

DOI:10.3969/j.issn.1672-1144.2014.01.013

# 基于神经网络的基坑变形动态预测研究

王颖, 刘勇健, 刘意美

(广东工业大学 土木与交通工程学院, 广东 广州 510006)

**摘要:** 基坑开挖过程中, 需要根据实际情况及建筑安全等级进行严格的变形控制, 有效的变形预测能更好地指导施工。根据某基坑工程现场监测数据, 应用 MATLAB 7 神经网络工具箱, 建立了基于 BP 网络的基坑变形多步预测模型 A 和动态预测模型 B, 并与广义回归网络建立的模型对比。结果表明, 动态预测的精度明显高于多步预测模型; 在变形数据随时间递增的情况下, BP 神经网络比广义回归网络动态预测精度高, 泛化能力强, 平均预测误差约 3.3%, 能满足实际工程要求。

**关键词:** 基坑; 测斜数据; 动态预测; BP 网络; 广义回归网络

中图分类号: TU47

文献标识码: A

文章编号: 1672-1144(2014)01-0062-05

## Research on Dynamic Prediction of Foundation Pit Deformation Based on Neural Networks

WANG Ying, LIU Yong-jian, LIU Yi-mei

(College of Civil and Communication Engineering, Guangdong Polytechnical University, Guangzhou, Guangdong 510006, China)

**Abstract:** In the process of geotechnical excavation, the deformation must be controlled strictly according to the actual situation and building safety grade, and the good deformation prediction can effectively guide the construction. According to the in-site deformation monitoring data of a foundation pit, the multi-step prediction model A and dynamic prediction model B were built based on BP network by using MATLAB 7 neural network toolbox, then compared with the models established by generalized regression neural network (GRNN). The results show that the dynamic prediction's accuracy is much higher than that of the general multi-step prediction model; when the deformation data is increased with time, the BP network has better generalization ability and higher accuracy than GRNN, the average prediction errors are around 3.3%, which can meet the engineering requirements.

**Keywords:** foundation pit; inclinometer data; dynamic prediction; BP network; generalized regression neural network (GRNN)

近年来, 岩土工程中基坑变形控制逐渐由应力控制转变为变形控制。动态设计是变形控制设计的核心, 即将设计置于时间和空间的动态过程中, 随施工过程中的采集与反馈, 对原设计做必要的调整。在施工过程中, 通常要对围护墙体位移进行监测, 利用采集的位移量来调节施工进度, 排除安全隐患, 以做到动态设计和信息化施工。基坑施工一般周期较长, 施工情况复杂, 及时对基坑变形趋势进行预测显得相当重要。一般常用的基坑变形预测方法包括理论计算法, 数值分析法, 相关(回归)分析法等<sup>[1-4]</sup>。

第一类方法由于施工情况复杂, 计算出的变形量往往与实际相差较大, 后两类方法涉及到的参数存在变异性, 比较难确定。支护结构变形由于受多种因素影响, 表现出很强的非线性特征<sup>[5]</sup>, 而神经网络具有高度的非线性映射能力, 能够高速、大规模并行处理数据信息。国内已有不少利用神经网络进行基坑位移预测的研究, 取得了许多有价值的成果<sup>[6-7]</sup>。

本文使用神经网络对基坑围护结构变形进行时间序列预测。通过移动时间窗口, 不断加入新的测斜数据, 更新网络的训练样本, 同时剔除监测时间最

早的数据建立动态预测模型。在网络结构不变的基础上重新训练,得到的预测结果不存在误差积累,使连续长期预测成为可能。

## 1 基坑变形机理

基坑开挖过程是开挖面卸荷的过程,卸荷使坑底土体产生向上为主的位移,同时也使围护墙体在两侧压力差作用下产生向基坑内的侧向变形,进而导致墙后地面沉降。以有支撑柔性挡墙破坏形式为例,各变形如图 1 所示。围护墙内侧卸去原有土压力,基坑内、外侧受不平衡土压力使墙体产生变形和位移,进而使墙外主动土压力区的土体向坑内移动,墙外土体水平向应力减小;开挖面以下的被动区土体向坑内移动,坑底土体水平向应力加大,导致坑底土体应力增大发生水平向挤压和向上隆起。围护墙体变形是引起周围地层变形的重要原因。




