

DOI: 10.11835/j.issn.2096-6717.2021.092



开放科学(资源服务)标识码 OSID:



# 基于小波变换的 GASVM-ARMA 模型 在深基坑变形预测中的应用

牛帅星<sup>1</sup>, 李庶林<sup>1</sup>, 刘胤池<sup>1</sup>, 安树正<sup>1</sup>, 黄玉仁<sup>1,2</sup>

(1. 厦门大学建筑与土木工程学院, 福建 厦门 361005; 2. 中铁二十四局集团福建公司, 福州 350013)

**摘要:** 为了提高深基坑施工过程中变形预测的准确度, 提出一种基于小波变换分解与重构、采用遗传算法优化参数的支持向量机(GASVM)和自回归滑动平均(ARMA)模型相结合的组合模型预测方法。使用 GASVM 模型对小波分解后的趋势项进行一步预测和多步滚动预测, 使用 ARMA 模型相应地对随机项进行预测, 将预测值求和得到最终预测结果。以某地铁车站深基坑为案例, 对 3 个监测点的支护桩深层水平位移进行预测分析, 得到其一步预测的短期预测值和多步滚动预测的中长期预测值, 并与单一采用 GASVM 模型得到的预测值进行对比。结果表明: 组合模型有效减小了预测误差, 在短期和中长期预测中均取得令人满意的结果。

**关键词:** 时间序列预测; 深基坑变形; 小波变换; 支持向量机; 遗传算法; 自回归滑动平均模型

**中图分类号:** TU433 **文献标志码:** A **文章编号:** 2096-6717(2023)03-0016-08

## Application of GASVM-ARMA model based on wavelet transform in deformation prediction of deep foundation pit

NIU Shuaixing<sup>1</sup>, LI Shulin<sup>1</sup>, LIU Yinchí<sup>1</sup>, AN Shuzheng<sup>1</sup>, HUANG Yuren<sup>1,2</sup>

(1. School of Architecture and Civil Engineering, Xiamen University, Xiamen 361005, Fujian, P. R. China;

2. China Railway 24th Bureau Fuzhou Branch, Fuzhou 350013, P. R. China)

**Abstract:** In order to improve the accuracy of deformation prediction during construction of deep foundation pits, this paper proposes a support vector machine with genetic algorithm optimized parameters (GASVM) and autoregressive moving average (ARMA) model based on wavelet transform decomposition and reconstruction. This paper uses GASVM model to make one-step prediction and multi-step rolling prediction for trend items after wavelet decomposition, utilizing ARMA model to predict random items accordingly, and to sum the predicted values to get the final prediction result. Finally, taking a deep foundation pit of a subway station as a case, the prediction and analysis of the deep horizontal displacement of the supporting piles at the three

**收稿日期:** 2021-02-02

**基金项目:** 国家自然科学基金(51674218)

**作者简介:** 牛帅星(1996-), 男, 主要从事深基坑和抗浮结构研究, E-mail: shuaixing\_niu@163.com。

李庶林(通信作者), 男, 教授, E-mail: shulin.li@163.com。

**Received:** 2021-02-02

**Foundation item:** National Natural Science Foundation of China (No. 51674218)

**Author brief:** NIU Shuaixing (1996-), main research interests: deep foundation pit and anti-floating structure, E-mail: shuaixing\_niu@163.com.

LI Shulin (corresponding author), professor, E-mail: shulin.li@163.com.

monitoring points are obtained, and the short-term prediction value of one-step prediction and the medium- and long-term prediction value of multi-step rolling prediction are obtained. The predicted value of the GASVM model is used for comparison. The results show that the combined model in this paper effectively reduces the predictive error, and has achieved satisfactory results in both short-term and medium- and long-term estimations.

**Keywords:** time series forecast; deep foundation pit deformation; wavelet transform; support vector machine; genetic algorithm; autoregressive moving average model

地铁工程施工一般位于城市的中心地带,其周边高层建筑物、地下管线、地面交通道路等环境纷繁复杂,给地铁工程基坑开挖提出了极高的要求。对基坑开挖过程中产生的监测信息进行有效的分析和预测,能够及时调整基坑支护参数,优化施工方案和合理安排工程进度,从而有效保障施工安全。因此,建立反映基坑开挖过程中周围土体及围护桩深层水平位移、地面沉降及坑底隆起、相邻建(构)筑物及地下管线的侧移、沉降或倾斜等的确定性基坑变形预测模型显得尤为重要。

