

DOI: 10.11779/CJGE202105004

山岭隧道洞口段地表沉降时序预测研究

王述红, 朱宝强*

(东北大学资源与土木工程学院, 辽宁 沈阳 110819)

摘 要: 地表沉降监测值具有复杂性及非线性动态变化特征, 以往静态模型预测时常存在易受历史监测数据干扰且模型输入权值及阈值选择较为困难的问题, 鉴于此, 提出一种洞口段地表沉降动态预测方法。利用 3 次样条函数插值法将监测数据等距化, 并结合时序分析理论和变分模态分解 (VMD), 将地表沉降分解为趋势项和随机项位移; 通过采用灰狼优化算法 (GWO) 对在线贯序极限学习机模型 (OSELM) 的权值及阈值进行优化, 建立了 GWO-OSELM 动态预测模型, 分别对位移分量进行预测; 以重庆市兴隆隧道洞口段为例, 利用该模型进行预测, 并与传统模型进行对比, 最后探讨了激励函数的选择对模型预测性能的影响及随机项位移的部分影响因素。结果表明: 非等距时序数据预处理后, 模型能够有效地对位移分量进行预测, 预测精度高、误差小, 且 Sigmoid 激励函数更适合该模型, 而地表沉降速率和拱顶下沉速率对随机项位移有重要影响。可为山岭隧道洞口段地表沉降的长期预测提供一种新的思路和方法。

关键词: 山岭隧道; 地表沉降; 非等距时间序列; 变分模态分解; 灰狼优化; 在线贯序极限学习机

中图分类号: U459.2 文献标识码: A 文章编号: 1000-4548(2021)05-0813-09

作者简介: 王述红(1969—), 男, 教授, 博士生导师, 主要从事岩土工程相关的教学和科研工作。E-mail: shwangneu@126.com。

Time series prediction for ground settlement in portal section of mountain tunnels

WANG Shu-hong, ZHU Bao-qiang

(School of Resource and Civil Engineering, Northeastern University, Shenyang 110819, China)

Abstract: The monitoring value of ground settlement is characterized by complexity and nonlinear dynamic change. Aiming at the problems that the previous static models are easily disturbed by historical monitoring data and the model input weights and thresholds are more difficult to choose, a dynamic prediction method for ground settlement of the portal section of tunnels is proposed. The ground settlement is equidistant by the cubic-spline function interpolation method and decomposed into the trend and random term displacement by the time series analysis theory and the variational mode decomposition (VMD). By using the grey wolf optimizer (GWO) to optimize the weights and thresholds of the online sequential extreme learning machine (OSELM), the GWO-OSELM dynamic prediction model is established to predict the displacement components separately. Taking the portal section of Xinglong tunnel in Chongqing as an example, the proposed model is compared with the traditional model. Finally, the influences of the choice of activation function on the prediction performance of the model and some factors influencing the random term displacement are analyzed. The results show that the model can effectively predict the displacement components after the preprocessing of non-equidistant time series data, and it has high prediction accuracy and small prediction error. Moreover, the Sigmoid activation function is more suitable for the model, and the rates of the ground settlement and the vault subsidence have important influences on the random term displacement. The model provides a new way of thinking and a method for the long-term prediction of ground settlement in the portal section of mountain tunnels.

Key words: mountain tunnel; ground settlement; non-equidistant time series; variational mode decomposition; grey wolf optimizer; online sequential extreme learning machine

0 引 言

山岭隧道的洞口段作为隧道施工的“咽喉”, 常常分布着节理裂隙较发育的严重风化岩体, 施工中极易出现围岩失稳坍塌、地表塌陷等工程灾害^[1-2]。鉴于位移和变形是反映工程安全控制最核心的元素, 因此, 对洞口段地表沉降进行预测研究, 对于保障隧道进洞

安全及塌方灾害防治具有重要现实意义。

近年来, 计算机和人工智能技术飞速发展, 智能

基金项目: 国家自然科学基金项目 (U1602232); 中央高校基本科研业务费专项资金项目 (N170108029); 辽宁省重点研发计划 (2019JH2/10100035); 东北大学双一流建设项目 (2018)

收稿日期: 2020-06-10

*通信作者 (E-mail: zzbq2289675237@163.com)

预测方法在路基沉降^[3-4]和滑坡位移^[5-6]预测中已有较多研究。而对于地表沉降的预测研究相对较少,主要采用的方法有神经网络模型^[7-8]、贝叶斯模型^[9]、粒子群-最大似然模型^[10]等。显然,对地表沉降的预测主要集中在地铁盾构隧道领域,而对山岭隧道洞口段地表沉降的预测缺乏深入研究。虽然上述智能预测方法有了一些应用,但仍存在某些方面的不足:①地表沉降监测值多为非线性和非等距时序数据,由于其复杂性,此时直接基于实测值的预测不易得到良好的结果;②预测模型(如 SVM、ELM 等)多为“静态”模型,只能学习并使用当前时刻的监测值,并且是一次性学习全部训练数据,以至于不能很好地反映地表沉降的长期变化趋势;③智能优化算法易陷入局部极小值,模型泛化能力变差,且“过拟合”现象较为严重,从而导致预测结果出现较大误差。

综上,本文结合非等距时序分析理论,并引入一种新的位移分解方法——变分模态分解(variational mode decomposition, VMD)^[11],对沉降实测值进行分解,然后采用具有动态预测能力的在线贯序极限学习机(online sequential extreme learning machine, OSELM)^[12]分别预测,针对模型存在的输入权值及隐含层阈值确定较为困难的缺陷,引入一种新型的元启发式智能优化算法——灰狼优化算法(grey wolf optimizer, GWO)^[13]对模型进行优化。将优化后的模型应用于重庆市兴隆隧道洞口段实测地表沉降预测中,并进行对比分析,进一步验证所提模型的合理性和实用性。