图 1 有支撑柔性挡墙的破坏形式

由此可见,在基坑施工过程中,基坑变形既有一定的规律性,同时又受到施工情况及周围环境影响,带有随机性。围护墙体水平位移预测对于控制施工对周围环境的影响相当重要。

## 2 神经网络原理

### 2.1 BP 网络

BP 网络目前应用最广泛,是一种单向传播的多层前向网络,包括输入层、中间层(隐层)和输出层。各层神经元之间实现全连接,层内无连接。三层 BP 网络结构如图 2 所示,网络的实际输入  $x_i$  和实际输出  $y_i$  代表神经元。网络输入为  $X = [x_1, x_2, \dots, x_n]^T$ ,输出为  $Y = [y_1, y_2, \dots, y_m]^T$ ,通过连续不断地在误差函数斜率下降的方向上调整网络权值和偏差而逐渐逼近目标。每一次权值和偏差的变化都与网络误差的影响成正比,并以反方向传播的方式传递到每一层。理论已经证明,单隐含层 BP 网络,只要隐层神经元数足够多,可以以任意精度逼近任何一个具有有限间断点的非线性函数。网络训练结束

后,将测试样本代入训练好的网络,利用已得到的稳定网络结构和连接权值对该样本进行预测。




图 2 三层 BP 网络结构

但是 BP 神经网络是基于梯度下降的误差反向传播算法进行学习的,网络训练速度一般很慢,且易陷入局部极小值。在训练时通常做相应改进:① 采用附加动量法,或和其它全局搜索算法结合<sup>[8-10]</sup>,保证 BP 算法收敛于全局最小值;② 采用变化的学习速率或自适应学习速率提高训练速度;③ 使用正则化能量函数方法,如贝叶斯训练函数抑制训练过度,提高泛化能力。

### 2.2 广义回归网络

广义回归神经网络(GRNN)是一种规则化的径向基函数网络,有三层组织结构。第一层为输入层,由信号源结点组成;第二层为径向基隐含层,神经元个数等于训练样本数,由所描述问题而定,该层输出  $a_1$  用高斯函数得出;第三层为特殊线性输出层,网络的输出为  $a_1$  和输出层权值矩阵的规则化内积。径向基层输入输出关系为:

$$a_1 = \exp(-(\|IW_{1,1} - X\| \cdot b_1)^2) \quad (1)$$

$$b_1 = 0.8326/s \quad (2)$$

式中: $X$  为输入; $\|\cdot\|$  为向量范数; $s$  为平滑因子;阈值  $b_1$  可以调节函数的灵敏度。

广义回归网络的理论基础是非线性回归估计,收敛速度快,人为调节的参数只有  $s$ ,网络学习全部依赖于数据样本。 $s$  越大,函数拟合就越平滑,但需要更多的神经元来适应函数的快速变化, $s \rightarrow \infty$  时,估计值为所有样本观测值的均值; $s$  越小,则概率密度估计为非高斯型, $s \rightarrow 0$  时,估计值为输入变量  $X$  与权值之间欧氏距离最近的样本观测值。 $s$  值过小,易造成阈值分母为 0 的情况,网络无法训练。

## 3 工程实例分析

### 3.1 工程概况

某基坑工程位于广州市开发区,上部建筑为框架结构,地下为负一层停车场,基坑围护周长约 339 m,开挖深度约 6.84 m~10.10 m。该场地地貌为冲积平原,基坑开挖范围自上而下分别为填土层、海陆

交互相沉积层、残积层粉质粘土及基岩全~中风化粉砂质泥岩和泥质粉砂岩。其中不良土层海陆交互相沉积淤泥质土层平均厚度达 2.82 m。

基坑开挖过程中,采用 CX-3C 型测斜仪,收集测斜孔 CX2 从 2012 年 11 月 18 日到 2013 年 1 月 9 日的测斜数据,其监测数据从 -0.5 m 到 -14.0 m。该测斜孔的位置如图 3 所示,为一层地下室到坑中坑的过渡段,开挖深度从 8.04 m 过渡到 10.10 m,支




图 3 某基坑工程测斜点布置图

### 3.2 变形预测模型

建立基于时间序列的预测模型,用过去相邻 3 d 的位移预测未来 1 d 的位移,依次取相邻 3 d 的样本为滑动窗,将它们映射为 1 d 的值。即用 11 月 18、20、22 日的 15 个测斜数据来预测 11 月 24 日的 5 个位移值,以此类推。输入和输出样本限于篇幅不再列出。预测样本用 12 月 28、30 日和 1 月 1 日的的数据预测 1 月 3 日测斜值,以此类推。分别建立普通多步预测模型 A 和动态预测模型 B。