常用的基坑变形预测模型有灰色模型、小波分析、BP神经网络算法、支持向量机(SVM)、自回归滑动平均(ARMA)模型等,这些单一模型<sup>[1-5]</sup>或者组合模型<sup>[6-9]</sup>通常都有各自的适用性和局限性,例如,胡冬等<sup>[1]</sup>利用灰色系统理论对基坑变形数据建立GM(1,1)预测模型,对基坑的短期变形做出了较好的预测,但对于长期预测的效果不佳。郭健等<sup>[2]</sup>将小波变换与Elman神经网络耦合方法相结合,建立了WPEM预测模型,对基坑变形数据的预测取得了较好的结果,但其模型仅适用于对现有数据的超前一步预测。王晶晶等<sup>[3]</sup>将趋势函数回归模型和ARMA模型分别应用于沉降监测序列的趋势项和随机项中,克服了ARIMA模型在长期预测中精度较差的缺点,但其方法仅对于增长较为平稳的建筑沉降序列预测效果较好,存在一定的局限性。石祥锋等<sup>[6]</sup>利用遗传算法对SVM的参数进行寻优,建立了GA-SVM模型并对基坑地面沉降进行了预测,提高了单一SVM模型的预测精度和收敛速度,但其方法同样仅应用于一步预测中,在多步滚动预测中的适用性有待验证。李思慧等<sup>[7]</sup>通过LMD分解出基坑变形波动性、随机性和变形趋势特征的分量,建立了LMD-PSO-LSSVM组合模型来改善PSO-LSSVM模型的预测误差和拟合泛化能力,其缺点在于模型复杂度较高,导致运行速度变慢。

笔者从基坑变形原始数据的小波分解和重构出发,结合支持向量机(SVM)方法和自回归滑动平均(ARMA)模型建立组合预测方法和模型,将基坑

变形原始数据的趋势项和随机项加以区分,分别做出分析预测,结合一步预测和多步滚动预测方法,获得基坑变形的短期预测值和中长期预测值,并将组合模型应用于基坑支护桩深层水平位移的预测中,探讨其在基坑施工变形预测中的应用。

## 1 基于小波变换的GASVM-ARMA模型

### 1.1 基本理论

1.1.1 小波变换 小波的定义为:设 $\psi(t)$ 为一平方可积函数,即 $\psi(t) \in L^2(R)$ ,若它的傅里叶变换 $\hat{\psi}(\omega)$ 满足容许前提

$$C_{\psi} = \int_{-\infty}^{+\infty} |\hat{\psi}(\omega)|^2 2\omega^{-1} d\omega < \infty \quad (1)$$

则把 $\psi(t)$ 称作小波母函数。此时,再对小波 $\psi(t)$ 做伸缩和平移就能得到一个小波基函数集合 $\{\psi_{a,b}(t)\}$ 。

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in R, a \neq 0 \quad (2)$$

式中: $a$ 为尺度因子; $b$ 为平移因子。小波变换的本质是把原信号 $f(t)$ 在 $t=b$ 按 $\psi_{a,b}$ 进行加权平均来表现 $f(t)$ 在 $t=b$ 周围随分析而表现的变化,即

$$w_f(b, a) = \int f(x) \psi_{a,b}(t) dt \quad (3)$$

通过小波变换可将基坑变形原始监测数据分解成若干层高频和低频信息,以高频信息为误差信息,低频信息为有用信息。将基坑变形噪声模型表示为

$$s(n) = f(n) + \sigma \cdot e(n) \quad (4)$$

式中: $s(n)$ 为原始监测数据; $f(n)$ 为趋势项; $\sigma$ 为噪声水平; $e(n)$ 为误差信息; $n$ 为等间隔的时间。

对不同小波基函数分解重构结果进行对比后,最终选用db4正交小波对监测数据进行3层分解<sup>[10]</sup>。

1.1.2 支持向量机(SVM) 支持向量机(SVM)方法<sup>[11-12]</sup>是通过选用映射核函数将输入的非线性原空间变换到一个高维特征空间,构造出最优超平面。对于训练样本集 $(x_i, y_i) = 1, 2, 3 \dots l$ ,

$x_i \in R^n, y_i \in R$ , 引入非线性变换  $\phi(x)$ , 将数据集映射到高维特征空间中进行线性回归, 其回归方程可表示为

$$f(x) = w\phi(x) + b \quad (5)$$

上述函数回归问题可以转换为求解式(6)的最小值问题。

$$R(f) = \frac{1}{2} \|w\|^2 + C \frac{1}{l} \sum_{i=1}^l L_\epsilon(y_i, f(x_i)) \quad (6)$$

式中:  $C$  称为惩罚因子;  $\epsilon$  为损失函数。综合考虑拟合误差, 引入松弛变量  $\xi_i$  和  $\xi_i^*$ , 使优化目标为

$$\begin{aligned} \min & \left[ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \right] \\ \text{s.t.} & \begin{cases} y_i - w\phi(x_i) - b \leq \epsilon + \xi_i \\ w\phi(x_i) + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 (i = 1, 2, \dots, l) \end{cases} \end{aligned} \quad (7)$$

