

基于灰色相关分析的 GRFM 倾斜量预测模型

张小红^{1,2}, 王慧琴^{1,3}, 于洪磊³, 高大峰⁴, 王 展⁵

(1. 西安建筑科技大学管理学院, 陕西 西安 710055; 2. 西安科技大学通信与信息工程学院, 陕西 西安 710054; 3. 西安建筑科技大学信息与控制工程学院, 陕西 西安 710055; 4. 西安建筑科技大学土木工程学院, 陕西 西安 710055; 5. 陕西省文物保护研究院, 陕西 西安 710075)

摘要: 针对时间序列的动态性、相关性、小样本性、非线性等特征, 利用灰色模型的小样本适用性和神经网络的预测高精度等性能, 提出了一种基于相关分析的灰色神经网络组合预测模型。首先, 基于灰色相关理论定量分析了倾斜量与沉降观测指标时间序列之间的相关度; 然后, 采用 GM(1,1)模型对原始序列累加求和, 降低各因素原始数据的噪声干扰; 利用优化径向基神经网络(Radial Basis Function, RBF)多步拟合训练, 其中心点和扩展系数初值采用蚁群算法进行优化。最后, 将该模型应用到了砖石古塔的倾斜量预测中, 设计了沉降综合指数, 通过计算, 该指数与倾斜量的灰色相关度为 0.789 1, 采用该模型对某古塔倾斜量进行了预测, 平均相对误差为 9.056%。实验结果表明, 该模型对小样本、非线性的时间序列预测具有高精度和有效性, 为古建筑保护中变形预测提供了理论和实践经验。

关键词: 相关性分析; 灰色模型; 径向基神经网络; 预测模型; 砖石古塔

中图分类号: TU196⁺.4

文献标志码: A

文章编号: 1006-7930(2016)06-0919-06

GRFM forecasting mode of inclination based on the grey relation analysis

ZHANG Xiaohong^{1,2}, WANG Huiqin^{1,3}, YU Honglei³, GAO Dafeng⁴, WANG Zhan⁵

(1.School of Management, Xi'an Univ. of Arch. & Tech., Xi'an 710055, China;

2. School of Communication&Information Engineering, Xi'an Univ. of Scie.& Tech., Xi'an 710054, China;

3. School of Information Control Engineering, Xi'an Univ. of Arch. & Tech., Xi'an 710055, China

4. School of Civil Engineering, Xi'an Univ. of Arch. & Tech., Xi'an 710055, China

5. Shanxi Provincial Institute of Cultural Relics Protection)

Abstract: Considering time series with dynamic, small sample size, relativity, nonlinearity characteristics, a new grey radial basis function (RBF) neural network forecasting model based on correlation analysis is proposed, which is based on the capability of grey model fitting to the small sample data and the properties of neural network with high prediction precision. At first, the new model analyses the correlation of the inclination and settlements time series quantitatively. And then, generated the accumulation sequences of the original time series using GM(1,1) model, which reduced the noise of the original data; the result is input into the radial basis function neural network, the center pointer and expansion coefficient of which is optimized by ant colony algorithm to forecast the inclination quantity with multi-steps. At last, the new model is applied in small goose pagoda, after the grey correlation of inclination and the inhomogeneous settlement index designed is calculated, the inclination quantity is forecasted with the average relative error of 9.056%. The experimental results show that the proposed model has the capability of the good precision and effectiveness, which supplies the theoretical and practical experience for the ancient building protection.

Key words: coherence analysis; grey system; radial basis function neural network; forecasting model; masonry pagodas

时间序列预测是大数据研究的热点, 在天气预报、电力故障预测等多方面都有着广泛的应用, 在古建筑保护领域应用较少。很多砖石古塔面临不均匀沉降、倾斜、裂缝等诸多问题, 极大影响了古塔的稳定性和观瞻性^[1]。鉴于古塔观测时间较短, 数据量小, 通过掌握观测数据的发展规律预测古塔变形趋势, 具有重要的社会意义和实用价值^[2]。

一些国内外学者利用有限元等数值分析方法^[3-5]对结构沉降进行了预测, 但预测误差较大^[6]。近年来, 一些学者将古建筑变形数据作为时间序列, 采用了回归分析^[7]、灰色理论^[8]、时间序列^[9]、BP神经网络^[10]等模型进行建模预测分析。总起来说,