模型 A:

(1) 为了提高网络的稳定性和训练速度,按式(3)将每个神经元的的数据归一化:

$$y = \frac{2x - 1.2x_{\max} - 0.8x_{\min}}{1.2x_{\max} - 0.8x_{\min}} \quad (3)$$

式中: $x_{\max}$ ,  $x_{\min}$  分别为该神经元中训练样本的最大、最小值; $x$  为实际值; $y$  为归一化后的值;利用该方法可将样本数据范围扩大 20%,适用于目标数据大于训练数据的样本归一化,且实践证明该归一化方法得到的网络较稳定。

(2) 通过 MATLAB 7 神经网络工具箱,应用样本数据建立 BP 预测模型和 GRNN 预测模型,通过训练得到拟合效果较好的模型。

(3) 应用训练好的网络,输入新的测试样本,进行 4 步预测,预测到 1 月 9 日。

(4) 以均方误差  $mse$  和平均相对误差  $E$  作为评价网络预测效果的性能函数。

护类型为深层搅拌桩加钢管桩超前支护,5~6 排锚杆加 2 排预应力锚索的加强型土钉支护。由监测数据可知,基坑围护结构的位移-时间曲线大体呈弓形,位移随开挖深度不断增加,最大水平位移点随之下移,这是由于锚索的设置。由于该段后施工,所以监测数据较少,选取测斜数据中水平位移较大的 -1.0, -2.0, ..., -5.0 m 的 5 个观测数据作为样本。

$$mse = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (4)$$

式中: $N$  为样本数; $y$  为预测值; $t$  为目标值。

模型 B:(1)、(2)、(4)步骤同上;(3)将最新 1 d 的监测数据加入到网络训练样本中,剔除最早的样本数据,即将样本窗向后滑动 1 d,即将时间窗口随时间逐步向后滑动,进行单步动态预测。

### 3.3 BP 神经网络和 GRNN 训练和预测结果

应用模型 A 分别建立基于 BP 和基于广义回归网络的预测模型。BP 预测模型的网络结构为 15-20-5,输入层到隐层的传递函数为正切 S 型函数,隐层到输出层为线性传递函数,训练目标为  $10^{-5}$ 。通过反复比较,选择泛化能力较好贝叶斯正则化训练函数  $trainbr$ ,得到的网络训练速度较快,仅 90 步就满足目标,其性能函数是平方和误差  $sse = \sum_{i=1}^N (y_i - t_i)^2$ ,训练误差曲线如图 4。




图 4 BP 网络训练误差曲线(模型 A)

广义回归网络的建立过程就是训练过程,训练

时为得到较好的仿真效果需试调  $s$  值,仿真误差随  $s$  值变化的对数曲线如图 5,其误差随  $s$  增大而增大。综合考虑仿真和预测效果选取  $s = 0.08$ 。GRNN 的仿真误差精度显著高于 BP 网络,且误差矩阵中误差数值中有 5/6 为 0,网络仿真性能优良。

利用 BP 网络和 GRNN 建立的模型,各点的预测值都基本与监测值重合,仿真精度非常高,说明神经网络能够应用于基坑变形的多个测斜数据预测中。




图 5 GRNN 均方误差随  $s$  变化关系(模型 A)

应用模型 B 分别建立基于 BP 和基于广义回归网络的动态预测模型,每次将最近 1 d 的数据加入到训练样本中重新训练,连续预测 1 月 3 日到 9 日的位移值,结果如表 1 和表 2 中的 B 值。将动态预测结果 B 值和模型 A 的预测结果 A 值做比较。

从表 1 中可看出,模型 A 值随时间累积,预测值的均方误差  $mse$  逐渐增大,而模型 B 预测结果没有呈现该趋势。模型 A、B 预测的各点相对误差如图 6 和图 7 所示,横坐标数字代表地下深度(m)。图 6 中模型 B 预测值相对误差最大的 1 d 是 1 月 9 日地下 1 m 处,为 10.46%,误差值为  $-1.476$  mm,这是由于支护结构水平位移呈现阶段性的“加速变形 - 减慢变形”规律,而选取样本数量不是很多,不能很精确地预测出各个点的位移变化,不过,岩土工程中相对

误差在 25% 以下即满足工程需求。模型 A 和 B 预测 4 d 的平均相对误差分别为 6.1% 和 3.3%,且模型 B 的 20 个预测结果中有 19 个误差均小于 1 mm,预测精度非常高。

