

DOI:10.3969/j.issn.1003-5060.2025.04.021

基于GF-GPR的地铁车站基坑变形预测与应用研究

张凤明¹, 苏谦¹, 邓志兴², 王呈金¹, 程梦凡¹, 周辰冷¹

(1. 西南交通大学土木工程学院, 四川成都 610031; 2. 中南大学土木工程学院, 湖南长沙 410083)

摘要:为解决受噪声影响地铁车站基坑变形预测精度受到限制的问题,文章首先使用高斯滤波(Gaussian filter, GF)算法对监测数据进行降噪处理,再采用高斯过程回归(Gaussian process regression, GPR)算法预测基坑变形,构建一种GF-GPR基坑变形预测模型,并将GF-GPR模型应用于成都某车站地铁基坑的变形预测。结果表明:原始监测数据存在大量噪声,变形不连续,经过GF算法降噪后基坑变形序列变得平稳,同时有用的突变信息仍然被保留。降噪后数据的信噪比(signal-to-noise ratio, SNR)为12.884~17.139,均方误差(mean square error, MSE)为0.430~0.875 mm;所提出的GF-GPR模型的变形预测结果与基坑实际变形趋势一致,GF-GPR模型的预测精度相较于单一GPR算法提高了31%~81%,最大均方根误差降低了0.4367~1.2881 mm。该研究成果可为基坑变形智能预测、施工事故防范提供参考。

关键词:地铁车站;组合预测模型;变形预测;基坑水平位移;高斯滤波(GF);高斯过程回归(GPR)

中图分类号:U216.417 **文献标志码:**A **文章编号:**1003-5060(2025)04-0563-07

Research on deformation prediction and application of subway station foundation pit based on GF-GPR

ZHANG Fengming¹, SU Qian¹, DENG Zhixing²,
WANG Chengjin¹, CHENG Mengfan¹, ZHOU Chenling¹

(1. School of Civil Engineering, Southwest Jiaotong University, Chengdu 610031, China; 2. School of Civil Engineering, Central South University, Changsha 410083, China)

Abstract: In order to solve the problem that the prediction accuracy of foundation pit deformation in subway stations is limited due to noise, Gaussian filter (GF) algorithm is used to reduce the noise of monitoring data, and then Gaussian process regression (GPR) algorithm is used to predict foundation pit deformation, and a GF-GPR foundation pit deformation prediction model is constructed. The GF-GPR model is applied to the deformation prediction of a subway station foundation pit in Chengdu City. The results show that there is a lot of noise in the original monitoring data, and the deformation is discontinuous. After the noise reduction by GF algorithm, the deformation sequence of foundation pit becomes stable, and the useful mutation information is still retained. The signal-to-noise ratio (SNR) and mean square error (MSE) range from 12.884 to 17.139 and 0.430 mm to 0.875 mm, respectively. The deformation prediction results of the proposed GF-GPR model are consistent with the actual deformation trend of the foundation pit. Compared with the single GPR model, the prediction accuracy of the GF-GPR model is increased by 31%~81%, and the maximum root mean square error (RMSE) is reduced by 0.4367~1.2881 mm. The research results can provide references for the intelligent prediction of foundation pit deformation and the prevention of construction accidents.

Key words: subway station; combination prediction model; deformation prediction; horizontal displacement of foundation pit; Gaussian filter (GF); Gaussian process regression (GPR)

收稿日期:2023-12-14;修回日期:2024-02-27

基金项目:国家自然科学基金资助项目(51978588);国家自然科学基金联合基金资助项目(U2268213)

作者简介:张凤明(2000—),女,四川眉山人,西南交通大学硕士生;

苏谦(1972—),男,山西运城人,博士,西南交通大学教授,博士生导师,通信作者, E-mail: suqian@126.com.