采用的模型主要包括单一预测模型和组合预测模型。实验证明, 单一预测模型中, 自回归和滑动平均 (ARIMA) 等更适用于线性时间序列, 对于非线性时间序列预测具有局限性; 神经网络可以按精度要求无限逼近函数, 但前提是数据量大, 并且存在过拟合现象等缺点。总之, 回归分析、BP神经网络等多数方法都是建立在大量数据基础上, 计算量大, 对于古塔的“小样本”观测数据不太适用。

为了弥补单一预测模型的缺陷, 一些组合预测模型也相继提出, 如: 模糊神经网络、经验模式分解等模型等。但主要针对某一特征数据进行学习和预测, 多数文献较少考虑影响因素, 缺乏对影响因

素的相关性进行定量分析,忽略了其它因素对预测量的影响贡献。

由于古塔结构变形不是独立的事件,从影响因素出发,通过分析影响因素的变化规律来预测倾斜的发展趋势,提高预测的准确率。径向基函数神经网络可以逼近任意的非线性函数,能够处理系统内的难以解析的规律性,具有良好的泛化能力,并有很快的训练学习收敛速度^[11],但在处理小样本数据方面也存在不足^[12]。为了解决小样本问题,本文引入灰色系统(Grey System)理论,采用等维递补的方式进行“小样本”数据的预测,从而扩充训练样本。同时,灰色相关理论可以通过计算两个因果关系的小样本时间序列的相关系数,选择与倾斜量相关性高的自变量作为神经网络的输入,有助于提高学习效率。

鉴于以上分析,针对砖石古塔结构形变的小样本、非线性等特点,通过分析古塔结构沉降与倾斜时间序列的相关性,利用灰色模型理论对原始监测数据进行累加求和,设计 GRFM 灰色神经网络模型,并将该模型应用于小雁塔倾斜预测中,检验了该方法良好的预测精度和工程适用性。

1 基于相关分析的灰色神经网络组合预测模型

利用灰色 RBF 神经网络模型对砖石古塔倾斜进行预测,需要对影响因素、灰色模型和 RBF 神经网络模型输入、输出样本的选择,合理选取样本,建立预测模型并优化模型参数,从而提高预测精度。

1.1 灰色关联度分析

设两个长度为 n 的时间序列向量分别为 X 和 Y ,其中

$$X = (x(1), x(2), \dots, x(k), \dots, x(n)), \\ Y = (y(1), y(2), \dots, y(k), \dots, y(n)),$$

二者的灰色邓氏相关系数表示为

$$\gamma(x(k), y(k)) = \frac{\min_x \min_y |x(k) - y(k)| + \zeta \max_x \max_y |x(k) - y(k)|}{|x(k) - y(k)| + \zeta \max_x \max_y |x(k) - y(k)|} \quad (1)$$

二者的邓氏相关度表示为:

$$\gamma(X, Y) = \frac{1}{n} \sum_{k=1}^n \gamma(x(k), y(k)) \quad (2)$$

1.2 灰色 GM(1, 1) 模型

灰色 GM(1, 1) 模型是单变量二阶微分方程,通过对原始数据进行累加求和和生成处理,构建指数增长型数列,弱化数据的随机因素,生成规律性较强

的数据序列,从而有效降低数据的随机干扰^[13]。

设 $X^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n))$ 为原始时间序列,对其进行 1-AGO 累加求和运算,即 $x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i)$, 其中, $k = 1, 2, \dots, n$ 。从而生成其累加序列 $X^{(1)} = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n))$

对 $X^{(1)}$ 中的序列值求其紧邻均值,即 $z^{(1)}(k) = 0.5x^{(1)}(k) + 0.5x^{(1)}(k-1)$, 生成其紧邻均值序列

$$Z^{(1)} = (z^{(1)}(2), z^{(1)}(3), \dots, z^{(1)}(n))$$

分别建立自变量为 $X^{(0)}$, 因变量为 Z_1 的 GM(1, 1) 灰色微分方程

$$x^{(0)}(k) + ax^{(1)}(k) = b \quad (3)$$

其中,参数 $-a$ 为发展系数, b 为灰色作用量。其时间响应序列为:

$$x^{(1)}(k+1) = (x^{(0)}(1) - \frac{b}{a})e^{-ak} + \frac{b}{a} \quad (4)$$

原始序列的估计值可以通过累减操作将 $x^{(1)}(k+1)$ 序列进行还原,即

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k) \quad (5)$$

1.3 RBF 神经网络预测

RBF 神经网络包含三层,分别为输入层、隐含层和输出层。输入层有 n 个神经元,输入向量为

$$X \in R^n, \quad X = (x_1, x_2, \dots, x_n)^T$$

隐含层有 l 个神经元,隐层输出矢量 $H \in R^l$, $H = (h_1, h_2, \dots, h_l)^T$, 输出层有 m 个神经元,输出矢量为 $Y \in R^m$, $Y = (y_1, y_2, \dots, y_m)^T$ 。其中, n, l, m 分别代表输入层、隐含层和输出层节点的数量^[14]。

在隐含层,每一个节点都使用非线性函数作为径向基函数(RBF),从输入空间到隐含空间的变换 $\hat{x} \rightarrow H_j(x)$, 选择 Gaussian 函数作为 RBF 神经网络的径向基函数,来实现在隐含层 x 节点的非线性映射,其公式为

$$H_j(x) = \psi\left(\frac{\|x - c_j\|}{\sigma_j}\right) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right) \quad (6)$$

其中: c_j 为基函数的中心点, σ_j 为扩展系数, j 为 $1 \sim l$ 的整数。

RBF 的输出估计值为

$$y_{kp} = \sum_{j=1}^l W_{kj} \psi\left(\frac{\|x_p - c_j\|}{\sigma_j}\right) \quad (7)$$

式中, y_{kp} 表示第 p 个输入层节点 x_p 对应的第 i 个输出层节点的输出值; W_{kj} 表示隐含层第 j 个径向基函

数连接到输出层第 k 个节点的权值。

1.4 基于灰色关联度的 GRFM 倾斜量预测模型

古塔建筑结构的倾斜量呈现出一个非平稳震荡的特点, 用回归分析方法简单预测不合适。考虑到古塔的倾斜是由于四个方位不均匀沉降而造成的, 将沉降综合指数与倾斜量两个时间序列分别输入灰色系统, 计算两个时间序列的累加序列。

如图 1 所示, 将趋势项输入 RBF 神经网络, 对偏移量进行预测, 并做精度检验, 达到预测精度输出倾斜预测量, 否则重新返回 RBF 神经网络, 进行学习拟合, 直达满足预测精度要求为止。

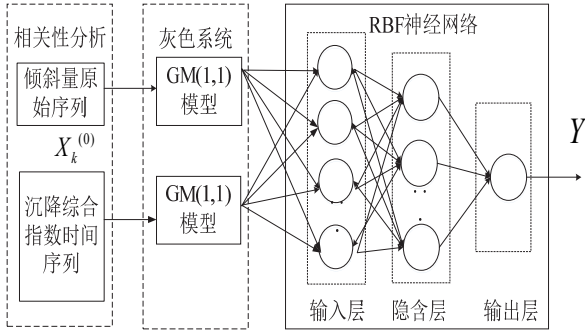


图 1 GRFM 预测模型

Fig. 1 GRFM forecasting model

GRFM 组合建模的主要步骤如下:

步骤 1: 通过古塔四个方位的沉降值计算沉降综合指数, 计算沉降与倾斜量监测数据的相关性, 保证灰色神经网络输入的样本选择的合理性。根据公式(1)和公式(2), 采用邓氏灰色关联度来表示沉降综合指数与倾斜量的关联关系。

步骤 2: 建立沉降综合指数和倾斜量两个序列的 GM(1, 1)灰色微分方程, 采用最小二乘法来确定发展系数 a 和灰色系数 b [15], 即

$$\hat{a} = (a, b)^T = (B^T B)^{-1} B^T Y$$

$$Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \dots \\ x^{(0)}(n) \end{bmatrix}, B = \begin{bmatrix} -z^{(1)}(2) & (z^{(1)}(2))^2 \\ -z^{(1)}(3) & (z^{(1)}(3))^2 \\ \dots & \dots \\ -z^{(1)}(n) & (z^{(1)}(n))^2 \end{bmatrix}$$

确定式(4)从而确定时间响应方程, 求得沉降综合指数序列和倾斜量的灰色预测值 $X_1^{(1)} = \{\hat{x}_1^{(0)}(k)\}$ 和 $X_2^{(1)} = \{\hat{x}_2^{(0)}(k)\}$, $k=1, 2, \dots, n$ 。