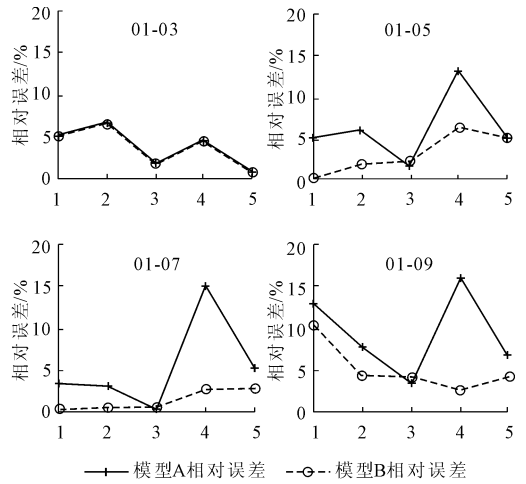


图 6 基于 BP 网络的模型 A、模型 B 预测相对误差对比




图 7 基于 GRNN 的模型 A、模型 B 预测相对误差对比

表 1 BP 网络预测值与监测值对比

| 深度 /m  | 01-03   |             |             | 01-05   |             |             | 01-07   |             |             | 01-09   |             |             |
|--------|---------|-------------|-------------|---------|-------------|-------------|---------|-------------|-------------|---------|-------------|-------------|
|        | 实际值 /mm | 模型 A 预测值/mm | 模型 B 预测值/mm | 实际值 /mm | 模型 A 预测值/mm | 模型 B 预测值/mm | 实际值 /mm | 模型 A 预测值/mm | 模型 B 预测值/mm | 实际值 /mm | 模型 A 预测值/mm | 模型 B 预测值/mm |
| -1.0   | 12.23   | 11.62       | 11.62       | 13.59   | 12.92       | 13.62       | 13.62   | 13.15       | 13.66       | 14.12   | 12.29       | 12.64       |
| -2.0   | 12.33   | 11.53       | 11.53       | 13.46   | 12.67       | 13.72       | 13.67   | 13.28       | 13.74       | 14.02   | 12.94       | 13.43       |
| -3.0   | 18.89   | 18.59       | 18.59       | 20.17   | 19.84       | 20.63       | 20.28   | 20.25       | 20.18       | 20.52   | 19.83       | 19.72       |
| -4.0   | 13.82   | 14.43       | 14.43       | 14.77   | 16.71       | 15.69       | 15.17   | 17.45       | 15.58       | 15.30   | 17.78       | 15.67       |
| -5.0   | 12.45   | 12.36       | 12.36       | 13.43   | 14.08       | 14.11       | 13.76   | 14.47       | 14.13       | 13.75   | 14.66       | 14.34       |
| $mse$  |         | 0.2938      | 0.2938      |         | 1.0715      | 0.3143      |         | 1.2133      | 0.0647      |         | 2.3909      | 0.7323      |
| $E/\%$ |         | 3.63        | 3.63        |         | 6.08        | 3.13        |         | 5.33        | 1.35        |         | 9.37        | 5.06        |

从表 2 中可以发现,用 GRNN 建立的模型 A 预测误差也逐渐增大,而模型 B 的精度要远高于模型

A,4 d 的相对误差均值,模型 A 和模型 B 分别为 15.1% 和 4.9%,说明动态预测效果优于一般预测。

进一步观察,模型 A 的 4 d 预测结果相同,均为 1 月 1 日的监测值。由于测斜数据大致呈逐日递增的状态,预测误差自然越来越大。但是增大  $s$  值得到的预测误差更大,从图 5 即可看出。模型 B 的预测值均为前 1 d 的监测值,即:  $B(n) = R(n-1)$ ,  $n$  为预测序号。这是因为选取  $s = 0.08$  时,虽然仿真精度很高,但由于  $s$  较小,输出结果为已有样本训练值。

这也说明 GRNN 适用于拟合训练样本较充分包含各类情况的事件,其拟合精度高,速度快,但在基坑测斜预测中,预测样本值大于训练样本值,GRNN 预测误差比 BP 网络大。