随着城市地下空间建设进程的不断推进,地铁线路愈加密集,不断出现超长、超深、超大地铁车站基坑,地铁车站基坑工程正向复杂化的趋势发展。在基坑开挖扰动、周围环境的共同作用下,车站基坑不可避免的出现变形,由于变形过大导致的基坑坍塌、坑底隆起、结构失稳等灾害,将对施工安全造成严重影响。对基坑进行变形预测,掌握基坑结构状态和变形趋势,提前发现基坑安全问题,能够有效降低施工人员风险和经济损失。

基坑变形预测方法可以分为理论分析法、有限元法和人工智能算法。理论分析法是通过分析实际工程中的大量数据,得到土体的本构模型,定性揭示土体的变形机制,为土体的应力、应变计算提供理论依据。文献[1-2]提出的土的渗透固结理论和土体的真三维固结理论都属于经典土力学,2种模型基于弹性力学的分析方法,将土体视为理想弹性体,分开计算土体的强度和变形,与真实值间有较大的偏差^[3]。文献[4]提出的剑桥模型是一种弹塑性本构模型,可以很好地描述土体的塑性阶段变形。然而,在研究深度上,经典的本构模型概念地给出了土体的变形公式,往往只适用于简单工程条件下的基坑预测,面对复杂的土体结构,经典本构模型难以准确描述其变形机制,且求解计算复杂。

有限元法的核心思想是将研究对象离散化,对离散体进行力学性能分析。有限元法能够描述土体的复杂非线性关系,计算精度更高。有限元法^[5-10]能够基于已有的基坑监测数据分析变形规律,但数值分析的结果取决于设置的参数,由于地质条件的复杂性和受施工扰动等因素影响,土体的相关力学参数具有不确定性,这使得有限元法难以真实反映基坑变形情况。随着技术的发展,人工智能算法理论被提出并得到广泛的应用与发展。与传统的理论分析、有限元法相比,人工智能算法在变形预测中有着更优异的表现。

常用的基坑变形智能预测方法有回归分析、灰色理论、时间序列预测、支持向量机、神经网络等^[11-16]。文献[17]对比分析 BP(back propagation)神经网络、K 近邻及支持向量机等算法的预测性能,采用 K 最邻近(K-nearest neighbor, KNN)算法建立地铁深基坑地连墙变形预测模型;文献[18]比较灰色系统、时间序列及其组合模型的变形预测精度;文献[19]将人工蜂群算法用于 BP 神经网络优化,能够更好地寻找网络初始权重;文献[20]针对单步预测模型单次只输出一

期预测值的局限性,研究长短期记忆网络多步预测模型。上述研究均为基坑变形智能预测提供了解决方案,然而受施工振动、现场条件、监测手段等多种条件影响,基坑现场的变形监测数据易出现噪音问题,大部分对基坑的智能预测主要是算法的优化与比选分析,模型没有考虑到随机噪声的影响,限制了变形预测的精度。

本文基于成都某地铁车站基坑工程,依托现场长期的实际监测数据,对基坑的变形进行预测和分析。引入高斯滤波(Gaussian filter, GF)算法,在预测分析之前针对原始数据做出降噪处理,保障数据质量,利用高斯过程回归(Gaussian process regression, GPR)算法实现基坑的变形趋势预测,以解决噪声导致基坑变形预测精度低的问题。

1 GF-GPR 基坑变形预测模型的建立

1.1 GF 算法

GF 是一种线性滤波技术,概率密度函数服从正态分布,可以用于减弱基坑变形数据中的高斯噪声干扰。GF 算法的基本思想为将原始数据与 Gaussian 核函数进行卷积运算,使用数据点邻域的加权平均值来代替该数据点,从而得到降噪后的数据。定义一维高斯函数 $g(t, \sigma)$ 为:

$$g(t, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(t-t_0)^2}{2\sigma^2}\right] \quad (1)$$

其中: t 为基坑变形监测取样点; t_0 为 t 的均值。由于计算时以当前取样点为原点, $t_0=0$ 。

高斯函数的一阶导数 $g^{(1)}(t, \sigma)$ 为:

$$g^{(1)}(t, \sigma) = \frac{-t}{\sqrt{2\pi}\sigma^3} \exp\left(-\frac{t^2}{2\sigma^2}\right) \quad (2)$$