为了求解式(7)的最优解, 引入拉格朗日函数, 求 Lagrange 因子  $a_i, a_i^*$  的最大目标函数

$$\begin{aligned} W(a, a^*) &= -\frac{1}{2} \sum_{i,j} (a_i^* - a_i)(a_j^* - a_j)(x_i \cdot x_j) + \\ & \sum_{i=1}^k y_i (a_i^* - a_i) - \epsilon \sum_{i=1}^k (a_i^* + a_i) \\ \text{s.t.} & \sum_{i=1}^n (a_i - a_i^*) = 0 \quad (0 \leq a_i, a_i^* \leq C, i = 1, 2, \dots, n) \end{aligned} \quad (8)$$

最终得到的回归函数为

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) k(x_i, x) + b \quad (9)$$

式中:  $k(x_i, x) = \varphi(x_i) \varphi(x)$ , 是 SVM 的核函数。

支持向量机 SVM 常用的核函数有多种。高斯径向基核函数(RBF)具有能够较好地实现非线性映射、参数数量少、数值计算难度较小等优点<sup>[13]</sup>。因此, 选用 RBF 核函数。

SVM 的预测结果对惩罚参数  $C$ 、核函数参数  $g$  有高度敏感性, 传统的参数选择多数依靠经验, 这种方法耗时长且不一定最优。采用遗传算法<sup>[14]</sup>(Genetic Algorithm, GA)对 SVM 的  $C$  和  $g$  进行优化, 寻找最优参数。其主要步骤为: 1) 对每个个体进行初始编码; 2) 由指定的适应度函数对个体适应环境的能力进行评价, 根据个体的适应度值和选择原则选择进入下一代个体; 3) 令当前一代种群产生交叉、变异, 产生下一代群体; 4) 若满足停止条件, 停止运算, 解码得到最优解, 若不满足条件, 转到 2) 重新迭代。最终到达或接近最优解。

1.1.3 自回归滑动平均(ARMA)模型 自回归滑

动平均(ARMA)模型<sup>[15-17]</sup>的基本思路为: 将某一具有特定变化规律的时间序列通过如下数学模型的形式近似表示, 即可根据时间序列的过去值预测其未来的变化趋势, 即对于时间序列  $\{x_t\} (t = 1, 2, \dots, n)$ , 其自回归滑动平均模型 ARMA( $p, q$ ) 可以表示为

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + a_t - \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (10)$$

式中:  $\varphi_1, \varphi_2, \dots, \varphi_p$  为自回归系数;  $\theta_1, \theta_2, \dots, \theta_q$  为滑动平均系数;  $p, q$  为系数的阶数;  $a_t, a_{t-1}, \dots, a_{t-q}$  为互相独立的白噪声序列。如果原序列非平稳, 经过  $d$  阶逐期差分后平稳, 则原序列可表示为 ARIMA( $p, d, q$ ) 模型。

## 1.2 基于小波变换的 GASVM-ARMA 模型的建立

1.2.1 数据预处理 在基坑施工监测过程中, 监测频率往往随施工进度的变化而改变, 导致基坑监测数据并非等时距。应当对基坑监测数据进行等时距处理, 以提高变形预测的准确性。对原始监测数据进行分段线性插值, 插值后连续两次监测数据的时间间隔为 2 d。

采用 db4 正交小波将插值变形数据进行 3 层分解, 重构成一个较为平滑的趋势时间序列和 3 个随机时间序列。其中, 趋势时间序列反映了基坑施工过程中的力学演变特征, 随机时间序列即为过滤出的无序杂波。

1.2.2 趋势时间序列的 GASVM 预测 针对趋势时间序列, 采用 GA 对 SVM 参数  $C$  和  $g$  进行寻优, 建立 GASVM 时间序列预测模型, 对插值变形数据的时间序列进行训练, 寻找时间序列的变化规律  $F$ , 通过  $F$  求出时间序列下一个时间点的变形数据<sup>[18]</sup>。在预测过程中采用两种预测方法分别得到一步预测和多步滚动预测的预测结果。假设对时间序列  $\{x_t\}$  进行预测, 目前, 已获得前  $n$  个变形监测数据,  $p$  为最优学习样本数, 采用  $\{x_1, x_2, \dots, x_{n-1}, x_n\}$  作为训练集样本, 其对应的特征向量为  $\{X_1, X_2, \dots, X_{n-1}, X_n\}$ , 其中  $X_i = \{x_{i-p-1}, x_{i-p}, \dots, x_{i-2}, x_{i-1}\}^T (i = 1, 2, 3, \dots, n)$  (当  $i - p - 1 < 1$  时, 取  $x_1$  的值)。通过 SVM 回归预测得到下一个时间点  $x_{i+1}$  的预测值。其中, 一步预测方法旨在充分利用最新变形监测数据, 在得到最新时刻的变形监测数据后, 将其用于下一时间点预测训练样本中, 从而实现了对基坑变形数据的短期预测; 多步滚动预测方法旨在根据前期训练数据, 预测未来

