

基于改进极限学习机模型的盾构掘进引发地表最大沉降预测

阮永芬, 邱龙, 乔文倩, 闫明, 郭宇航

Prediction of the maximum ground settlement caused by shield tunneling based on the improved limit learning machine model

RUAN Yongfen, QIU Long, QIAO Wenjian, YAN Ming, and GUO Yuhang

在线阅读 View online: <https://doi.org/10.16030/j.cnki.issn.1000-3665.202210007>

您可能感兴趣的其他文章

Articles you may be interested in

基于主成分分析法的Q2黄土湿陷特性研究

A study of the collapsibility of Q2 loess based on principal component analysis

王玉涛, 刘小平, 曹晓毅 水文地质工程地质. 2020, 47(4): 141-148

干湿过程中膨胀土最大剪切模量及其预测

The maximum shear modulus of expansive soil during wetting-drying processes and its prediction

陈伟, 孙德安, 张俊然 水文地质工程地质. 2021, 48(6): 89-96

软土地区双线区间盾构隧道施工对周边地表以及建筑物沉降的影响

Influences of double-track shield tunnel construction on settlements of adjacent ground and buildings in a soft soil area

潘涛 水文地质工程地质. 2022, 49(1): 101-108

基于尖点突变理论的软岩弃渣路堤局部稳定性分析

An analysis of local stability of soft rock cinder embankment based on the cusp catastrophe theory

鞠兴华, 杨晓华, 张莎莎 水文地质工程地质. 2019, 46(6): 112-118

盾构地铁隧道穿越既有铁路桥的沉降分析

An analysis of the settlement of a shield tunnel passing under the operating railway bridge

于德海, 舒娇娇, 秦凯凯 水文地质工程地质. 2020, 47(2): 148-152

含分数阶的灰色模型及其在地基沉降预测中的应用

Gray model with fractional order and its application to settlement prediction

赖文杰, 齐昌广, 郑金辉, 王新泉, 左殿军 水文地质工程地质. 2019, 46(3): 124-124



关注微信公众号, 获得更多资讯信息

DOI: 10.16030/j.cnki.issn.1000-3665.202210007

阮永芬, 邱龙, 乔文件, 等. 基于改进极限学习机模型的盾构掘进引发地表最大沉降预测 [J]. 水文地质工程地质, 2023, 50(5): 124-133.

RUAN Yongfen, QIU Long, QIAO Wenjian, *et al.* Prediction of the maximum ground settlement caused by shield tunneling based on the improved limit learning machine model[J]. Hydrogeology & Engineering Geology, 2023, 50(5): 124-133.

基于改进极限学习机模型的盾构掘进引发 地表最大沉降预测

阮永芬¹, 邱龙¹, 乔文件², 闫明², 郭宇航²

(1. 昆明理工大学建筑工程学院, 云南昆明 650500;

2. 中铁二十局集团第五工程有限公司, 云南昆明 650000)

摘要: 城市地铁盾构施工引发的地面过大变形会严重影响周边构筑物的正常使用, 甚至引发工程事故。针对传统预测方法中的数据维度过大容易导致精度降低、计算复杂等问题, 提出了一种基于主成分分析 (principal component analysis, PCA) 算法和哈里斯鹰优化 (Harris Hawks optimization, HHO) 算法的极限学习机 (extreme learning machine, ELM) 预测模型。在地质、几何及盾构参数中初选 14 个影响因子, 利用 PCA 算法在 14 维数组中分离和提取 5 个主成分变量作为模型的输入, 利用 HHO 优化 ELM 模型的输入层权值和隐含层阈值参数, 得到预测模型的最优解。以昆明轨道交通五号线怡心桥站—广福路站隧道区间监测数据进行仿真验证, 并将该模型与 BP 神经网络、RBF、未优化的 ELM 模型进行对比分析。结果表明: PCA-HHO-ELM 预测模型的均方根误差为 0.143 5、平均绝对误差为 0.026 2、决定系数为 0.959 6, 相较于其他模型, 该模型具有更优的预测性能; 与未优化的 ELM 模型相比, HHO 算法能够提高 ELM 模型的预测精度和泛化能力。PCA-HHO-ELM 模型能可靠预测盾构诱发的地表最大沉降, 可为类似变形预测提供一种更为可行的新思路。