其中, $g^{(1)}(t, \sigma)$ 为高斯滤波器。

基坑位移序列函数 $f(t)$ 降噪后的结果为:

$$S(t, \sigma) = f(t) * g^{(1)}(t, \sigma) \quad (3)$$

其中: $*$ 为卷积运算符; σ 为高斯函数标准方差。 σ 控制着 Gaussian 核函数滤波的平滑程度, σ 越大, Gaussian 核函数局部影响范围越大,信号平滑程度越好; σ 越小,数据的突变信息越被放大。

1.2 GPR 算法

GPR 算法是基于贝叶斯理论和统计学习理论的一种机器学习方法,算法的核心思想是运用 GPR 模型确定多个自变量 x 与因变量 y 之间的映射关系,运用共扼梯度法、牛顿法等优化方法,求出映射关系中超参数的最优解,进而预测基坑变形的概率分布。

1.2.1 GPR 预测

标准回归模型的一般表达式为:

$$y = f(x) + \varepsilon \quad (4)$$

其中: x 为输入变量; $f(x)$ 为函数值; y 为观测值; ε 为高斯噪声, $\varepsilon \sim N(0, \sigma_n^2)$ 。

为求解 $f(x)$ 的先验函数空间,定义一个高斯过程(Gaussian process, GP),也称正态随机过程。GP由独立的、均满足联合高斯分布的随机变量集合组成,即任一组随机变量 $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_i]^T (i=1, 2, \dots, n)$,与其对应的观测值 $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_i]^T (i=1, 2, \dots, n)$ 皆服从 n 维高斯分布。故GP可定义为:

$$f(x) \sim \text{GP}(\mu(\mathbf{x}), \mathbf{C}(\mathbf{x}, \mathbf{x}')) \quad (5)$$

其中: $\mathbf{x}, \mathbf{x}' \in X$ 为任意随机变量; $\mu(\mathbf{x})$ 为均值函数, $\mu(\mathbf{x}) = E[\mathbf{y}(\mathbf{x})]$, $\mu(\mathbf{x})$ 通常取为 $\mathbf{0}$;协方差函数 $\mathbf{C}(\mathbf{x}, \mathbf{x}') = E[(\mathbf{y}(\mathbf{x}) - \mu(\mathbf{x}))(\mathbf{y}(\mathbf{x}') - \mu(\mathbf{x}'))^T]$,协方差函数也被称为核函数,其完全决定了GP的统计性质。联合式(4)、式(5),可得出观测值 \mathbf{y} 的先验分布为:

$$\mathbf{y} \sim N(\mathbf{0}, \mathbf{C}(\mathbf{x}, \mathbf{x}) + \sigma_n^2 \mathbf{I}_n) \quad (6)$$

其中: $\mathbf{C}(\mathbf{x}, \mathbf{x})$ 为 $n \times n$ 阶对称正定协方差矩阵; \mathbf{I}_n 为单位矩阵。观测值 \mathbf{y} 与输出样本 \mathbf{y}^* (预测值)的联合先验分布为:

$$\begin{bmatrix} \mathbf{y} \\ \mathbf{y}^* \end{bmatrix} \sim N \left(\mathbf{0}, \begin{bmatrix} \mathbf{C}(\mathbf{x}, \mathbf{x}) + \sigma_n^2 \mathbf{I}_n & \mathbf{C}(\mathbf{x}, \mathbf{x}^*) \\ \mathbf{C}(\mathbf{x}, \mathbf{x}^*) & \mathbf{C}(\mathbf{x}^*, \mathbf{x}^*) \end{bmatrix} \right) \quad (7)$$