1 地表沉降时序预测模型

1.1 监测数据预处理

根据《公路隧道施工技术规范》^[14],当隧道埋深小于 2 倍的洞室开挖宽度时,地表沉降的量测是十分重要的,其量测频率见表 1。因此,现场实测值往往是非等间距的,不利于时序分析原理的应用,这就需要采用数学手段将其转换为等间距时序数据。3 次样条函数插值法作为一种应用十分广泛的插值方法,将其应用于地表沉降监测值的等距处理中,可得到较为连续光滑的曲线,并且能够最大程度的保留原始数据的变化趋势。

表 1 地表沉降量测频率

Table 1 Measurement frequencies of ground settlement		
量测项目	d	量测频率
地表沉降	$d < 2B$	(1~2 次) / d
	$2b < d < 5B$	1 次 / (2~3 d)
	$d > 5B$	1 次 / 7 d

注: d 为开挖断面距量测断面的距离, B 为隧道开挖宽度。

现有研究表明,地表沉降是受基础地质条件(如地形地貌和岩性等)和外部因素(如降雨、风荷载、测量条件等)等共同作用形成的^[15]。在前者作用下表现为随时间变化的趋势项位移,反映变形的主要规律,为非平稳序列;在后者作用下则表现为随机变化的随机项位移,为平稳噪声序列,该序列的存在会降低预测真实性及精度。基于此,为了更好的反映各位移分量变化情况,利用时间序列原理,对地表沉降进行分解,

$$s(t) = \alpha(t) + \beta(t) \quad (1)$$

式中, $s(t)$ 为隧道地表沉降总位移, $\alpha(t)$ 为趋势项位移, $\beta(t)$ 为随机项位移。

目前较为典型的位移序列分解方法主要有 EMD^[16]和 EEMD^[17]等,他们各有优缺点。本文尝试引入一种新的分解方法——变分模态分解^[11],该方法理论基础完善,能根据位移序列自身特征尺度将其转化为非递归 VMD 模式,分解所得各位移分量均具有明确物理意义,可有效克服传统 EMD 和 EEMD 存在的模态混叠问题。

实现 VMD 的核心是构造和求解变分问题。

(1) 构造变分问题。假设原始位移序列 $s(t)$ 经分解后得到了 K 个分量, VMD 通过在变分框架内寻找模型的最优解来实现位移的分解,其变分约束表达式为

$$\min_{\{\delta_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[(\mu(t) + \frac{i}{\pi n}) * \delta_k(t) \right] e^{-i\omega_k t} \right\|_2^2 \right\} \quad (2)$$

$$\text{s.t.} \quad \sum_k \delta_k = s(t) \quad (3)$$

式中, K 为分解所得的模态个数(正整数), $\{\delta_k\}$, $\{\omega_k\}$ 分别为分解后的第 K 个模态分量及对应中心频率, $\mu(t)$ 为狄拉克函数, $*$ 为卷积运算符。

(2) 求解变分问题。引入 Lagrange 乘法算子,将上式转变为非约束变分问题,得到增广 Lagrange 表达式为

$$L(\{\delta_k\}, \{\omega_k\}, \lambda) = \sigma \sum_k \left\| \partial_t \left[(\mu(t) + i/\pi t) * \delta_k(t) \right] e^{-i\omega_k t} \right\|_2^2 + \left\| s(t) - \sum_k \delta_k(t) \right\|_2^2 + \left\langle \lambda(t), s(t) - \sum_k \delta_k(t) \right\rangle \quad (4)$$

式中, σ 为二次惩罚因子。

利用交替方向乘子法将上述问题转化为寻找增广 Lagrange 方程的“鞍点”问题,也即最优解,限于篇幅,具体过程见文献[18]。本文将其引入地表沉降分解中,得到不同特征尺度的位移分量,更能反映其自身信息。

1.2 地表沉降动态预测的 GWO-OSELM 模型

(1) 在线贯序极限学习机模型

传统神经网络模型(如 SVM、ELM 等)多为“静

态”的, 预测时只能学习并使用当前时刻监测值, 并且一次性学习全部训练数据, 而地表沉降监测值往往是非线性动态变化的, 并且彼此之间存在一定联系。鉴于此, 将具有在线学习机制的 OSELM 模型^[12]引入地表沉降预测中, 它是对传统 ELM 模型的改进, 能够逐批学习监测值并根据最新监测值不断更新网络, 实现动态预测。

OSELM 模型主要通过利用递推计算对 ELM 模型的输出层权值 $\hat{\beta}$ 进行更新, 主要包括两部分。

a) 初始化阶段

给定激励函数 $g(x)$, 隐含层节点数 n , 以及初始训练子集 $\psi_0 = \{(x_i, y_i) | i = 1, 2, \dots, N_0\}$, 并且 $N_0 \geq n$, 则初始隐含层输出权值可由下式求得,

$$\beta_0 = P_0 H_0^T T_0 \quad (5)$$

式中, $P_0 = (H_0^T H_0)^{-1}$, $T_0 = [y_1 \ y_2 \ \dots \ y_{N_0}]^T$, H_0 为隐含层初始输出矩阵。

b) 在线学习阶段

令 $m=0$, m 为加入训练数据的批次, 对 $m+1$ 批数据, 计算其隐层输出矩阵 H_{m+1} , 并按下式更新隐层输出权值:

$$P_{m+1} = P_m - \frac{P_m h_{m+1}^T h_{m+1} P_m}{1 + h_{m+1}^T P_m h_{m+1}} \quad (6)$$

$$\beta_{m+1} = \beta_m + P_{m+1} H_{m+1}^T (T_{m+1}^T - H_{m+1} \beta_m) \quad (7)$$