步骤 3: 为了增强预测的精度, 在 RBF 训练之前, 将 GM(1, 1)预测的序列结果 $X_1^{(1)}, X_2^{(1)}$ 根据公式(8)归一化处理。

$$x_i = \frac{\hat{x}_i^{(0)} - \min}{\max - \min} \times 0.8 + 0.1, i=1, 2 \quad (8)$$

式中: \max 和 \min 分别表示该序列数据的最大值和最小值。从而求得 $X_1 = \{x_1(k)\}$ 和 $X_2 = \{x_2(k)\}$, $k=1, 2, \dots, n$ 。

步骤 4: 将步骤 3 的结果输入 RBF 神经网络, 用蚁群聚类算法初始化公式(6)中的中心点 c_j 和扩展系数 σ_j , 对倾斜偏移量进行预测, 并做精度检验, 直达满足预测精度要求为止。

设给定沉降综合指数趋势归一化后的沉降样本集 X_1 , 将 X_1 可以分为 k 个模式

$$C = \{C_1, C_2, \dots, C_k\}, \text{ 且 } \bigcup_{j=1}^k C_j = X_1^{(1)}$$

初始化蚁群算法的信息启发因子 α 、期望启发因子 β 、信息素挥发系数 ρ 和信息素强度 Q 、聚类半径 r , 以及蚂蚁个数 m , 最大进化代数 N , 蚂蚁留下的信息素 $\tau(x_i, m_j)$, 设 RBF 基函数的中心点 m_i 为 C_j 的中心点: $m_j = \sum_{x_i \in C_j} x_i / |C_j|$, 计算每个样本到每个模式中心的欧式距离 $g_{ij}(x)$ 以及启发函数 $\eta_{ij}(t) = 1 / g_{ij}(t)$, 将每只蚂蚁爬过的样本点构成的聚类结果构成一个解, 蚂蚁随机选取模式样本 x_i , 每个样本到各个聚类中心的归属概率为:

$$p(x_i, m_j) = \frac{|\tau(x_i, m_j)|^\alpha \times |\eta(x_i, m_j)|^\beta}{\sum_t |\tau(x_i, m_t)|^\alpha \times |\eta(x_i, m_t)|^\beta} \quad (9)$$

把所有样本分别归类到 k 个模式中, 构成一个解。

蚂蚁在某个样本上留下的信息素 $\tau(x_i, m_j)$ 增加方式为: $\tau(x_i, m_j) = \rho \tau(x_i, m_j) + \Delta \tau(x_i, m_j)$, 其中, ρ 为信息素挥发系数。从 m 只蚂蚁聚类的 m 个解的目标函数值, 选择 k 个最优解。使离散度之和达到最小, 即:

$$F = \min \sum_{j=1}^k \sum_{x_i \in C_j} d(x_i, m_j) \quad (10)$$

最后, 得出最优的聚类中心点 C_j 坐标和所有点到所有类的中心点的平均值 $g_{ij}(x)$, 作为 RBF 的中心点和扩展系数的初值。经过 RBF 训练和优化, 根据公式(7)得到其输出 $Y^{(1)} = \{y^{(1)}_i\}$ 。

步骤 5: 根据公式(11), 将步骤 4 的输出 $y^{(1)}_i$ 反归一化, 得到 $y^{(1)}(i)$

$$y^{(0)}_i = \frac{(y^{(1)}_i - 0.1)(\max - \min)}{0.8} + \min \quad (11)$$

式中: $i=1, 2, \dots, m$, \max 和 \min 与公式 (8) 中的值相同。然后根据公式(5) 对 $y^{(0)}_i$ 做累减运算, 得出倾斜量的预测序列 $Y = \{y_i\}$ 。

2 GRFM 预测模型在小雁塔倾斜量中的应用分析

2.1 小雁塔观测数据

小雁塔系密檐式砖结构佛塔, 由于年代久远, 塔体产生了倾斜和沉降. 为了掌握塔体稳定性, 从2000年开始, 按照《建筑变形测量规程》(JGJ/T8-97)和《建筑变形测量规范》(JGJ8-2007)行业标准和规范对小雁塔进行塔体倾斜量监测和沉降监测, 观测设备见表1.