其中: $\mathbf{C}(\mathbf{x}, \mathbf{x}^*)$ 是所有输入变量 \mathbf{x} 与待预测输入变量 \mathbf{x}^* 之间的 $n \times 1$ 的协方差矩阵; $\mathbf{C}(\mathbf{x}^*, \mathbf{x}^*)$ 为待预测输入变量 \mathbf{x}^* 自身的协方差矩阵。将 \mathbf{x}, \mathbf{y} 中元素组成的集合 $D = \{(x_i, y_i) | i=1, 2, \dots, n\}$ 作为GPR模型的训练集,得到 \mathbf{y}^* 的后验分布:

$$p(\mathbf{y}^* | D, \mathbf{x}^*) \sim N(\mu_{\mathbf{y}^*}, \sigma_{\mathbf{y}^*}^2) \quad (8)$$

\mathbf{y}^* 的均值为:

$$\mu_{\mathbf{y}^*} = \mathbf{C}(\mathbf{x}, \mathbf{x}^*) (\mathbf{C}(\mathbf{x}, \mathbf{x}) + \sigma_n^2 \mathbf{I}_n)^{-1} \mathbf{y} \quad (9)$$

\mathbf{y}^* 的方差为:

$$\sigma_{\mathbf{y}^*}^2 = \mathbf{C}(\mathbf{x}^*, \mathbf{x}^*) - \mathbf{C}(\mathbf{x}^*, \mathbf{x}) [\mathbf{C}(\mathbf{x}, \mathbf{x}) + \sigma_n^2 \mathbf{I}_n]^{-1} \mathbf{C}(\mathbf{x}, \mathbf{x}^*)^T \quad (10)$$

1.2.2 GPR 训练

\mathbf{y}^* 的协方差函数度量了预测结果的可信区间,其决定了GPR模型的预测性能。GP的协方差函数为对称正定函数,满足Mercer定理条件,可以将协方差函数等价于核函数,从而将非线性的数据映射到特征空间转换为线性关系。本文使用的协方差函数为平方指数协方差函数,其形式为:

$$C_{SE}(x_i, x_j) = \sigma_l^2 \exp[-r^2 / (2l^2)] + \sigma_n^2 \delta_{ij} \quad (11)$$

其中: σ_l^2 为信号方差,用于控制输出值局部波动的程度; l 为方差尺度,表示输入值与输出值之间

的相关性大小; $r^2 = \sum_{k=1}^n (x_{i,k} - x_{j,k})^2$, $x_{i,k}, x_{j,k} \in X$ 为任意随机变量,表示输入值局部的波动程度; σ_n^2 为噪声方差; δ_{ij} 为克洛内克尔函数。令 $\theta = \{l, \sigma_l^2, \sigma_n^2\}$ 为包含所有超参数的量,采用共轭梯度法取训练集的极大似然估计值,求得最优超参数 θ 。

$$L(\theta) = -\ln p(\mathbf{y} | \mathbf{x}, \theta) =$$

$$\mathbf{y}^T \mathbf{C}^{-1} \mathbf{y} / 2 + (\ln |\mathbf{C}|) / 2 + (n \ln 2\pi) / 2 \quad (12)$$

$$\frac{\partial L(\theta)}{\partial \theta_i} = \frac{1}{2} \text{tr} \left[(\boldsymbol{\alpha} \boldsymbol{\alpha}^T - \mathbf{C}^{-1}) \frac{\partial \mathbf{C}}{\partial \theta_i} \right] \quad (13)$$

其中: $\mathbf{C} = \mathbf{C}_n + \sigma_n^2 \mathbf{I}_n$; $\boldsymbol{\alpha} = (\mathbf{C}_n + \sigma_n^2 \mathbf{I}_n)^{-1} \mathbf{y} = \mathbf{C}^{-1} \mathbf{y}$ 。