式中, $h_m = [G(a_1, b_1, x_m) \ \dots \ G(a_n, b_n, x_m)]$, $G(a_n, b_n, x_m) = g_n(x_m)$, a_n, b_n 分别是第 n 个隐层节点的输入权值和阈值。

(2) 灰狼优化算法

GWO 由澳大利亚学者 Mirjalili 等^[13]在 2014 年首次提出, 它模拟了自然界中灰狼种群的社会等级制度和群体狩猎行为, 灰狼群体按社会等级制度高低依次分为 α 狼、 β 狼、 γ 狼和 ω 狼, 其群体狩猎行为如下:

Step 1 狼群跟踪并接近猎物。按下式计算距离:

$$D = |C \cdot X_p(u) - X(u)| \quad (8)$$

$$C = 2 \times r_1 \quad (9)$$

式中, D 为灰狼与猎物间的距离, u 为当前迭代次数, $X_p(u)$ 为第 u 代猎物位置向量, $X(u)$ 为第 u 代灰狼个体位置向量, C 为系数向量, r_1 为 $[0,1]$ 间均匀分布的随机向量。

Step 2 狼群追捕并包围猎物。按下式更新位置:

$$X(u+1) = X_p(u) - \eta \cdot D \quad (10)$$

$$\eta = 2b \times r_2 - b \quad (11)$$

式中, η 为系数向量, r_2 为 b 的随机向量, b 的初始值为 2, 随最大迭代次数增加而线性递减至 0。

Step 3 狼群攻击并捕杀猎物。依据狼群中 α 狼寻找猎物方向, 按下式计算 ω 狼与各等级狼的距离:

$$D_l = |C_j \cdot X_l(u) - X(u)| \quad (12)$$

$$X_j = X_l(u) - \eta_j \cdot D_l \quad (13)$$

$$X(u+1) = \frac{X_1 + X_2 + X_3}{3} \quad (14)$$

式中 $l = \alpha, \beta, \gamma; j = 1, 2, 3$ 。

(3) GWO-OSELM 模型动态预测流程

虽然 OSELM 模型存在诸多优点, 但它同样是通过随机产生输入权值及隐层阈值来进行计算, 存在诸多缺点, 故引入 GWO 算法对其输入权值及隐层阈值进行优化, 以提高模型预测精度, 并改善模型泛化能力。如图 1 所示, 基于前述原理建立了该模型, 具体步骤如下:

a) 判断洞口段地表沉降监测值是否等距, 若是, 则利用 VMD 将其分解为趋势项及随机项, 若否, 则先利用 3 次样条插值将其转化为等距后再进行分解。

b) 为便于后续进行最优权值及阈值的搜寻及消除数据量纲的影响, 使算法更容易收敛, 分别对分解得到的时序数据进行归一化操作, 使其位于 $[-1, 1]$ 。

c) 初始化算法相关参数, 主要包括狼群数量、最大迭代次数、搜索变量最大值及最小值、狼群个体初始位置及初始目标函数值。

d) 以模型测试集预测的均方根误差作为个体适应度计算值, 将适应度最优的个体依次作为 α 狼、 β 狼和 γ 狼, 然后更新狼群位置, 并更新 α 狼、 β 狼和 γ 狼。

e) 判断是否达到最大迭代次数, 若否, 则继续执行步骤 d), 若是, 则输出 OSELM 最优权值及阈值。

f) 将结果用于模型训练和预测中, 得位移分量预测结果, 由时间序列原理叠加得到地表沉降总预测值。

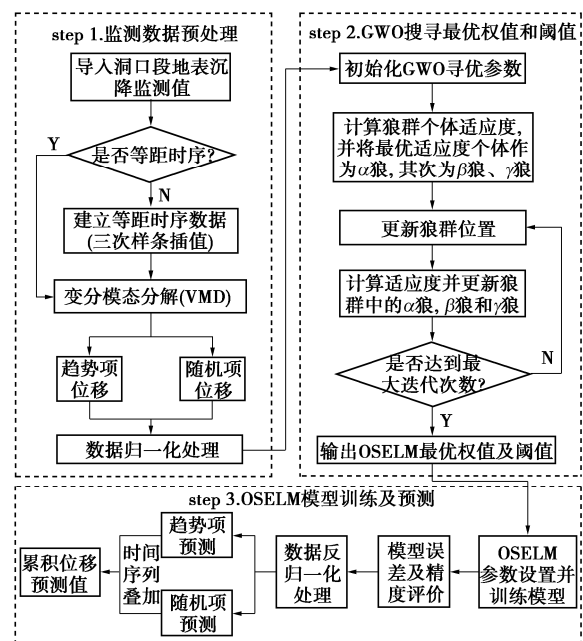


图 1 GWO-OSELM 动态预测流程

Fig. 1 Flow chart of dynamic prediction of GWO-OSELM

1.3 模型预测结果评价指标

相关性系数 R 、均方根误差 R_{MSE} 、平均绝对误差 M_{AE} 3 项指标常用来衡量位移预测精度^[17]。因此，本文采用它们来评价模型预测效果，

$$R = \frac{\sum_{j=1}^N (d_j - \bar{d})(\hat{d}_j - \bar{\hat{d}})}{\sqrt{\sum_{j=1}^N (d_j - \bar{d})^2 (\hat{d}_j - \bar{\hat{d}})^2}} \quad (15)$$

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{j=1}^N (\hat{d}_j - d_j)^2} \quad (16)$$

$$M_{AE} = \frac{1}{N} \sum_{j=1}^N |\hat{d}_j - d_j| \quad (17)$$

式中， d_j 为沉降监测数据， \hat{d}_j 为沉降预测数据， \bar{d} 为沉降监测值均值， $\bar{\hat{d}}$ 为沉降预测值均值，3 项指标均为相对越小时预测结果越好。