一段时间内的基坑变形特征,将前一步的预测值作为下一步的监测数据进行滚动预测,并以此类推。通过一步预测或多步滚动预测即可得到对于趋势时间序列的预测值。

1.2.3 随机时间序列的 ARMA 模型预测 为了提高预测的准确性,减少基坑变形原始数据中有效信息的丢失,针对随机时间序列,利用 ARMA 模型的一步预测方法和多步滚动预测方法得到其预测值。模型建立具体步骤为:通过小波变换后的随机时间序列均为平稳序列,不需要进行差分处理,可直接采用 ARMA 模型;通过随机时间序列的自相关和偏相关性图来初步判断模型的阶数  $p$  和  $q$  的可能取值,初选模型  $ARMA(p, q)$ ;估计模型的参数并检验(包括参数的显著性检验和残差的随机性检验),然后判断所建模型是否可取;利用所取参数所建立的模型,对样本时间序列进行预测。其一步预测和多步滚动预测的实现方式同趋势时间序列相似。

最后,将趋势时间序列预测值和随机时间序列预测值求和,作为该处变形数据的预测结果。基于小波变换的 GASVM-ARMA 模型具体流程如图 1 所示。

## 2 工程实例分析

对厦门地铁 3 号线某地铁车站施工基坑的深层水平位移进行预测分析。该车站为地下两层岛式车站,全长 196 m,标准基坑宽度 19.7 m,车站埋深 3.6 m,开挖深度 20 m,属深基坑工程,围护结构采用围护桩+内支撑体系<sup>[19]</sup>。由于项目工程场地周边存在民房且地下管网繁杂,为确保基坑施工的顺利进行和周边建筑物的安全,在基坑施工过程中对基坑周围的地面沉降和位移进行了实时监测。

深基坑在开挖过程中的深层水平位移信息能

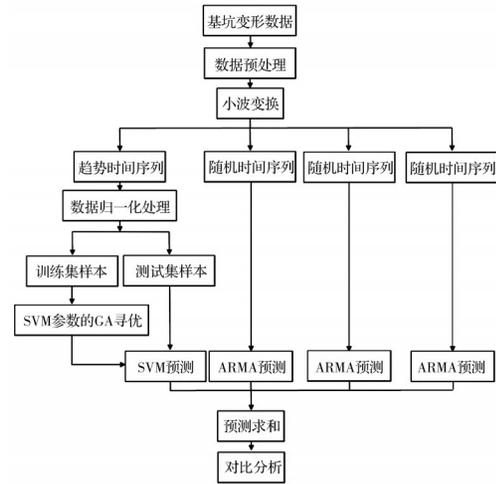


图 1 基于小波变换的 GASVM-ARMA 模型流程图  
Fig. 1 The flow chart of GASVM-ARMA model based on wavelet transform

够很好地反映出基坑开挖和支护设置对于基坑及其周边建筑物的影响,在深层水平位移超过预警值时及时调整施工方案是基坑安全施工中必不可少的环节。项目共设置 12 个围护桩深层水平位移监测点。在各监测点中,基坑南北两侧长边正中心测点 ZQT-9 与测点 ZQT-3、东西两侧测点 ZQT-6 与测点 ZQT-12 变形较大。其中,测点 ZQT-9 与测点 ZQT-3 检测数据变化趋势较为相似,以南侧测点 ZQT-9 为例进行预测分析。基坑西侧测点 ZQT-12 在部分深度的水平位移累计变化值超过了预警值 30 mm,故作为典型监测点进行分析,与其对应的东侧测点 ZQT-6 同样作为对照分析。各监测点的布局如图 2 所示。

以测点 ZQT-9 对应 11 m 测试深度的实测数据为例说明其预测方法。选取 2017-12-24 至 2018-09-21 基坑开挖和主体结构施工阶段的监测数据进行分析。首先,对该阶段数据进行分段线性插值处