关键词: 地表最大沉降; 主成分分析; 哈里斯鹰算法; 极限学习机; 沉降预测

中图分类号: TU478

文献标志码: A

文章编号: 1000-3665(2023)05-0124-10

Prediction of the maximum ground settlement caused by shield tunneling based on the improved limit learning machine model

RUAN Yongfen¹, QIU Long¹, QIAO Wenjian², YAN Ming², GUO Yuhang²

(1. Faculty of Civil Engineering and Mechanics, Kunming University of Science and Technology, Kunming, Yunnan 650500, China; 2. China Railway 16th Bureau Group Urban Rail Engineering Co. Ltd., Kunming, Yunnan 650000, China)

Abstract: Excessive ground deformation caused by shield tunneling of urban metro will seriously affect the normal use of surrounding structures, and even cause engineering accidents. In view of the problems that the data dimension in traditional prediction methods is too large, which easily leads to lower accuracy and complex calculation, this study proposes an extreme learning machine (ELM) prediction model based on the principal component analysis (PCA) algorithm and Harris Hawk optimization algorithm (HHO). Ten influence factors are

收稿日期: 2022-10-08; 修订日期: 2023-01-07

投稿网址: www.swdzcgdz.com

基金项目: 云南省重点研发计划(社会发展领域)项目(2018BC008)

第一作者: 阮永芬(1964-), 女, 博士, 教授, 主要从事工程地质与岩土工程的研究。E-mail: rxy64@163.com

通讯作者: 邱龙(1998-), 男, 硕士研究生, 主要从事工程地质与岩土工程的研究。E-mail: 1034403813@qq.com

preliminarily selected from the geological, geometric and shield parameters. PCA is used to separate and extract five principal component variables from the 10 dimensional arrays as the input of the model. HHO is used to optimize the input layer weights and hidden layer threshold parameters of the ELM model, and the optimal solution of the prediction model is obtained. The monitoring data of the Yiguang section of Kunming Rail Transit Line 5 are used for simulation verification, and the model is compared with the BP neural network, RBF and non-optimized ELM model. The results show that the root mean square error of the PCA-HHO-ELM prediction model is 0.143 5, the average absolute error is 0.026 2, and the determination coefficient R^2 is 0.959 6. Compared with other models, this model has better prediction performance. Compared with the non-optimized ELM, HHO can improve the prediction accuracy and generalization ability of ELM. The PCA-HHO-ELM model can reliably predict the maximum ground settlement induced by shield, and can provide a more feasible new idea for similar deformation prediction.

Keywords: maximum surface settlement; Principal component analysis; Harris Hawk Optimization; Extreme learning machine; settlement prediction

盾构法因其施工速度快、适应性强、环境污染小等优点,已成为目前城市轨道交通的主要施工方法^[1-3]。但盾构机在掘进过程中会对周围土体产生附加荷载,不可避免地扰动周围土体,进而诱发地表沉降,如果局部地表沉降过大,将严重影响周围结构的正常使用,甚至引发工程事故。所以,研究各类诱发因素与地表沉降间的关系,减小掘进过程带来的地表沉降已然成为隧道施工的重中之重。当前,针对盾构隧道施工引起地面沉降这一岩土工程问题,众多学者进行了深入研究,较有代表性的研究方法有理论法^[4-7]、经验公式法^[8-9]、数值模拟^[10-14]等。但是严格来讲,上述研究方法均属于传统理论范畴,在参数选取及解决非线性问题等方面均具有很大局限性。

为解决掘进断面的地质条件、施工过程中产生的各类新参数以及持续时间的影响,近年来国内外学者提出了许多盾构隧道地表沉降预测的机器学习方法。如 Zhang 等^[15]对比了误差反向传播(back propagation, BP)、径向基函数(radial basis function, RBF)、广义回归神经网络(generalized regression neural network, GRNN)3种神经网络模型对隧道最大地面沉降的预测效果,提出了一种将土层力学特性与几何参数相结合的指标计算方法;赵楠等^[16]选用粒子群优化(particle swarm optimization, PSO)算法和遗传算法(genetic algorithm, GA)对支持向量机参数进行优化处理,针对多步算法产生的较大偏差,结合实际工程,验证了融合长短时记忆(long short-term memory, LSTM)神经网络支持向量机模型的优越性;李建生等^[17]结合 Peck 公式与遗传算法的相关优点,提出了一种用融合理论公式预测隧道地面沉降的智能学习方法。随着网络技术的发展,越