求解超参数的过程即为GPR训练,当训练完成后,应用式(9)、式(10)可求得与 \mathbf{x}^* 对应的预测值 \mathbf{y}^* 的均值和方差。

1.3 GF-GPR 基坑变形预测模型

本文所构建的GF-GPR基坑变形预测模型建立过程描述如下。

1) 采用GF算法对数据集进行降噪处理,GF算法降噪的核心在于确定高斯核函数 $w_k(x+i, \sigma)$ 的权重矩阵。首先定义基坑位移序列函数 $f(x)$ 的滤波窗口长度 $(2L+1)$ 、迭代次数 K 和标准方差 σ 。计算以取样点为中心,Gaussian核函数影响半径为 L 的权重矩阵,对权重矩阵进行归一化,令权重总和等于1,得到最终的权重矩阵,将权重矩阵与原始监测数据对应点相乘后累加,计算出基坑位移序列函数 $f(x)$ 滤波后的输出值 $f_{k+1}(x)$,其计算公式为:

$$f_{k+1}(x) = \sum_{i=-L}^L f_k(x+i) w_k(x+i, \sigma) \quad (14)$$

重复步骤1),直至迭代次数 $k=K$,得到GF算法降噪后的基坑监测位移序列。

2) 使用信噪比(signal-to-noise ratio, SNR)与均方误差(mean square error, MSE)作为降噪性能评价指标,选出最优的降噪数据。SNR、MSE计算公式分别为:

$$R_{\text{SNR}} = 10 \lg \left[\frac{\sum_{i=1}^N x_i^2}{\sum_{i=1}^N (d_i - x_i)^2} \right] \quad (15)$$

$$E_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (d_i - x_i)^2 \quad (16)$$

其中: x 为初始基坑位移数据序列; d_i 为降噪后的基坑位移序列; N 为基坑位移序列长度。若降噪数据SNR越大、MSE越小,表明降噪效果越好。选取降噪效果最优的数据进行后续处理。

3) 采用GPR算法预测基坑的变形。按比例将监测数据集划分为70%训练集和30%测试集,建立GPR模型,定义超参数 $\theta = \{l, \sigma_l^2, \sigma_n^2\}$ 的数

值,使用训练集训练 GPR 模型,求解出超参数的最优值,在测试集上预测样本的均值和方差,完成复杂地铁车站基坑现场的变形预测。

4) 选取平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和拟合优度 R^2 评估降噪精度,公式分别为:

$$E_{MAE} = \left(\sum_{i=1}^N |y_i - \hat{y}_i| \right) / N \quad (17)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (18)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (19)$$

其中: N 为预测样本数; y_i 为实测位移值; \hat{y}_i 为预测位移值; \bar{y} 为实测值位移的平均值。 E_{MAE} 、 E_{RMSE} 的值越小,预测误差越小。 R^2 值越大,表明模型精度越高。

2 工程实例验证

2.1 工程概况

成都某地铁车站全长 729 m,开挖基坑深度为 25.86~28.92 m,基坑开挖深度深。车站采用明挖法施工,基坑外围支护形式为围护桩,采用“三道水平混凝土钢管内支撑+钢格构立柱”作为内支撑体系。车站基坑周边存在的众多邻近建筑物和地下管线影响车站结构施工。

2.2 水文地质

该车站所在区域为岷江水系冲积平原三级阶地,车站施工场地范围地势较平坦。勘测结果表明,车站场地范围内的地层主要为人工杂填土、含黏土卵石、风化泥岩、砂岩,车站地质剖面图如图 1 所示。




图 1 车站地质剖面图

基坑施工范围内的人工填土层和风化泥岩层遇水软化、崩解从而其,强度急剧降低,易导致场地地面沉降,为不良地质层。车站范围内地下水位较高,基坑局部地段有富水条件。

综上可知,该地铁车站基坑工程的施工环境复杂,技术难度大。

2.3 传感器布设和监测数据分析

围护结构的水平位移是能较好反映基坑本身及周边环境稳定状况的重要物理量,本文着重对该监测项进行分析,整个车站共布设 73 个水平位移监测点,监测频率为 1 次/d,共监测 160 d,监测点布设在基坑各边中间部位、阳角部位,每个监测点间距为 20 m,测点布设在围护结构顶部冠梁上。由于监测点位多,选取其中 4 个监测点(ZQS27、ZQS30、ZQS32、ZQS34)进行变形分析,各监测点的布设位置如图 2 所示。部分水平位移监测点数据见表 1 所列。