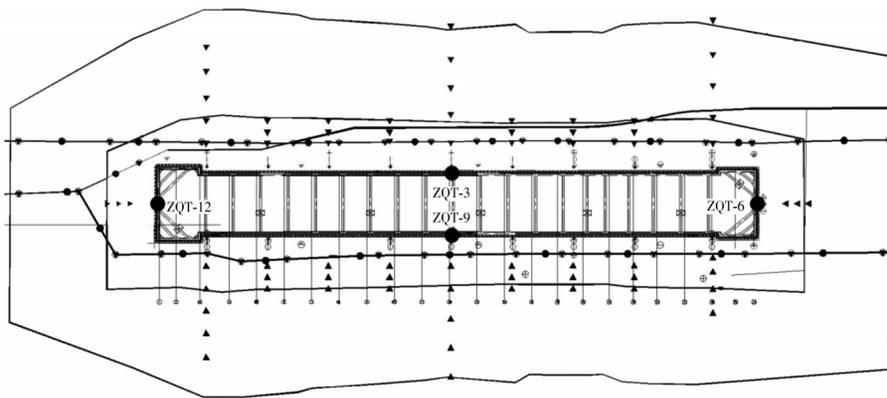


图 2 监测点平面布置图  
Fig. 2 Layout plan of monitoring points

理,在满足等时距要求的同时,充分保证原数据序列的变形规律。插值后连续两次监测数据的时间间隔为 2 d,最终得到 90 组监测数据。将前 80 组数据作为训练集,后 10 组数据作为测试集。首先,利用 db4 正交小波对前 80 组数据进行 3 层分解,得到趋势时间序列  $a_3$  和随机时间序列  $d_1, d_2, d_3$ 。对于趋势时间序列  $a_3$ ,取紧邻每组数据的前面 10 组作为该组数据的训练集标签,建立 GASVM 训练模型,利用所建立起的训练模型对第 81~90 组数据进行一步预测和多步滚动预测,得到趋势时间序列的预测值。对于随机时间序列  $d_1, d_2, d_3$ ,相应地利用 ARMA 模型进行一步预测和多步滚动预测。最后将预测得到的趋势时间序列和 3 个随机时间序列相叠加,作为最终的预测结果,并与测试集基坑变形真实数据进行对比。测点 ZQT-9 插值后的时间序列以及 db 正交小波分解后的趋势时间序列和随机时间序列如图 3 所示。

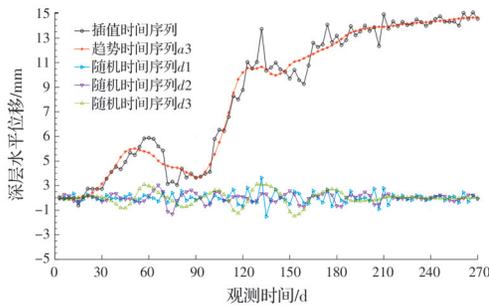


图 3 插值时间序列曲线和 db4 正交小波分解后的时间序列曲线

Fig. 3 Interpolation time series curve and time series curve decomposed by db4 orthogonal wavelet

采用 GASVM 训练模型对趋势时间序列  $a_3$  进行训练,遗传算法优化的初始参数设置为:种群规模为 30,  $C$  和  $g$  的取值范围分别为  $[0, 100]$  和  $[0, 1\ 000]$ ,算法停止条件为适应度函数值  $< 10^{-4}$ ,最大进化代数取 200。经 GASVM 模型优化后,得到最佳惩罚因子  $C = 9.9704$ ,RBF 核函数参数  $g$  的最佳值  $g = 3.1433$ 。利用最佳参数  $C$  和  $g$  对 SVM 进行训练,然后分别对训练集和测试集数据进行回归预测。图 4 为 80 个训练集数据和其回归预测数据的对比图,其中,决定系数  $R^2 = 0.99965$ ,最小均方差  $MSE = 0.0098408$ 。图 5 为预测结果的相对误差分布(由于取紧邻每组数据的前面 10 组作为该组数据的训练集标签,故前 10 组数据预测值无意义),相对误差主要分布在  $-2\% \sim 2\%$  之间。可以

看出,GASVM 模型对训练集数据具有较好的拟合性。

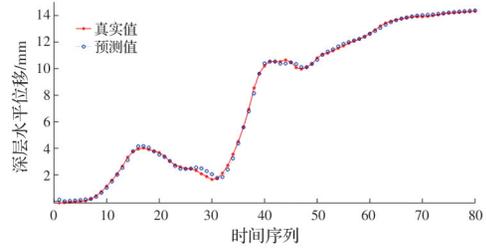


图 4 训练集预测结果对比

Fig. 4 Comparison of training set prediction results

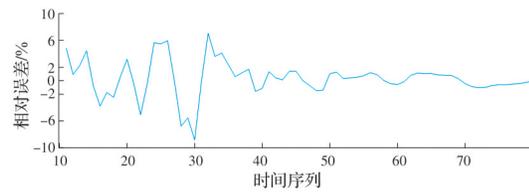


图 5 误差可视图

Fig. 5 The view of error

利用所建立的 GASVM 训练模型对趋势时间序列  $a_3$  的第 81~90 组数据进行一步预测和多步滚动预测,预测结果列于表 1 中。对于随机时间序列  $d_1, d_2, d_3$ ,利用 ARMA 模型进行动态预测,得到相应的预测值。其中,确定  $d_1, d_2, d_3$  的预测模型分别为 ARMA(5, 1)、ARMA(4, 1)、ARMA(2, 1)。