2 工程实例分析

2.1 工程概况

在建的兴隆隧道位于重庆市渝北区木耳镇，隧道左线全长 2553 m，右线全长 2539 m。前期地勘结果表明，隧址区域地质较稳定，总体呈单斜构造，主要穿越侏罗系中统上沙溪庙组地层。隧道出洞口段地形较平缓，缓坡主要分布第四系残坡积层粉质黏土，下伏基岩主要为泥岩和砂岩（图 2），岩体较破碎，洞口段山体覆盖层较薄，围岩自稳能力差。因此，施工过程中及时预测地表沉降变化，对于分析隧道进洞稳定性、保障施工安全及塌方灾害防治具有重要意义。




图 2 洞口段地质情况

Fig. 2 Geological conditions of portal section of tunnel

本文以隧道左线出口段 ZK38+020 和 ZK38+015 断面地表沉降实测值为研究对象，隧道采用三台阶法施工，初期支护为钢拱架+系统锚杆+27 cm 厚喷射混凝土，监测断面平面位置见图 3，沿隧道横断面每隔 2~5 m 布置监测点位置见图 4，选择距隧道拱顶最近的 D1-4，D1-5 监测点前 50 d 沉降实测值进行分析。

2.2 洞口段监测数据预处理

将监测数据分为 2 组，第一组为 ZK38+020 断面 D1-4，D1-5 监测点，第二组为 ZK38+015 断面 D1-4，

D1-5 监测点，以进一步验证模型的合理性。实际预测时，以前 36 d 的监测值为训练集，后 14 d 监测值为测试集，利用前 4 d 的监测值依次预测后 1 d 的监测值。

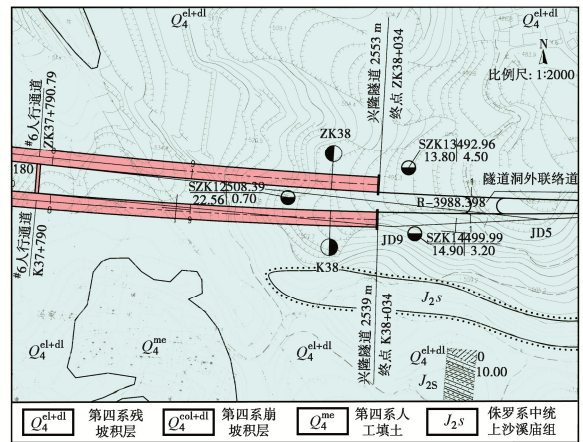


图 3 监测点位置平面图

Fig. 3 Location plan of monitoring arrangement




图 4 监测点位置横断面图

Fig. 4 Cross section of monitoring points

研究区段地表沉降监测值为非等距时序数据，因此利用前述原理对监测数据进行等距处理，将其转化为间距均为 1 d 的等距时序数据（图 5）。在此基础上，利用前述时间序列分析及 VMD 分解原理对地表沉降总位移进行分解，首先设定模态数 $K=2$ ，以位移分解残余项（即趋势项位移）的分解效果为目标，经多次试算后确定二次惩罚因子 $\sigma=2400$ ，上升步长 $\tau=0.03$ 。各监测点沉降监测值分解结果如图 6 所示。




图 5 非等距时序数据的等距化

Fig. 5 Equidistance of non-equidistant time series data

2.3 模型预测结果及分析

GWO-OSELM 在传统 ELM 基础上引入了“时间”概念，通过不断更新网络输出权值及阈值，实现动态预




图 6 地表沉降数据时序分解

Fig. 6 Time series decomposition of ground settlement data

测。本文进行预测时, 设定算法参数为: 狼群数量 10 只, 最大迭代次数 300 次, 搜索变量上下限分别为 1 和 0; 经多次试算后确定隐层神经元个数为 10, 激励函数为“Sigmoid”, 初始训练样本集为 15, 每次学习 3 个数据。各位移分量及累计位移预测结果分析如下:

(1) 趋势项位移预测及分析

分别采用本文模型及 OSELM 模型和传统的 ELM 模型对各监测点的地表沉降趋势项进行预测, 预测结果

见图 7, ZK38+020 断面及 ZK38+015 断面 D1-4, D1-5 监测点趋势项的预测精度及误差分别见表 2, 3。

由图 7 中的结果对比可知, 在测试集的预测中, 具有动态预测能力的 GWO-OSELM 模型及 OSELM 模型的预测效果要明显优于传统的“静态”ELM 模型, 这主要是由于前者具有在线学习能力, 能够逐批学习监测数据, 并不断的更新网络, 而引入 GWO 后的 OSELM 模型预测结果也要优于传统 OSELM 模型, 原因主要是灰狼算法具有较强的寻优能力, 能够得到更为准确的模型输入权值及阈值, 相较于传统模型而言, 优势更加明显。

再结合表 2, 3 进一步分析, 以 ZK38+020 断面 D1-5 监测点测试集预测为例, R 达到了 0.9998, R_{MSE} 为 0.0051 mm, M_{AE} 为 0.0044 mm, 3 项误差指标计算结果均以本文模型更优, 这也进一步验证了模型用于趋势项位移预测的可靠性, 能得到较为满意的预测结果。