来越多的新兴优化算法不断提出。Chen 等^[18]基于3种神经网络,提出了一种定义输入参数物理意义的改进指标,用于量化地质参数,提高了人工神经网络模型的预测精度;乔金丽等^[19]采用变步长的方法构建 BP 网络模型,经广州地铁二号线实测沉降检验,其预测效果较好;Wang 等^[20]提出了基于小波核函数的平滑相关向量机,预测隧道开挖引起的地表沉降;陈仁鹏等^[21]通过 PSO 算法确定了 BP 神经网络和随机森林算法的超优参数,提出了一种预测盾构隧道纵向及最大地表沉降的方法;宫思艺等^[22]在 XGBoost 地层动态识别模型的基础上,利用盾构施工参数推断地层变化,提出基于 BP-SVR 的地面沉降预测融合模型;林荣安等^[23]为提高由盾构施工引起的软硬不均地层地表沉降预测的准确性,建立基于粗糙集-支持向量回归的地表沉降预测模型;李洛宾等^[24]研究处理盾构掘进的序列化数据时,发现循环神经网络的沉降预测结果优于 BP 神经网络。上述预测方法均取得了一定的效果,但数据维度过大导致精度低、模型学习速度慢、计算复杂,并且由于影响盾构施工地表沉降因素的复杂性、各类方法的缺陷性等问题,在实际应用中仍有一定的局限性。

极限学习机(extreme learning machine, ELM)是一种典型的单隐层前馈神经网络(single-hidden layer feed-forward neural network, SLFN)^[25-26],与 BP 神经网络等传统学习算法相比,ELM 具有泛化性能好、学习速度快、预测精度高等优点^[27]。但 ELM 模型输入层权值和隐含层阈值具有随机性,在不确定条件下可能导致模型预测精度降低。为解决这一问题,本文引入哈里斯鹰优化(Harris Hawks optimization, HHO)算法^[28]对

ELM 中的权值和阈值参数进行优化, 弥补 ELM 中存在的缺陷。针对上述预测方法中存在的数据维度过大、模型学习速度慢、精度低等问题, 本文提出了结合主成分分析 (principal component analysis, PCA) 算法、HHO 算法和 ELM 模型的盾构隧道地表最大沉降预测方法, 并以昆明轨道交通五号线怡心桥站—广福路站隧道区间盾构掘进实测数据为例, 通过仿真训练和对比分析验证模型的预测性能。

1 工程背景

昆明轨道交通五号线怡心桥站—广福路站 (以下简称“怡—广站”) 隧道区间起点里程右 DK11+911.523, 终点里程右 DK13+056.149, 全长 1 144.626 m。线路出怡心桥站后, 沿滇池路西北侧敷设, 绕避怡心桥、采莲桥桩基后回归滇池路下方, 于滇池路广福路路口进入广福路站。本段线路设置曲线半径分别为 350 m 及 1 000 m 的平面曲线。区间隧道埋深 9.71 ~ 21.35 m, 底板标高 1 867.08 ~ 1 872.54 m, 隧道洞径 6.20 m, 采用盾构法施工。研究数据取自怡—广站 DK11+966.221—DK12+966.733 区段, 间隔 5 m 设置一个监测点, 包含隧道轴线处地面沉降监测点位 200 个。模型所使用的数据集由输入参数和沉降值组成。ELM 模型输入是序列形式, 故输入值是由沉降监测点前后各 2 环 (共 4 环) 的数据组成, 而 ELM 模型的输出只包括一环。

数据集中测量沉降值取掘进过程中记录数据的最大沉降值, 模型的输入参数 (A_1 — A_{14}) 包括: 地质参数、几何参数、盾构参数 3 个部分。数据集数据统计信息如表 1。

表 1 数据集数据统计信息表
Table 1 Data set statistics table

	参数	最小值	最大值
地质参数	地下水位 (A_1)/m	1.50	1.92
	浮密度 (A_2)/(g·cm ⁻³)	0.54	0.77
	压缩模量 (A_3)/MPa	3.37	4.42
	泊松比 (A_4)	0.28	0.33
	侧压力系数 (A_5)	0.49	0.59
几何参数	埋深 (A_6)/m	18.4	25.3
	土压力 (A_7)/MPa	1.8	2.7
	总推力 (A_8)/kN	8 760	16 280
盾构参数	掘进速度 (A_9)/(mm·min ⁻¹)	61	94
	出土量 (A_{10})/m ³	45.8	48.0
	刀盘扭矩 (A_{11})/(N·m)	1 200	2 275
	拼装时间 (A_{12})/h	0.35	0.85
	注浆量 (A_{13})/m ³	3.60	4.40
	注浆压力 (A_{14})/bar	3.0	3.8
	地表最大沉降/mm	-15.69	10.44