表 1 趋势时间序列  $a_3$  测试集真实值与预测值比较

Table 1 Comparison of the true value and the predicted value of the test set of the trend time series  $a_3$

时间序列	真实值/mm	一步预测/mm	一步预测相对误差/%	多步预测/mm	多步预测相对误差/%
81	14.354	14.418	0.45	14.180	-1.21
82	14.389	14.439	0.35	14.149	-1.67
83	14.429	14.463	0.24	14.124	-2.11
84	14.474	14.491	0.12	14.129	-2.38
85	14.524	14.518	-0.04	14.121	-2.78
86	14.581	14.547	-0.23	14.074	-3.47
87	14.621	14.579	-0.29	14.052	-3.89
88	14.642	14.605	-0.26	14.049	-4.05
89	14.658	14.624	-0.23	14.092	-3.86
90	14.662	14.639	-0.16	14.037	-4.26

最后,将趋势时间序列和 3 个随机时间序列的预测结果求和,作为测点 ZQT-9 最终的预测结果,见表 2(一步预测水平位移 1、相对误差 1、多步预测

水平位移 1、相对误差 2)。为验证基于小波变换的 GASVM-ARMA 模型的预测效果,采用 GASVM 模型直接对原始值的插值时间序列进行回归预测,

并将其预测结果列于表 2(一步预测水平位移 2、相对误差 3、多步预测水平位移 2、相对误差 4)。

表 2 监测点 ZQT-9 深层水平位移实测值与预测值比较

Table 2 Comparison of measured and predicted values of deep horizontal displacement of monitoring point ZQT-9

时间序列	实测水平位移/mm	一步预测水平位移 1/mm	相对误差 1/%	多步预测水平位移 1/mm	相对误差 2/%	一步预测水平位移 2/mm	相对误差 3/%	多步预测水平位移 2/mm	相对误差 4/%
81	14.550	14.616	0.45	14.378	-1.18	14.298	-1.73	14.354	-1.35
82	14.760	14.641	-0.81	14.351	-2.77	14.418	-2.32	14.308	-3.06
83	14.320	14.417	0.67	14.078	-1.69	14.312	-0.06	14.453	0.93
84	14.320	14.297	-0.16	13.935	-2.69	14.522	1.41	14.251	-0.48
85	14.330	14.147	-1.28	13.749	-4.06	14.428	0.68	14.482	1.06
86	14.010	14.127	0.83	13.654	-2.54	14.379	2.63	14.400	2.78
87	15.040	14.864	-1.17	14.337	-4.67	14.398	-4.27	14.330	-4.72
88	14.560	14.571	0.08	14.015	-3.74	14.364	-1.35	14.420	-0.96
89	15.070	15.109	0.26	14.577	-3.27	14.656	-2.75	14.453	-4.10
90	14.560	14.501	-0.41	13.899	-4.54	14.242	-2.19	14.453	-0.73

由表 2 可知,采用组合模型一步预测结果的决定系数  $R^2=0.88816$ ,平均相对误差为  $-0.15\%$ ,取得了令人满意的预测效果;多步滚动预测的结果稍差于一步预测的结果,其平均相对误差为  $-3.02\%$ ,同样具有很高的参考价值。从图 6 可以看出,采用组合模型的深层水平位移一步预测和多步滚动预测结果的变化率与实测值走势相同;与之相比,采用 GASVM 模型的深层水平位移预测值虽然与实测值的误差能够保持在容许范围内,但其走势与实测值相差甚远。可见,相较于 GASVM 模型,采用基于小波变换的 GASVM-ARMA 组合模型对基坑深层水平位移的预测取得了较好的结果。

将该方法应用于监测点 ZQT-6 和监测点 ZQT-

12,其预测结果见图 7。从以上两个监测点的预测

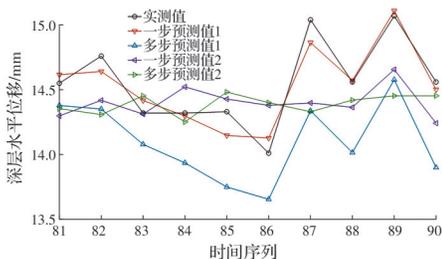
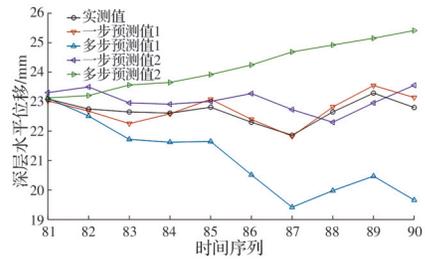
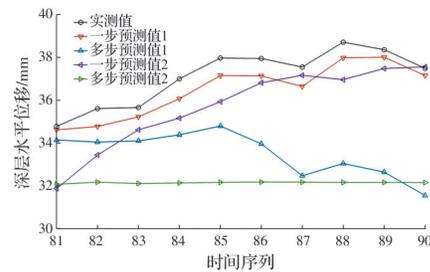