(2) 随机项位移预测及分析

与趋势项位移相比, 随机项位移表现出了一定程度




图 7 趋势项位移预测结果

Fig. 7 Prediction results of trend terms displacement

表 2 ZK38+020 趋势项位移预测精度及误差

Table 2 Prediction accuracies and errors of trend term displacement of ZK38+020

模型	R				R_{MSE}/mm				M_{AE}/mm			
	D1-4		D1-5		D1-4		D1-5		D1-4		D1-5	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GWO-OSELM	0.9999	0.9994	0.9999	0.9998	0.0089	0.0106	0.0127	0.0051	0.0077	0.0088	0.0105	0.0044
OSELM	0.9998	0.9996	0.9998	0.9998	0.0484	0.1889	0.0566	0.2349	0.0401	0.1803	0.0506	0.2282
ELM	0.9998	0.9989	0.9996	0.9997	0.0668	0.3581	0.0881	0.4870	0.0553	0.3392	0.0725	0.4724

表 3 ZK38+015 趋势项位移预测精度及误差

Table 3 Prediction accuracies and errors of trend term displacement of ZK38+015

模型	R				R_{MSE}/mm				M_{AE}/mm			
	D1-4		D1-5		D1-4		D1-5		D1-4		D1-5	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GWO-OSELM	0.9999	0.9991	0.9999	0.9998	0.0123	0.0540	0.0261	0.0166	0.0109	0.0405	0.0217	0.0155
OSELM	0.9994	0.9990	0.9993	0.9998	0.0825	0.2426	0.0711	0.2696	0.0732	0.2363	0.0618	0.2547
ELM	0.9994	0.9992	0.9995	0.9996	0.0945	0.5241	0.0754	0.6082	0.0790	0.5060	0.0475	0.5733

的波动及随机现象，并且具有一定的平稳性，因此，应用所提模型对随机项位移进行预测，更易体现出模型较强的预测能力。分别利用3种模型对两断面D1-4，D1-5监测点随机项位移进行预测，预测结果见图8，两断面各监测点预测精度和误差分别见表4，5。

由图8可知，在对各监测点随机项位移预测时，本文模型仍然表现出了较高精度，以ZK38+015断面D1-5监测点表现最为明显，传统ELM预测时，偏差较大，而经GWO优化后的OSELM预测效果明显更优，模型泛化能力也较好，算法整体性能较稳定。

再分析表4，5，同样以ZK38+020断面D1-5监测点测试集预测为例， R 达到了0.9731， R_{MSE} 为0.0114 mm， M_{AE} 为0.0093 mm，模型预测精度同样都远优于传统模型，表明所提模型应用于随机项位移预测中的适用性。另外，值得注意的是，在各监测点训练集的拟合中，传

统ELM在拟合前期效果较好，但后期性能下降较快，出现了一定程度的“过拟合”现象，使得模型泛化能力变差，出现较大预测误差，这主要是由于传统的ELM为“静态”模型，它一次性对全部训练数据进行学习并拟合，而动态预测模型则是将训练数据分为多个子集分别进行学习并拟合，因此不易出现过拟合现象，这也是本文模型在地表沉降预测中的优势所在。

(3) 累积位移预测及分析

利用前述时序分析原理，将趋势项及随机项位移进行叠加，便得到了各监测点累积位移预测结果，如图9所示，各监测点预测精度及误差见表6，7。

由图9对比可得，GWO-OSELM模型的预测结果与地表沉降实测值基本一致，而传统ELM模型预测结果偏差较大，且预测误差表现出了随着监测时间的延长而逐渐增大的特点，这也是传统“静态”模型在沉降长

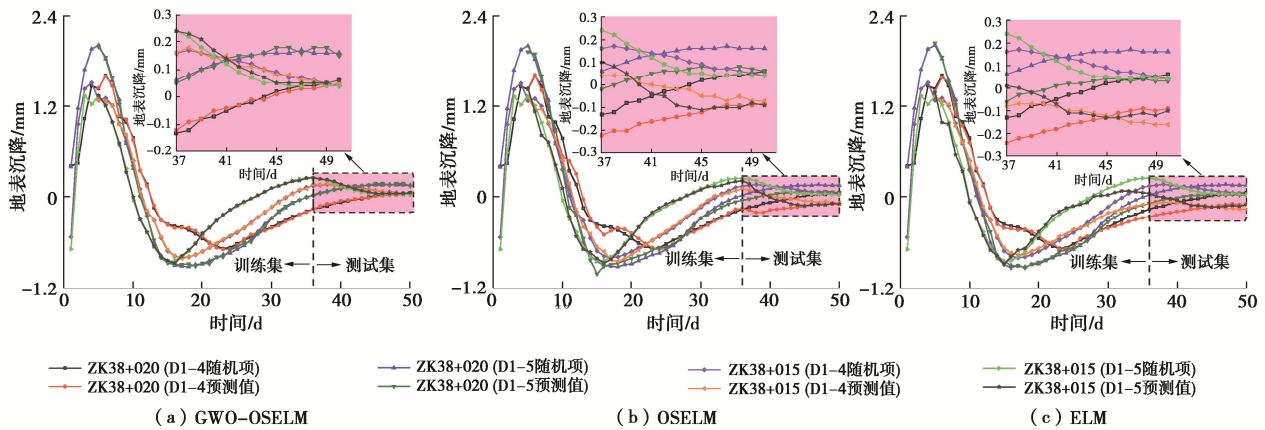


图8 随机项位移预测结果

Fig. 8 Predicted results of random term displacement

表4 ZK38+020 随机项位移预测精度及误差

Table 4 Prediction accuracies and errors of random term displacement of ZK38+020

模型	R				R_{MSE}/mm				M_{AE}/mm			
	D1-4		D1-5		D1-4		D1-5		D1-4		D1-5	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GWO-OSELM	0.9995	0.9839	0.9994	0.9731	0.0205	0.0162	0.0258	0.0114	0.0168	0.0137	0.0222	0.0093
OSELM	0.9938	0.9887	0.9961	0.9774	0.0748	0.1202	0.0717	0.0868	0.0523	0.1189	0.0570	0.0865
ELM	0.9982	0.9913	0.9989	0.9792	0.0440	0.1317	0.0553	0.1245	0.0369	0.1309	0.0438	0.1243