表1 观测设备与精度

Tab.1 Observation equipment and precision

项目	仪器及设备	标称精度
倾斜	索佳 SET2C-II 全站仪	测角: 2"
观测	索佳 SET230RK3 全站仪	测距: (3mm+2ppm)
沉降	德国产 FG005A 精密水准仪、配套钢钎尺	±0.5mm

如图2所示, 塔底四角编号分别为A5、A6、A7和A8, 塔顶四角编号分别为S1、S2、S3和S4.




图2 小雁塔观测点布置图

Fig.2 The small wild goose pagoda observation point layout

选择 A5~A8 四个沉降监测点的年累积最大值差值、塔刹倾斜量以及顶点坐标作为计算对象, 具体如图3和图4所示.




图3 小雁塔 A5-A8 观测点沉降差值

Fig.3 The small wild goose pagoda settlement observation difference of A5-A8




图4 小雁塔塔顶坐标(2000-2015年)

Fig.4 The small wild goose pagoda tower coordinates from 2000 to 2015

对于保护部门来说, 了解小雁塔的变形动态, 及时掌握其变形规律, 为保护工作提供科学的分析资料, 具有十分重要的现实意义.

2.2 小雁塔沉降综合指数

砖石古塔发生倾斜的主要因素是不均匀沉降. 设 SI 为沉降综合指数, 用以表示不均匀沉降的严重程度; 设小雁塔塔基的东、南、西、北四个观测点 A5、A6、A7、A8 的累积沉降值, 设 $SI_i (i=1,2,\dots,6)$ 表示观测点 A5 与 A6、A6 与 A7、A7 与 A8、A5 与 A8、A5 与 A7、A6 与 A8 的沉降差值. 则有

$$SI = \sqrt{\sum_{i=1}^6 SI_i^2} \quad (12)$$

根据公式(1)和(2), 计算塔顶点和沉降综合指数的相关度为 0.789 1, 属于强相关, 说明二者的相关性较大, 塔顶点的倾斜量预测可以参考塔基的沉降综合指数.

2.3 GM(1, 1)模型拟合

设原始序列中选择序列 X_1, X_2 , 建立相应的 GM(1, 1) 模型方程, 其中: $X_1 = \{x_1^{(0)}(k)\}$ 和 $X_2 = \{x_2^{(0)}(k)\}$, $k=1,2,\dots,n$. 根据公式(3)对 X_1 和 X_2 建立相应的 GM(1, 1) 模型方程, 分别求解得

$$x_1^{(0)}(k+1) = -80.2233e^{0.0696k} + 90.3333 \quad (13)$$

$$x_2^{(0)}(k+1) = -24.128e^{0.0004k} + 27.3279 \quad (14)$$

2.4 RBF 模拟训练与预测

设2000-2012年数据为 Training 训练集, 2013-2015年倾斜量为 Test 测试集合, 最后对2016-2018年的倾斜量进行预测.

实验工具为 Matlab 2009 仿真软件, 分别采用 GM(1, 1)模型和 GRFM 模型通过沉降综合指数对小雁塔倾斜量进行预测, 并计算预测误差. 通过试验, 倾斜量测量值和预测值分别如表4和图5所示.

表 2 训练结果与比较 (单位: mm)
Tab.2 Comparison of the training result/mm

年份	倾斜量	GM 模型 预测值	GM 模型 绝对误差	GRFM 模型 预测值	GRFM 绝对误差
2000	3.200	3.200	0.000	3.197	0.003
2001	5.100	11.620	6.520	5.335	0.235
2002	18.200	10.380	7.820	17.964	0.236
2003	14.300	9.260	5.040	13.231	1.069
2004	2.800	8.270	5.470	7.215	4.415
2005	10.800	7.380	3.420	5.361	5.439
2006	3.500	6.590	3.090	4.928	1.428
2007	2.500	5.880	3.380	4.816	2.316
2008	5.100	5.250	0.150	4.756	0.344
2009	5.300	4.690	0.610	4.665	0.635
2010	5.010	4.190	0.820	4.485	0.525
2011	5.000	3.740	1.260	4.177	0.823
2012	3.000	3.340	0.340	3.764	0.764
平均绝对误差		2.917		1.402	

为了检验GRFM模型训练和预测误差,采用MAE(平均绝对误差)标准和MAPE(平均相对误差)标准进行检验,具体如公式(15)和(16)所示.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i(k) - \hat{y}_i(k)| \quad (15)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i(k) - \hat{y}_i(k)|}{y_i(k)} 100\% \quad (16)$$

从表 GRFM 预测模型的平均绝对误差为 1.402 mm, 相对于 GM 模型来说, 优势明显, 具有良好的拟合效果.