综上所述,无论是利用 BP 网络还是广义回归网络建立的动态预测模型 B 预测效果都优于多步预测模型 A。

表 2 GRNN 预测值与监测值对比

| 深度<br>/m   | 01-03      |                 |                 | 01-05      |                 |                 | 01-07      |                 |                 | 01-09      |                 |                 |
|------------|------------|-----------------|-----------------|------------|-----------------|-----------------|------------|-----------------|-----------------|------------|-----------------|-----------------|
|            | 实际值<br>/mm | 模型 A 预<br>测值/mm | 模型 B 预<br>测值/mm | 实际值<br>/mm | 模型 A 预<br>测值/mm | 模型 B 预<br>测值/mm | 实际值<br>/mm | 模型 A 预<br>测值/mm | 模型 B 预<br>测值/mm | 实际值<br>/mm | 模型 A 预<br>测值/mm | 模型 B 预<br>测值/mm |
| -1.0       | 12.23      | 10.73           | 10.73           | 13.59      | 10.73           | 12.23           | 13.62      | 10.73           | 13.59           | 14.12      | 10.73           | 13.62           |
| -2.0       | 12.33      | 11.19           | 11.19           | 13.46      | 11.19           | 12.33           | 13.67      | 11.19           | 13.46           | 14.02      | 11.19           | 13.67           |
| -3.0       | 18.89      | 17.80           | 17.80           | 20.17      | 17.80           | 18.89           | 20.28      | 17.80           | 20.17           | 20.52      | 17.80           | 20.28           |
| -4.0       | 13.82      | 12.67           | 12.67           | 14.77      | 12.67           | 13.82           | 15.17      | 12.67           | 14.77           | 15.30      | 12.67           | 15.17           |
| -5.0       | 12.45      | 11.34           | 11.34           | 13.43      | 11.34           | 12.45           | 13.76      | 11.34           | 13.43           | 13.75      | 11.34           | 13.76           |
| <i>mse</i> |            | 1.4585          | 1.4585          |            | 5.5455          | 1.3256          |            | 6.5519          | 0.0652          |            | 7.9249          | 0.0894          |
| <i>E/%</i> |            | 8.90            | 8.90            |            | 15.89           | 7.70            |            | 17.13           | 1.47            |            | 18.44           | 1.63            |

注:表 1、表 2 中 *mse* 和 *E* 为当天预测结果的均方误差和平均相对误差。

## 4 结 论

本文采用动态预测方法对 BP 预测模型和广义回归预测模型进行改进,结合工程实例对软土地区基坑围护结构地下不同深度的测斜值进行预测。

(1) 针对于测试样本数据大于训练样本的情况,使用式(3)的归一化方法,适当将样本数据范围扩大 20%,能有效提高预测精度及稳定性。

(2) 将 GRNN 和 BP 神经网络应用于岩土基坑开挖过程中的变形预测时,GRNN 建模的仿真效果优于 BP 网络,且训练速度快,仿真误差极小。但用 GRNN 网络建立的预测模型,  $s$  足够小时,预测结果为已有样本值,预测意义不大。

(3) 从预测效果来看,使用动态预测方法建立模型大大提高了预测精度,避免了误差累积,预测相对误差低于 10%,能满足工程要求,值得在实际工程中推广应用。

### 参考文献:

[1] 胡冬,张小平.基于灰色系统理论的基坑变形预测研究[J].地下空间与工程学报,2009,5(1):74-78,168.

- [2] 曹长礼.基于神经网络误差修正灰色模型的基坑位移预测[J].人民长江,2010,41(17):25-29.
- [3] 陈健.基坑变形的混沌时间序列分析方法及应用研究[J].测绘,2011,34(2):57-59.
- [4] 熊莎,贺跃光,姬方,等.指数平滑法在基坑深层位移预测中的应用[J].矿冶工程,2013,33(2):5-7.
- [5] 高浪,谢康和.神经网络在岩土工程中的应用[J].土木工程学报,2002,35(4):77-81.
- [6] 党维维,高闯洲,党发宁,等.基于改进的 BP 神经网络对西安黄土抗剪强度指标的研究[J].水利与建筑工程学报,2009,7(2):1-4,13.
- [7] 孙钧,王东栋.地铁施工变形预测与控制的智能方法[J].施工技术,2009,38(1):3-9.
- [8] 梁桂兰,徐卫亚,何育智,等.PSO-RBFNN 模型及其在岩土工程非线性时间序列预测中的应用[J].岩土力学,2008,29(4):995-1000.
- [9] 熊孝波,桂国庆,郑明新,等.基于免疫 RBF 神经网络的深基坑施工变形预测[J].岩土力学,2008,28(S1):598-602.
- [10] 王雨,刘国彬,屠传豹.基于遗传-GRNN 在深基坑地连墙测斜预测中的研究[J].岩土工程学报,2012,34(S1):167-171.