图 2 围护结构水平位移监测点布置图

表 1 围护结构水平位移监测点数据

天数/d	监测点位移/mm			
	ZQS27	ZQS30	ZQS32	ZQS34
1	0.1	0.1	0.3	-0.2
2	-0.7	0.1	-0.6	0.8
3	-0.7	-0.7	-0.2	-0.9
⋮	⋮	⋮	⋮	⋮
158	5.0	4.91	1.7	8.8
159	6.0	3.91	3.3	9.4
160	5.8	5.21	3.3	9.4

2.4 结果分析

2.4.1 数据预处理结果

使用 Python 编程语言,基于机器学习中的 sklearn 库构建 GF 算法,对监测数据进行降噪,获取真实的变形信息。当高斯函数的标准方差 σ 取 2 时,降噪结果符合实际趋势,结果见表 2 所列。其中,降噪后 SNR 为 12.884~17.139, MSE 为 0.430~0.875 mm。

表 2 降噪性能评估结果

监测点	SNR	MSE/mm
ZQS27	14.906	0.875
ZQS30	15.210	0.444
ZQS32	12.884	0.430
ZQS34	17.139	0.742

GF 算法降噪前、后位移对比如图 3 所示。




图 3 不同监测点 GF 算法降噪前、后位移对比

由图 3 可知:在降噪前,监测数据存在大量噪声,变形数据连续性差,呈现非线性和非平稳性;经过降噪后,变形时间序列变得平稳,施工扰动噪声得到有效抑制;同时,GF 算法在降噪后仍保留

了数据中的有用突变信息,降噪后的整体变形趋势与降噪前一致,且无相位偏移。

2.4.2 变形预测结果

采用 tensorflow 深度学习框架搭建变形预测模型。以基坑水平位移监测数据为数据集,将数据集按 7 : 3 的比例划分为训练集和测试集,即将前 112 d 的监测数据作为已知数据训练 GPR 算法,并预测后 48 d 的数据变形值。GPR 算法训练中核函数的长度尺度设为 1.8,周期设为 9,长度尺度范围设为(0,100),周期范围设为(0,100),噪声设为 0.3。算法训练完成之后,代入测试集中的数据,得到的预测结果如图 4 所示。

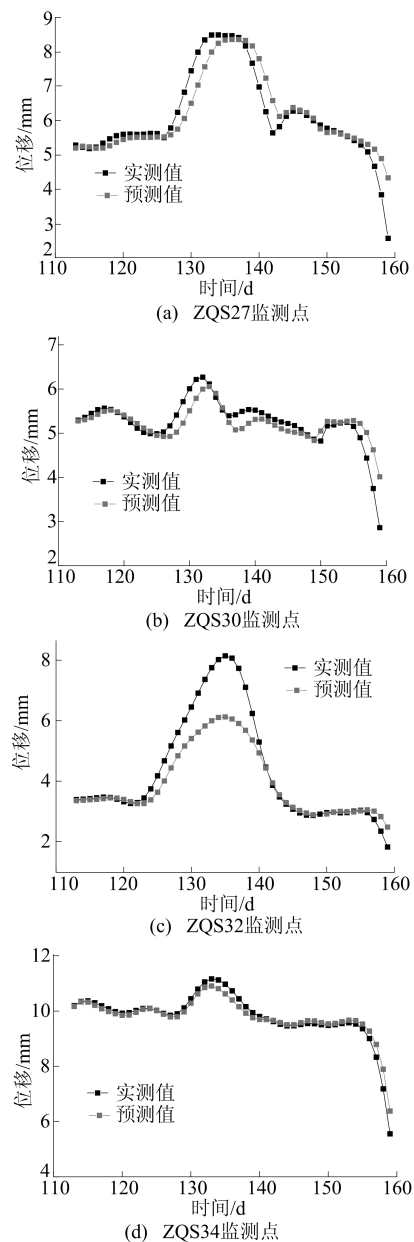


图 4 GF-GPR 模型变形预测结果

由图 4 可知,GPR 模型在测试集上的预测变

形趋势与实际相似,变形值与监测值间偏差小,对于 ZQS32 测点,在变形数据较大处预测值与监测值有一定偏差。


各测点预测结果的预测精度值见表 3 所列。由表 3 可知,经过 GF 算法降噪处理后的 GPR 模型对基坑水平位移变化的预测精度较高,拟合优度 R^2 达到了 0.915 5~0.978 2,最大 MAE 为 0.248 8 mm,最大 RMSE 为 0.188 7 mm。