图 6 监测点 ZQT-9 深层水平位移实测值与不同预测模型和方法的预测值比较

Fig. 6 Comparison of the measured value of the deep horizontal displacement of the monitoring point ZQT-9 with the predicted value of different prediction models and methods



(a) 监测点 ZQT-6



(b) 监测点 ZQT-12

图 7 不同监测点的深层水平位移实测值与不同预测模型和方法的预测值比较

Fig.7 Comparison of the measured values of deep horizontal displacement at different monitoring points with the predicted values of different prediction models and methods

结果可以看出,采用组合模型的一步预测能够有效预测下一个时间节点处基坑深层水平位移的变形值,其相对误差平均值分别为  $0.24\%$  和  $-1.70\%$ ,决定系数  $R^2$  分别为  $0.67140$  和  $0.70035$ 。相对于

实测值,采用该组合模型的多步滚动预测结果偏差略大,且随着时间序列的推移,误差逐步扩大,出现这一现象的原因主要在于多步滚动预测将前一步的预测值作为下一步的监测数据,导致其误差也被滚动放大,其相对误差平均值分别为7.14%和-9.54%。且由于该组合模型采用小波变换将深层水平位移数据的趋势项和随机项分别进行预测,使得多步滚动预测结果的变化率也与实测值具有相似的走势,即能够有效预测未来中长期时间内深层水平位移的走势,这对于基坑变形的监测预警具有十分重要的参考意义。

### 3 结论

提出一种基坑深层水平位移时间序列的预测方法,采用小波变换将原始时间序列分解,采用遗传算法优化参数的SVM模型预测其趋势项、ARMA模型预测其随机项,最后叠加产生最终的预测结果。得到以下主要结论:

1)将基坑变形数据的趋势项和随机项分别进行预测,相对平滑的趋势项序列能够有效提高SVM模型的学习和预测效率,将一步预测误差控制在±2%左右。同时,利用ARMA模型对平稳序列预测的优势,对随机项进行预测,减少基坑变形原始数据中无用信息的丢失,从而达到更好的预测效果。

2)将组合模型应用于厦门地铁某车站基坑3个监测点的深层水平位移预测,分别采用一步预测和多步滚动预测方法,得到其短期预测值和中长期预测值,其中一步预测的相对误差平均值分别为-0.15%、0.24%、-1.70%,多步滚动预测的相对误差平均值分别为-3.02%、7.14%、-9.54%,模型取得了良好的预测效果。

3)将组合模型的预测结果与采用单一GASVM模型的预测结果相对比,该方法显著提高了GASVM模型预测的准确性,尤其是在基坑深层水平位移的中长期预测中,该组合模型能够更好地模拟其未来发展趋势,且相对误差平均值控制在10%以内,给深基坑的监测和预警提供了可靠的依据,具有良好的工程应用价值。