地质参数: 怡—广站区间盾构隧道穿越范围内的土层主要包括粉质黏土、粉砂、黏质粉土、泥炭质土。为综合反映各断面不同土质对沉降的影响, 选取地下水位、浮密度、压缩模量、泊松比及侧压力系数作为地质参数。其中, 浮密度为隧道上方平均加权浮密度, 压缩模量、泊松比及侧压力系数取掌子面地层加权平均值。

几何参数: 盾构掘进过程中对地面沉降产生影响的有隧道埋深、盾构机直径及盾尾间隙等。因盾构掘进中, 其直径和盾尾间隙是常数, 对模型训练没有影响, 故仅考虑隧道埋深。

盾构参数: 盾构掘进过程中, 会产生大量包括盾构机姿态、注浆参数及刀盘状态在内的 64 项相关参数。结合文献 [29] 和实际施工过程, 选取 8 项盾构参数作为输入: 土压力、盾构总推力、掘进速度、出土量、刀盘扭矩、管片拼装时间、注浆量、注浆压力。

2 机器学习模型

2.1 主成分分析算法 (PCA)

PCA 是一种常用的数据降维算法之一, 其原理是在高维数组中分离和提取多个相互正交的特征变量, 充分反映原始数据的差异性, 在尽量减少原始指标信息损失的同时, 减少待分析的指标 [30-31]。PCA 数据降维通过重构主成分因子表达式, 将原始的 N 维特征映射到低维的 K 维特征 ($K < N$) 中, 得到 K 个主成分变量。

设原始 N 个影响因子构成的 N 维特征向量 $\mathbf{X} = (x_1, x_2, \dots, x_N)^T$, 则 \mathbf{X} 的协方差矩阵 $\mathbf{D}(\mathbf{X})$ 为:

$$\mathbf{D}(\mathbf{X}) = (c_{ij})_{N \times N} = \begin{pmatrix} c_{11} & c_{12} & \cdots & c_{1N} \\ c_{21} & c_{22} & \cdots & c_{2N} \\ \vdots & \vdots & \vdots & \vdots \\ c_{N1} & c_{N2} & \cdots & c_{NN} \end{pmatrix} \quad (1)$$

式中: c_{ij} —— N 维特征构成的协方差因子。

通过 $\mathbf{Q}^T \mathbf{D}(\mathbf{X}) \mathbf{Q}$ 变换得到 $\mathbf{D}(\mathbf{X})$ 特征值 $\lambda = \lambda_1, \lambda_2, \dots, \lambda_N (\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N)$, 最后得到重构后的综合向量 \mathbf{Z} , 其表达式为:

$$\mathbf{Z}_i = L_{1i}x_1 + L_{2i}x_2 + \cdots + L_{Ni}x_N \quad (2)$$

式中: \mathbf{L} ——特征值 λ 的正交特征向量, $\mathbf{L} = (L_{ij})$ 。

为全面反映原始 N 维特征且不减少指标信息损失, 一般取方差最大的前 K ($K < N$) 个变量作为主成分因子, 且定义累计贡献率 (即累计方差) 大于或等于 80% 时为筛选出的 K 个主成分因子, 将得到的 K 个主成分因子通过式 (2) 计算, 即可得到重构后的 Z_1 — Z_K 。

2.2 极限学习机(ELM)

SLFN 大多采用梯度下降法迭代, 容易导致模型训练慢、计算复杂等问题。与之相比, ELM 模型的输入层权值和隐含层阈值具有随机性, 模型收敛速度快, 训练时只需设置隐含层神经元个数, 便可通过迭代获得全局最优解, 所以与传统 SLFN 相比, ELM 模型的泛化性更好、学习速度更快。其网络拓扑结构如图 1 所示。