表 3 预测精度结果


监测点	R^2	MAE/mm	RMSE/mm
ZQS27	0.915 5	0.245 2	0.126 5
ZQS30	0.978 2	0.058 4	0.000 7
ZQS32	0.941 3	0.248 8	0.188 7
ZQS34	0.941 8	0.149 4	0.049 4

3 讨 论


本研究为验证所提出的 GF 算法对模型预测精度的优化效果,仅使用 GPR 模型预测未经降噪的监测数据集,GPR 模型核函数的参数设置不变,所得到的预测结果如图 5 所示。




(a) ZQS27监测点



(b) ZQS30监测点



(c) ZQS32监测点



(d) ZQS34监测点

图 5 GPR 模型变形预测结果

由图 5 可知,GPR 模型的预测值与实际有较大误差,变形预测的整体相关性不高,对于 ZQS32 监测点,在第 11~第 33 天出现了与实测值相反的预测结果。

GF-GPR 模型和 GPR 模型的变形预测精度对比见表 4 所列。由表 4 可知:使用未经处理的数据,预测的拟合优度 R^2 最高为 0.628 8,最小 MAE 为 0.706 2 mm,最小 RMSE 为 0.625 4 mm;GF-GPR 模型将预测的精度由 0.164 1~0.628 8 提高到 0.915 5~0.978 2(提高 31%~81%),最大 RMSE 也由 0.625 4~1.414 6 mm 减小到了 0.007 0~0.188 7 mm(降低了 0.436 7~1.288 1 mm)。因此,在 GPR 模型中引入 GF 算法,对于提高预测精度是有效的。

表 4 降噪前、后模型预测结果精度评估对比

监测点	模型	R^2	MAE/mm	RMSE/mm
ZQS27	GPR	0.493 8	0.891 8	1.414 6
	GF-GPR	0.915 5	0.245 2	0.126 5
ZQS30	GPR	0.164 1	0.755 6	0.880 8
	GF-GPR	0.978 2	0.058 4	0.007 0
ZQS32	GPR	0.628 8	0.782 6	0.625 4
	GF-GPR	0.941 3	0.248 8	0.188 7
ZQS34	GPR	0.280 4	0.706 2	0.939 2
	GF-GPR	0.941 8	0.149 4	0.049 4

4 结 论

针对复杂地铁车站基坑开挖过程中变形监测数据受噪声影响,导致基坑变形预测精度受到限制的问题,本文构建了一种基于 GF-GPR 的基坑变形预测模型。首先,使用 GF 算法对监测数据进行降噪处理,然后采用 GPR 算法实现基坑的变形预测,最后依托成都某车站地铁基坑工程实例,开展实例验证,得出如下结论:

1) 由于施工、降雨、地下水位变化、地质条件不良、临近建筑物等因素的影响,会导致数据出现

突变的异常点,长期来看,变形趋势呈现非线性和非平稳性,难以分析规律。

2) GF算法在对突变处进行平滑处理的同时保留了有效的突变信息,经过降噪后,数据的SNR增加到12.884~17.139,MSE为0.430~0.875 mm。有利于提高GPR算法对基坑变形预测的准确性。

3) 除在较大的变形突变处,GF-GPR基坑变形预测模型的预测结果与实际位移在趋势和数值上都基本一致,说明GF-GPR预测模型有较高的预测精度,符合基坑变形客观规律。