表5 ZK38+015 随机项位移预测精度及误差

Table 5 Prediction accuracies and errors of random term displacement of ZK38+015

模型	R				R_{MSE}/mm				M_{AE}/mm			
	D1-4		D1-5		D1-4		D1-5		D1-4		D1-5	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GWO-OSELM	0.9994	0.9673	0.9995	0.9912	0.0206	0.0124	0.0163	0.0259	0.0118	0.0104	0.0115	0.0241
OSELM	0.9974	0.9721	0.9953	0.9862	0.0449	0.1272	0.0515	0.1444	0.0331	0.1268	0.0328	0.1439
ELM	0.9901	0.9881	0.9991	0.9802	0.0931	0.2190	0.0994	0.1837	0.0666	0.2186	0.0769	0.1822

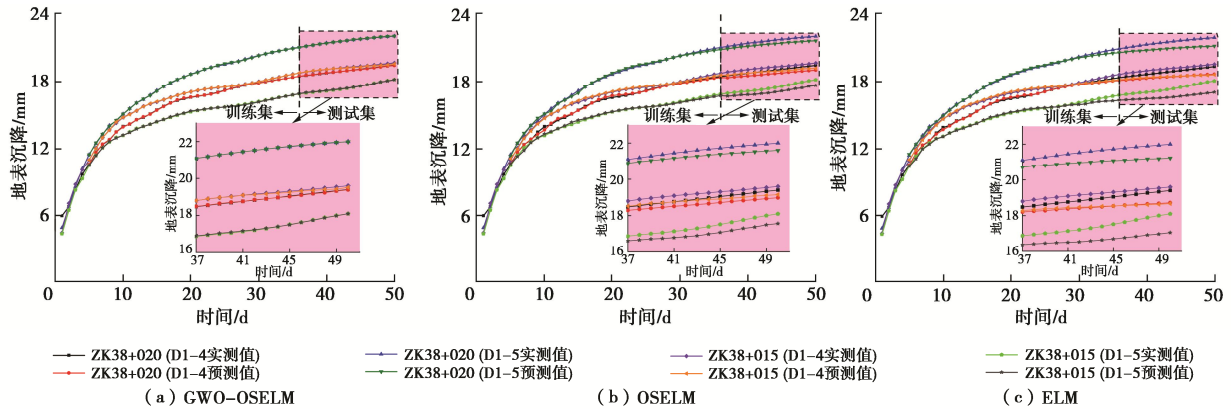


图 9 累积位移预测结果

Fig. 9 Predicted results of cumulative displacement

表 6 ZK38+020 累积位移预测精度及误差

Table 6 Prediction accuracies and errors of cumulative displacement of ZK38+020

模型	R		RMSE/ mm				MAE/ mm					
	D1-4		D1-5		D1-4		D1-5		D1-4		D1-5	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GWO-OSELM	0.9999	0.9994	0.9999	0.9997	0.0230	0.0167	0.0340	0.0093	0.0203	0.0136	0.0281	0.0071
OSELM	0.9989	0.9998	0.9991	0.9997	0.0976	0.3085	0.1125	0.3201	0.0762	0.3000	0.0919	0.3143
ELM	0.9991	0.9986	0.9990	0.9993	0.0976	0.4865	0.1255	0.6100	0.0697	0.4700	0.0962	0.5979

表 7 ZK38+015 累积位移预测精度及误差

Table 7 Prediction accuracies and errors of cumulative displacement of ZK38+015

模型	R		RMSE/ mm				MAE/ mm					
	D1-4		D1-5		D1-4		D1-5		D1-4		D1-5	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GWO-OSELM	0.9999	0.9975	0.9998	0.9996	0.0274	0.0567	0.0302	0.0246	0.0200	0.0443	0.0241	0.0207
OSELM	0.9989	0.9984	0.9983	0.9986	0.0895	0.3679	0.0989	0.4063	0.0766	0.3643	0.0806	0.3971
ELM	0.9962	0.9951	0.9960	0.9980	0.1736	0.7358	0.1629	0.7763	0.1338	0.7250	0.1125	0.7550

表 8 模型预测精度及误差

Table 8 Prediction accuracies and errors of model

类别	R		RMSE/ mm		MAE/ mm	
	训练集	测试集	训练集	测试集	训练集	测试集
RBF	0.9996	0.9813	0.0746	0.5205	0.0625	0.4852
Sigmoid	0.9999	0.9997	0.0340	0.0093	0.0281	0.0071
Sine	0.9999	0.9991	0.0314	0.2221	0.0266	0.2077

期预测中所表现出的不足。而 OSELM 模型在两断面 D1-5 监测点的预测中也出现了较大误差,其原因主要是两断面监测点随机项位移的预测精度均不是特别高,这也说明了随机项位移对累积位移预测精度有一定影响。

再结合表 6, 7 进一步分析,同样以 ZK38+020 断面 D1-5 监测点测试集预测为例, R 达到了 0.9997, RMSE 为 0.0093 mm, MAE 为 0.0071 mm, 模型预测精度也都远优于传统模型,具有较高精度及泛化能力,算法整体稳定性较好。因此,本文所提模型更适合应用于洞口段地表沉降长期预测中,具有较好的推广应用价值。