图 5 倾斜量训练结果
Fig. 5 Training results

从图 5 可以看出, 用 GRFM 预测算法可以很好的倾斜量发展趋势和细节变化, 该模型与 GM 模型比较, 其平均相对误差性能具有很大优势. 在拟合过程中, 灰色 GM(1, 1)模型只能拟合总体趋势, 而灰色神经网络模型可以很好的拟合具体细节, 表现出了良好的拟合能力.

如表 3 所示, 根据公式(16), GRFM 模型预测

的平均相对误差为 9.056%. 采用 GRFM 对 2016-2018 年的倾斜量进行预测, 得 2016 年、2017 年和 2018 年的倾斜量预分别为 4.538 mm, 4.560 mm 和 4.590 mm. 从图 5 中可以看出, 从 2006 年以来, 倾斜量值相对稳定, 2016-2018 年的倾斜量略低于 2008 年, 属于稳定状态.

表 3 预测结果与比较 (单位: mm)
Tab.3 Comparison of the forecasting result

年份	倾斜量	GM 模型	GM 相对误差	GRFM 预测	GRFM 相对误差
2013	3.100	2.980	0.240	3.353	0.133
2014	3.500	2.660	0.210	3.035	0.057
2015	3.000	2.570	0.557	2.828	0.328
2016		2.532		4.538	
2017		2.492		4.560	
2018		2.489		4.590	
平均相对误差		16.290%		9.056%	

根据该模型的预测值, 按照《建筑变形测量规程》(JGJ/T8-97)规范, 已知小雁塔从塔基到塔顶的高度为 38.14 m, 可以计算 2013-2018 年的倾斜度, 具体如表 6 所示.

表 4 2013-2018 倾斜量预测
Tab.4 Inclination forecast of 2013-2018

年份	倾斜量/mm	倾斜度/‰
2013	3.353	0.0879
2014	3.035	0.0796
2015	2.828	0.0741
2016	4.538	0.1190
2017	4.560	0.1196
2018	4.590	0.1203

根据建筑地基基础设计规范(GB50007-2011)中民用建筑倾斜标准, 小雁塔的倾斜量均在 200 mm 以下, 倾斜度在 0.8% 以下, 在近几年内倾斜量和倾斜度均较为稳定, 该结论与文献[16]的分析一致.

3 结论

设计了基于灰色关联分析的 GRFM 预测模型, 采用灰色相关分析理论分析了沉降和倾斜量的相关度, 利用灰色模型建立倾斜量相关因素累加求和, 建立紧邻均值序列, 采用基于蚁群算法的 RBF 神经网络对倾斜量进行预测, 该模型的有效性在小雁塔倾斜量预测中得到了有效性的验证, 为砖石古塔稳定性分析提供了一种基于监测数据的分析方法. 研究的结论主要包括:

(1) 模型采用灰色关联分析法计算了预测量与影响因素之间的相关度, 在二者属于强关联的情况下进行预测, 保证了该模型对具有相关性时间序列预测的可靠性.

(2) 模型通过灰色系统建立影响因素的累加序列,降低数据的随机性,保证该模型适用于“小样本”数据;采用基于蚁群算法的 RBF 神经网络对倾斜量进行预测,发挥 RBF 神经网络的快速收敛特点,对非线性数据具有预测优势,能够有效地提高预测精度,其预测精度明显高于 GM(1,1)灰色模型。实验证明,采用 GRFM 模型对非线性、小样本性和动态性的时间序列的预测是有效的。

(3) 该模型在小雁塔倾斜量预测应用中,在计算了沉降综合指数与倾斜量的基础上,对倾斜量进行预测。根据《建筑地基基础设计规范》(GB5007-2002),实验结果表明小雁塔的塔身倾斜量较为稳定,整体的结构安全性良好,在短期内没有结构风险。

当然,时间序列影响因素较多,需要针对多种因素的进行选择,既保证预测的精度,有尽量降低预测模型的计算量。因此,课题组的下一个工作重点是建立多种因素对倾斜量的相关性,研究多种影响因素的有效选择,研究基于多因素相关的倾斜量预测模型。