### 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.  
HU D, ZHANG X P. Research on predicting deformation of foundation pit based on grey system theory [J]. Chinese Journal of Underground Space and Engineering, 2009, 5(1): 74-78, 168. (in Chinese)
- [2] 郭健, 陈健, 胡杨. 基于小波智能模型的地铁车站基坑变形时序预测分析[J]. 岩土力学, 2020, 41(sup 1): 299-304.  
GUO J, CHEN J, HU Y. Time series prediction for deformation of the metro foundation pit based on wavelet intelligence model [J]. Rock and Soil Mechanics, 2020, 41(Sup1): 299-304. (in Chinese)
- [3] 王晶晶, 尹晖. 一种建筑沉降叠加预测方法[J]. 测绘科学, 2019, 44(3): 107-113, 121.  
WANG J J, YIN H. A method of building settlement superposition prediction based on ARMA model [J]. Science of Surveying and Mapping, 2019, 44(3): 107-113, 121. (in Chinese)
- [4] LV Y, LIU T T, MA J, et al. Study on settlement prediction model of deep foundation pit in sand and pebble strata based on grey theory and BP neural network [J]. Arabian Journal of Geosciences, 2020, 13(23): 1-13.
- [5] LI X, LIU X, LI C Z, et al. Foundation pit displacement monitoring and prediction using least squares support vector machines based on multi-point measurement [J]. Structural Health Monitoring, 2019, 18(3): 715-724.
- [6] 石祥锋, 王丽芬, 沈阳, 等. 基于GA-SVM的基坑施工地面沉降时间序列预测研究[J]. 施工技术, 2017, 46(8): 16-19, 31.  
SHI X F, WANG L F, SHEN Y, et al. Research on time series prediction of foundation excavation construction land settlement based on the GA-SVM [J]. Construction Technology, 2017, 46(8): 16-19, 31. (in Chinese)
- [7] 李思慧, 刘海卿. 基于LMD-PSO-LSSVM组合模型的深基坑变形预测[J]. 地下空间与工程学报, 2018, 14(2): 483-489.  
LI S H, LIU H Q. Deep foundation pit deformation prediction based on LMD-PSO-LSSVM model [J]. Chinese Journal of Underground Space and Engineering, 2018, 14(2): 483-489. (in Chinese)
- [8] ZHANG C, LI J Z, HE Y. Application of optimized grey discrete Verhulst-BP neural network model in settlement prediction of foundation pit [J]. Environmental Earth Sciences, 2019, 78(15): 1-15.
- [9] LUO X L, GAN W J, WANG L X, et al. A prediction model of structural settlement based on EMD-SVR-WNN [J]. Advances in Civil Engineering, 2020 (4): 1-11.
- [10] 周明, 聂艳丽, 李庚银, 等. 基于小波分析的短期电价

- ARIMA 预测方法[J]. 电网技术, 2005, 29(9): 50-55.
- ZHOU M, NIE Y L, LI G Y, et al. Wavelet analysis based arima hourly electricity prices forecasting approach [J]. Power System Technology, 2005, 29(9): 50-55. (in Chinese)
- [11] VAPNIK V N. The nature of statistical learning theory [M]. New York, USA: Springer New York, 2000.
- [12] 毛湘云, 徐冰峰, 孟繁艺. PSO-SVM与BP神经网络组合预测供水系统余氯的方法[J]. 土木与环境工程学报(中英文), 2019, 41(4): 159-164.
- MAO X Y, XU B F, MENG F Y. Prediction of residual chlorine in water supply system by PSO-SVM and BP neural network combined model [J]. Journal of Civil and Environmental Engineering, 2019, 41(4): 159-164. (in Chinese)
- [13] 阎威武, 邵惠鹤. 支持向量机和最小二乘支持向量机的比较及应用研究[J]. 控制与决策, 2003, 18(3): 358-360.
- YAN W W, SHAO H H. Application of support vector machines and least squares support vector machines to heart disease diagnoses [J]. Control and Decision, 2003, 18(3): 358-360. (in Chinese)
- [14] 刘爱国, 薛云涛, 胡江鹭, 等. 基于GA优化SVM的风电功率的超短期预测[J]. 电力系统保护与控制, 2015, 43(2): 90-95.
- LIU A G, XUE Y T, HU J L, et al. Ultra-short-term wind power forecasting based on SVM optimized by GA [J]. Power System Protection and Control, 2015, 43(2): 90-95. (in Chinese)
- [15] ERDEM E, SHI J. ARMA based approaches for forecasting the tuple of wind speed and direction [J]. Applied Energy, 2011, 88(4): 1405-1414.
- [16] WANG Q, YU X H, ZHANG C. The analysis and prediction of China's gross ocean product in coastal areas: Based on the ARMA model [J]. Journal of Coastal Research, 2020, 109(sp1): 51-56.
- [17] 熊志斌. ARIMA融合神经网络的人民币汇率预测模型研究[J]. 数量经济技术经济研究, 2011, 28(6): 64-76.
- XIONG Z B. Research on RMB exchange rate forecasting model based on combining ARIMA with neural networks [J]. The Journal of Quantitative & Technical Economics, 2011, 28(6): 64-76. (in Chinese)
- [18] 曹净, 丁文云, 赵党书, 等. 基于LSSVM-ARMA模型的基坑变形时间序列预测[J]. 岩土力学, 2014, 35 (Sup2): 579-586.
- CAO J, DING W Y, ZHAO D S, et al. Time series forecast of foundation pit deformation based on LSSVM-ARMA model [J]. Rock and Soil Mechanics, 2014, 35 (Sup2): 579-586. (in Chinese)
- [19] 陈煌煜. 地铁深基坑变形监测预测及施工动态风险评估研究[D]. 厦门: 厦门大学, 2019.
- CHEN H Y. Research on deformation monitoring prediction and construction dynamic risk assessment of deep foundation pit of subway [D]. Xiamen, Fujian: Xiamen University, 2019. (in Chinese)

(编辑 胡玲)