3 讨论

3.1 激励函数的选择

由于神经网络的上一层输出需通过激励函数转换之后才能输入到下一层,因此,激励函数的选择十分重要^[9]。为了比较不同激励函数对模型预测性能的影响,选取常用的“径向基函数(RBF)”、“Sigmoid 函数”“Sine 函数”,并以 ZK38+020 断面 D1-5 监测点的实测值为例进行分析。表 8 为选择不同激励函数时的预测精度和误差,图 10 为不同激励函数时的预测结果。




图 10 不同激励函数时的预测结果

Fig. 10 Predicted results of different activation functions

由表 8 可知,对于训练集拟合结果而言,以 Sine 函数稍优一些,但测试集的预测精度则以 Sigmoid 函数最优。再结合图 10 可得,当模型参数设置相同时,采用 RBF 函数,测试集预测结果偏差最大,而采用

Sigmoid 函数, 预测结果与实测值基本一致, 采用 Sine 函数, 预测结果介于两者之间。综上, 本文模型预测时采用 Sigmoid 函数整体要更优, 模型泛化能力较好。

值得注意的是, 对于新建工程, 往往只有前期监测数据, 然而对于同一断面而言, 其工程地质特征及条件往往是固定的, 前期所获监测数据一定程度上也可以反映出其未来变化趋势, 因此实际应用时, 激励函数可通过前期监测数据的训练和测试进行选择。

3.2 随机项位移优势影响因素分析

事实上, 对于随机项位移的预测, 若以影响因素作为模型输入变量, 则更利于实际应用, 但鉴于目前监测手段有限, 很多随机性因素无法获得。因此, 本文仍以分解所得随机项位移进行模型训练和预测, 并根据现有监测手段所获数据, 以 ZK38+020 断面 D1-5 监测点为例, 对其部分影响因素 (单日降雨量、双日降雨量、拱顶下沉速率及地表沉降速率, 如图 11 所示) 进行分析。




图 11 随机项位移影响因素

Fig. 11 Impact factors of random term displacement

本文借鉴生物化学领域相关性分析新方法 (GRaMM) [20], 尝试将其引入随机项位移优势影响因素分析中, 具体流程如图 12 所示。它是由贾伟教授团队于 2019 年首次提出的一种相关性分析方法, 整合了线性回归、最大信息系数 (MIC) 等多种方法, 能够较好的处理线性和非线性关系, 最初应用于代谢组与微生物组的相关性分析中。为更好的验证其合理性, 与文献[18]中的 MIC 分析结果进行对比, 见表 9, 当某一影响因素与随机项位移相关性越强时, 数值越接近 0, 此时可认为该影响因素是相对主要的。

分析表 9 可知, 在现有监测手段所获数据中, 地表沉降速率影响程度最大, 其次是拱顶下沉速率, 而降雨量影响稍小一些, 原因是该段隧道施工期间采取了较为得当的地表防排水措施, 并且地层沉降较稳定。另外, GRaMM 的分析结果与文献[18]中 MIC 的分析结果基本一致, 且前者结果整体偏小一些, 主要是由于它可以有效的对数据中存在的异常值进行处理。因此, 利用 GRaMM 分析随机项位移影响因素具备一定的合理性和可行性。随着监测手段日趋完善, 将会有更多的影响因素被采集, 然后利用该方法分析出优势影响因素, 并以

此作为模型输入变量, 即可更精确地预测随机项位移。

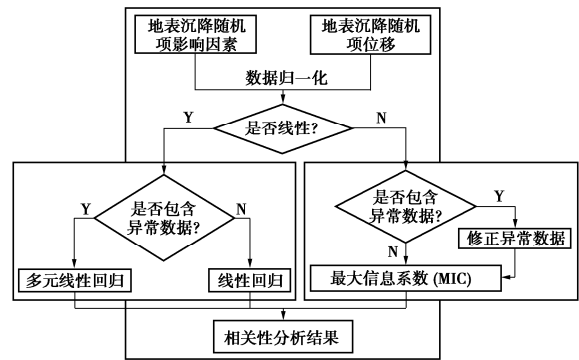


图 12 GRaMM 相关性计算流程

Fig. 12 Calculation flowchart of correlation with GRaMM

表 9 相关性对比结果

Table 9 Comparative results of correlation

方法	单日降雨量	双日降雨量	拱顶下沉速率	地表沉降速率
GRaMM	0.4968	0.4519	0.7114	0.7664
MIC	0.4716	0.4584	0.8642	0.9600

4 结论

(1) 采用三次样条函数插值法对地表沉降实测值进行等距处理, 并结合时序分析理论和 VMD 分解方法对其进行分解, 可以有效降低原始数据复杂性, 提高预测准确性, 并且可以反映出位移分量自身尺度特征。

(2) 将 GWO-OSELM 模型应用于重庆兴隆隧道洞口段 ZK38+020 和 ZK38+015 断面 D1-4, D1-5 监测点实测地表沉降预测中, 对比分析结果表明了该模型在趋势项、随机项及累积位移预测中均要优于 OSELM 模型及传统 ELM 模型, 模型预测精度高且误差小, 具有很好的泛化能力, 验证了该模型的合理性及工程实用性。

(3) 深入探讨了激励函数的选择对模型预测性能的影响, 发现 Sigmoid 激励函数更适合本文模型, 此时模型预测性能最佳, 且具有很好的泛化能力。

(4) 通过引入 GRaMM 相关性分析新方法, 对地表沉降随机项部分影响因素进行定量分析, 发现地表沉降速率和拱顶下沉速率对随机项位移影响程度要高于降雨量, 可为后续更精确的预测随机项位移提供借鉴。

致 谢: 衷心感谢中交隧道局重庆项目经理部和国家科技基础条件平台-国家气象科学数据中心提供的监测数据及气象数据支持!

