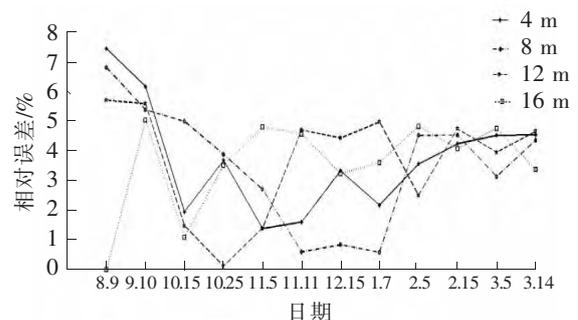


图 6 QX5 处 4 m、8 m、12 m、16 m 的预测相对误差

从图 6 中可以看出,9 月 10 日之前的预测误差略大于 5%,由于此时第二层土方刚开挖完毕,围护结构的最大变形为 5 mm,5% 内的相对误差是可以接受的。随着基坑继续开挖,基坑围护结构的变形越来越大,但是相对误差越来越趋近于 3%~5% 的范围内,满足实际工程的应用要求。

4 结论

通过结合层次分析法和 matlab,在总结前人研究的基础上综合考虑影响基坑变形的所有因素,并在征求多个专家老师意见的前提下对其进行赋值,建立基于影响因子的 BP 神经网络。最后结合天津市国际城 1D 地块的深基坑工程,对网络进行训练仿真以及泛化能力测试,结果表明这种影响因子以及训练样本选择方法在变形预测的精度上满足工程要求的 5% 的要求,同时提高了网络训练的速率,有很好的推广应用价值。

(1) 针对我国季节变化比较明显的中北部地区,将温度的影响考虑在内,同时将相对的水位变化速率而非绝对的水位高度等考虑在内,最终筛选出 17 个主要影响因子,提高了神经网络的仿真精度。

(2) 针对训练样本的选择,区别于以往的考虑基坑开挖全程或者只考虑某个时间区段,通过筛选基坑发生明显变形的土层开挖区段以及季节变化时的个别区段进行考虑,在减少训练样本量加快训练速度的同时可以对基坑开挖的全程考虑在内。

(3) 利用黄金分割法,对隐含层最优节点数进行筛选,提高了网络训练的速率和精度,进一步验证了这种方法的高效性。

参 考 文 献

- [1] 刘建航,侯学渊. 基坑工程手册[M]. 北京: 中国建筑工业出版社,1997.

- [2]刘国彬,刘登攀,刘丽雯,等. 基坑坑底施工阶段围护墙变形监测分析[J]. 岩石力学与工程学报,2007(S2):4386-4394.
- [3]白永学. 软土地铁车站深基坑变形的影响因素及其控制措施[D]. 成都:西南交通大学,2006.
- [4]刘少魏. 海积软土地层地铁车站基坑开挖的时空效应研究[J]. 石家庄铁道大学学报:自然科学版,2013,26(1):23-27.
- [5]Rajasekaran S, Febin M F, Ramasamy J V. Artificial fuzzy neural networks in civil engineering[J]. Computers & Structures, 1996, 61(2): 291-302.
- [6]Chua C G, Anthony T C Goh. Estimating wall deflections in deep excavations using Bayesian neural networks[J]. Tunneling and Underground Space Technology, 2005(20): 400-409.
- [7]贺志勇,郑伟. 基于 BP 神经网络的深基坑变形预测[J]. 华南理工大学学报:自然科学版,2008,36(10):92-96.
- [8]李燕. 基于 BP 神经网络的深基坑围护变形预测[D]. 杭州:浙江工业大学,2013.
- [9]张德峰. MATLAB 神经网络仿真与应用[M]. 北京:电子工业出版社,2009.
- [10]张乃尧,阎平凡. 神经网络与模糊控制[M]. 北京:清华大学出版社,1998.
- [11]朱文桐. 基于改进 BP 神经网络的铁路货运量预测[J]. 石家庄铁道大学学报:自然科学版,2014,27(2):79-82.
- [12]邓雪,李家铭等. 层次分析法权重计算方法分析及其应用研究[J]. 数学的实践与认识,2012(7):93-100.
- [13]陈玉香. 温度对深大基坑地下连续墙内力和变形影响分析[D]. 杭州:浙江大学,2006.
- [14]夏克文,李昌彪,沈钧毅. 前向神经网络隐含层节点数的一种优化算法[J]. 计算机科学,2005,10: 143-145.

Study on the Influence Factors Analysis and Prediction Method of Deep Foundation Pit Deformation

Xiong Chunbao¹, Li Lang¹, Ma Chaofeng²

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

2. Railway Construction Research Institute of China Academy of Railway Sciences, Beijing 100081, China)

Abstract: There are many factors that affect the deformation of foundation pit, including major factors and secondary factors. According to the engineering experience and relevant information, based on a more comprehensive summary of the factors and identifying the major factors, the quantitative criteria are established by combining the AHP. Using the factors as the input layers, the BP neural network can be constructed based on these factors. Taking the deep foundation pit engineering of Chinese Railway International City 1D block as an example, selecting the time periods that the retaining structure have deformations and establishing the 17×10^6 training data, the node numbers of hidden layer can be settled down by using the Fibonacci method. Then take the deformation data of 4 m, 8 m, 12 m, 16 m as target layer to train and simulate. At last, using the network that have trained to make prediction of other points, the accuracy meets the requirements. This conclusion verifies the validity of this impact factor selection and sample selection method and has some guiding significance for the deformation predicting of deep foundation.

Key words: deformation prediction of foundation pit; influence factors; BP neural network; fibonacci method; AHP