4) 与单一GPR基坑变形预测模型相比,所构建的GF-GPR基坑变形预测模型有更高模型精度和更小误差,预测精度由0.164 1~0.628 8提高到0.915 5~0.978 2(提高31%~81%),最大均方根误差也由0.625 4~1.414 6 mm减小到了0.007 0~0.188 7 mm(降低了0.436 7~1.288 1 mm),表明使用GF-GPR预测模型预测复杂车站基坑位移的优越性。

[参 考 文 献]

- [1] TERZAGHI K. Principles of soil mechanics. IV Settlement and consolidation of clay[J]. Engineering News Record, 1925,95:874.
- [2] BIOT M A. General theory of three-dimensional consolidation[J]. Journal of Applied Physics, 1941,12(2):155-164.
- [3] 陈云敏,马鹏程,唐耀. 土体的本构模型和超重力物理模拟[J]. 力学学报, 2020,52(4):901-915.
- [4] ROSCOE K H, SCHOFIELD A N, THURAIRAJAH A. Yielding of clays in states wetter than critical[J]. Geotechnique, 1963,13(3):211-240.
- [5] 黄莺,方中义,李学聪,等. 上软下硬地层深基坑结构变形监测及分析[J]. 中国安全生产科学技术, 2022, 18(9): 203-209.
- [6] 秦胜伍,苗强,张领帅,等. 基坑开挖与支撑拆除对周围环境影响的研究[J]. 工程地质学报, 2020,28(5):1106-1115.
- [7] 李兵,刘阳,李卓伦,等. 锚杆参数对深基坑变形影响的有限元分析[J]. 沈阳建筑大学学报(自然科学版), 2020,36(3): 404-411.
- [8] WU B, PENG Y, MENG G, et al. Empirical method and finite element analysis of deep foundation pit excavation in Ningbo soft soil[J]. IOP Conference Series (Earth and Environmental Science), 2019,267(3):32-60.
- [9] 甄文战. 基于UH本构模型的软土深基坑数值分析[J]. 土工基础, 2012,26(1):33-36.
- [10] 张福海,周玉石,刘学港,等. 基于斜桩支护的框架结构基坑变形分析[J]. 山东大学学报(工学版), 2022, 52(1): 58-65.
- [11] 薛艳杰. 基于机器学习算法的土岩复合地层深基坑变形时序预测[J]. 现代隧道技术, 2022,59(增刊2):77-85.
- [12] 陈伟航,罗强,王腾飞,等. 基于Bi-LSTM的非等时距路基后沉降滚动预测[J]. 浙江大学学报(工学版), 2022,56(4): 683-691.
- [13] 陈华. 基坑变形预测及优化研究[J]. 公路, 2020, 65(8): 414-418.
- [14] 李成龙,李敬伟,王磊. 深基坑开挖中KPCA结合BP神经网络的基坑变形预测[J]. 湘潭大学自然科学学报, 2017, 39(4):60-63.
- [15] 周有荣,王凯. 改进WOA-指数幂乘积模型在基坑变形预测中的应用[J]. 水资源与水工程学报, 2020, 31(3): 233-239.
- [16] 张朋博. 指数平滑模型在深基坑变形预测中的应用[J]. 测绘技术装备, 2020,22(4):43-46.
- [17] 张雯超,史培新,刘维,等. 基于改进KNN与基坑参数对地连墙变形预测研究[J]. 华中科技大学学报(自然科学版), 2021,49(9):101-106.
- [18] 王林林. 灰色时序模型在变形监测中的应用[J]. 大坝与安全, 2021(4):67-70.
- [19] FENG T, WANG C, ZHANG J, et al. Prediction of stratum deformation during the excavation of a foundation pit in composite formation based on the artificial bee colony: back-propagation model [J]. Engineering Optimization, 2022,54(7):1217-1235.
- [20] 刘俊城,谭勇,张生杰. 地铁车站深基坑开挖变形智能多步预测方法[J]. 上海交通大学学报, 2024,58(7):1108-1117.

(责任编辑 吴亮)