参考文献:

[1] 王迎超, 尚岳全, 徐兴华, 等. 隧道出洞口松散围岩塌方时空预测研究[J]. 岩土工程学报, 2010, 32(12): 1868 - 1874. (WANG Ying-chao, SHANG Yue-quan, XU Xing-hua, et al. Time and space prediction of collapse of loose wall rock at tunnel exit[J]. Chinese Journal of Geotechnical Engineering,

- 2010, **32**(12): 1868 - 1874. (in Chinese))
- [2] 谢亦朋, 杨秀竹, 阳军生, 等. 松散堆积体隧道围岩变形破坏细观特征研究[J]. 岩土力学, 2019, **40**(12): 4925 - 4934. (XIE Yi-peng, YANG Xiu-zhu, YANG Jun-sheng, et al. Mesoscopic characteristics of deformation and failure on surrounding rocks of tunnel through loose deposits[J]. Rock and Soil Mechanics, 2019, **40**(12): 4925 - 4934. (in Chinese))
- [3] ZHENG D, HUANG J, LI D Q, et al. Embankment prediction using testing data and monitored behaviour: a Bayesian updating approach[J]. Computers and Geotechnics, 2017, **93**: 150 - 162.
- [4] 姚仰平, 王 珅, 王乃东, 等. 临线堆载影响下高速铁路基长期沉降预测方法[J]. 岩土工程学报, 2019, **41**(4): 625 - 630. (YAO Yang-ping, WANG Shen, WANG Nai-dong, et al. Prediction method for long-term settlements of high-speed railway subgrade under influences of nearby loads[J]. Chinese Journal of Geotechnical Engineering, 2019, **41**(4): 625 - 630. (in Chinese))
- [5] WANG S H, ZHANG Z S, REN Y P, et al. UAV photogrammetry and AFSA-Elman neural network in slopes displacement monitoring and forecasting[J]. KSCE Journal of Civil Engineering, 2020, **24**(8): 19 - 29.
- [6] 李麟玮, 吴益平, 苗发盛, 等. 考虑变形状态动态切换的阶跃型滑坡位移区间预测方法[J]. 岩石力学与工程学报, 2019, **38**(11): 2272 - 2287. (LI Lin-wei, WU Yi-ping, MIAO Fa-sheng, et al. Displacement interval prediction method for step-like landslides considering deformation state dynamic switching[J]. Chinese Journal of Rock Mechanics and Engineering, 2019, **38**(11): 2272 - 2287. (in Chinese))
- [7] MOGHADDASI M R, NOORIAN-BIDGOLI M. ICA-ANN, ANN and multiple regression models for prediction of surface settlement caused by tunneling[J]. Tunnelling and Underground Space Technology, 2018, **79**: 197 - 209.
- [8] CHEN R P, ZHANG P, KANG X, et al. Prediction of maximum surface settlement caused by earth pressure balance (EPB) shield tunneling with ANN methods[J]. Soils and Foundations, 2019, **59**(2): 284 - 295.
- [9] TOMAS J, SEJNOHA M, SEJNOHA J. Applying bayesian approach to predict deformations during tunnel construction[J]. International Journal for Numerical and Analytical Methods in Geomechanics, 2018, **42**(15): 1765 - 1784.
- [10] ZHANG P, WU H N, CHEN R P, et al. Hybrid meta-heuristic and machine learning algorithms for tunneling-induced settlement prediction: A comparative study[J]. Tunnelling and Underground Space Technology, 2020, **99**.
- [11] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, **62**(3): 531 - 544.
- [12] LIANG N Y, HUANG G B, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. IEEE Transactions on Neural Networks, 2006, **17**(6): 1411 - 1423.
- [13] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, **69**(3): 46 - 61.
- [14] 公路隧道施工技术规范: JTG F60—2009[S]. 2009. (Technical Specification for Highway Tunnel Construction: JTG F60—2009[S]. 2009. (in Chinese))
- [15] WANG Z, YAO W J, CAI Y Q, et al. Analysis of ground surface settlement induced by the construction of a large-diameter shallow-buried twin-tunnel in soft ground[J]. Tunnelling and Underground Space Technology, 2019, **83**: 520 - 532.
- [16] ZHANG A B, CHEN T Y, LIU X X, et al. Monitoring data filter and deformation information extraction based on wavelet filter and empirical mode decomposition[J]. Applied Mechanics and Materials, 2015, **742**: 261 - 271.
- [17] DU H, SONG D Q, CHEN Z, et al. Prediction model oriented for landslide displacement with step-like curve by applying ensemble empirical mode decomposition and the PSO-ELM method[J]. Journal of Cleaner Production, 2020, **270**.
- [18] 李麟玮, 吴益平, 苗发盛, 等. 基于变分模态分解与GWO-MIC-SVR模型的滑坡位移预测研究[J]. 岩石力学与工程学报, 2018, **37**(6): 1395 - 1406. (LI Lin-wei, WU Yi-ping, MIAO Fa-sheng, et al. Displacement prediction of landslides based on variational mode decomposition and GWO-MIC-SVR model[J]. Chinese Journal of Rock Mechanics and Engineering, 2018, **37**(6): 1395 - 1406. (in Chinese))
- [19] 王鹏宇, 王述红. 四类常见边坡岩石类别识别和边界范围确定的方法[J]. 岩土工程学报, 2019, **41**(8): 1505 - 1512. (WANG Peng-yu, WANG Shu-hong. Method for identifying four common rock types of slopes and determining boundary range[J]. Chinese Journal of Geotechnical Engineering, 2019, **41**(8): 1505 - 1512. (in Chinese))
- [20] LIANG D D, LI M C, WEI R M, et al. Strategy for intercorrelation identification between metabolome and microbiome[J]. Analytical Chemistry, 2019, **91**(22): 14424 - 14432.