参考文献 References

- [1] GULLINO P, LARCHER F. Integrity in UNESCO world heritage sites: A comparative study for rural landscapes [J]. Journal of Cultural Heritage, 2013, 14(3): 389-395.
- [2] ELISA F, FRANCO S, SIMONE B. et al. An experimental fixture for continuous monitoring of electrical effects in moist masonry walls[J]. Construction and Building Materials, 2013, 25(4): 2023-2029.
- [3] 李战胜. 复合地基上建筑物沉降发展规律研究[D]. 郑州: 郑州大学, 2007.
LI Zhansheng. Study on the development of building settlement on composite foundation[D]. Zhengzhou: Zhengzhou University, 2007.
- [4] 杨涛, 李国维, 杨伟清. 基于双曲线法的分级填筑路堤沉降预测[J]. 岩土力学, 2004, 25(10): 1551-1554.
YANG Tao, LI Guowei, YANG Weiqing. Prediction of the settlement of embankment with the classification based on the hyperbolic method [J]. Rock and Soil Mechanics, 2004, 25(10): 1551-1554
- [5] KOUKOUTAS S P, SOFIANOS A I. Settlements due to single and twin tube urban EPB shield tunnelling[J]. Geotechnical and Geological Engineering, 2015, 33(3): 487-510.
- [6] CHEN Ping, XIE Xiaoning, CHEN Te. Seismic risk assessment of ancient timber-structure[J]. World Earthquake Engineering, 2015, 3(1): 16-21.
- [7] 徐峰, 汪洋, 杜娟, 等. 基于时间序列分析的滑坡位移预测模型研究[J]. 岩石力学与工程学报, 2011(4): 746-751.
XU Feng, WANG Yang, DU Juan, et al. Study of displacement prediction model of landslide based on time series analysis[J]. Journal of Rock Mechanics and Engineering, 2011(4): 746-751.
- [8] 王智磊, 孙红月, 尚岳全. 基于地下水位变化的滑坡预测时序分析[J]. 岩石力学与工程学报, 2011, 11: 2276-2284.
WANG Zhilei, SUN Hongyue, SHANG Yuequan. Time series analysis of landslide prediction based on groundwater level variation[J]. Journal of Rock Mechanics and Engineering, 2011, 11: 2276-2284.
- [9] POURTAGHI, YAGHIN L M A A. Wavenet ability assessment in comparison to ANN for predicting them aximum surface settlement caused by tunneling[J]. Tunneling and Underground Space Technology, 2012, 28(1): 257-271
- [10] AZADI M, POURAKBA S, KASHFIC Ali. Assessment of optimum settlement of structure adjacent urban tunnel by using neural network methods[J]. Tunneling and Underground Space Technology, 2013, 37(5): 1-9.
- [11] FALAMARZIA Y, PALIZDANA N, HUANGB Y F, et al. Estimating evapo-transpiration from temperature and wind speed data using artificial and wavelet neural networks [J]. Agricultural Water Management, 2016, 164(5): 26-36.
- [12] FALAMARZIA Yashar, PALIZDANA Narges, HUANGB Y F, et al. Estimating evapo-transpiration from temperature and wind speed data using artificial and wavelet neural networks[J]. Agricultural Water Management, 2016, 164(5): 26-36.
- [13] OCAK I, SEKER S E. Calculation of surface settlements caused by EPBM tunneling using artificial neural network, SVM, Gaussian processes[J]. Environmental Earth Sciences, 2013, 26(1): 257-266
- [14] 高宁, 潘传姣, 李建刚. 深埋隧道围岩变形预测的非线性组合模型[J]. 金属矿山, 2014(8): 45-48.
GAO Ning, PAN Chuanjiao, LI Jiangang. Non-linear combination forecast model to predict Surrounding rock deformation in deep buried tunnels [J]. Metal Mine, 2014 (8): 45-48.
- [15] AHMADI MA, ZENDEHBOUDI S, LOHI A, et al. Reservoir permeability prediction by neural networks combined with hybrid genetic algorithm and particle swarm optimization[J]. Geophysical Prospecting, 2013, 61(3): 582-598.
- [16] 李小珠, 高大峰, 吴健康. 小雁塔的抗震性能评估. 水利与建筑工程学报, 2009, 07(2): 33-35.
LI Xiaozhu, GAO Dafeng, WU Jiankang. Evaluation on seismic performance of small goose pagod[J]. Journal of Water Resources and Architectural Engineering, 2009, 07(2): 33-35.

(编辑 吴海西)