图 1 ELM 算法模型结构图

Fig. 1 Structure diagram of ELM algorithm model

由图 1 知, ELM 模型的输入层、隐含层及输出层之间全连接, 分别有 K 、 L 和 S 个神经元节点。输入层的 K 个神经元节点, 对应 2.1 节中的 K 个主成分变量; 若模型用于分类问题, 则 $S > 1$, 若模型用于回归预测, 则 $S = 1$ 。设 Q 个训练集输入矩阵 \mathbf{X} 和输出矩阵 \mathbf{Y} 分别为 $\mathbf{X} = (x_{i1}, x_{i2}, \dots, x_{iK})^T \in \mathbf{R}_K$ 、 $\mathbf{Y} = (y_{i1}, y_{i2}, \dots, y_{iS})^T \in \mathbf{R}_S$, 假定任意小误差激活函数 $g(x)$, 则网络输出矩阵 \mathbf{Z} 为

$$\mathbf{Z}_j = \sum_{i=1}^L \beta_i g(\omega_i \cdot \mathbf{X}_j + b_j), j = 1, 2, \dots, Q \quad (3)$$

式中: $\omega_i = (\omega_{i1}, \omega_{i2}, \dots, \omega_{iK})$ ——输入层权值矩阵;

$\beta = (\beta_1, \beta_2, \dots, \beta_S)$ ——输出层权值矩阵;

$\mathbf{b} = (b_1, b_2, \dots, b_L)$ ——隐含层阈值矩阵。

若 \mathbf{G} 为 ELM 的隐含层输出矩阵, 则式(3)可简化为

$$\mathbf{G} \cdot \beta = \mathbf{Z}^T \quad (4)$$

当 Q 较大时, 为减少计算量, L 一般取小于 Q 的数, 这时 ELM 的误差就可逼近一个无限小的值 $\varepsilon (\varepsilon > 0)$, 如式(5)所示。所以, 当激活函数任意无限小且可微时, ELM 参数就不再需要全部迭代调整, 即当 ω 和 \mathbf{b} 随机设定后, ELM 就可直接运行且不再修改权值和阈值参数。综上, ELM 模型的训练结果可等效为求解方程(6)的最小二乘解。

$$\sum_{j=1}^Q \|\mathbf{Z}_j - \mathbf{Y}_j\| = 0 \quad (5)$$

$$\min_{\beta} \|\mathbf{G} \cdot \beta - \mathbf{Z}^T\| \quad (6)$$

式(6)的解为:

$$\bar{\beta} = \mathbf{G}^+ \cdot \mathbf{Z}^T \quad (7)$$

式中: \mathbf{G}^+ —— \mathbf{G} 的 Moore-Penrose 广义逆。

2.3 哈里斯鹰优化(HHO)算法

HHO 算法是 Heidari 等^[28] 基于哈里斯鹰的捕食行为, 于 2019 年提出的一种群算法, 该算法需要调节的参数较少, 具有较强的全局搜索能力。具体包括探索阶段、转换阶段及开发阶段, 具体捕食行为如下。

2.3.1 探索阶段

在此阶段, 哈里斯鹰处于侦察猎物状态, 若未找到猎物, 需不断按式(8)更新位置寻找猎物。

$$\mathbf{X}(t+1) = \begin{cases} X_{\text{rand}}(t) - r_1 |X_{\text{rand}}(t) - 2r_2 X(t)| & q \geq 0.5 \\ [X_{\text{rabbit}}(t) - X_m(t)] - r_3 [lb + r_4(ub - lb)] & q < 0.5 \end{cases} \quad (8)$$

式中: r_1, r_2, r_3, r_4 —— $[0, 1]$ 之间的随机数;

q ——用于判定选择采用的策略;

ub, lb ——搜索空间的上、下限;

$X_{\text{rand}}(t)$ ——哈里斯鹰个体的随机位置;

$X_{\text{rabbit}}(t)$ ——猎物当前位置;

$X(t), X(t+1)$ ——当前和下一次更新时的个体位置;

$X_m(t)$ ——当前种群所有个体的平均位置, 表达式为:

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad (9)$$

式中: $X_i(t)$ ——种群中第 i 个个体的位置;

N ——种群数量。

2.3.2 搜索与开发的转换阶段

在此阶段, 猎物体能极大消耗, 哈里斯鹰根据猎物的逃逸能量(C)调整自身位置, 将全局搜索范围变为局部搜索, C 按式(10)计算:

$$C = 2C_0 \left(1 - \frac{t}{M_a}\right) \quad (10)$$

式中: C_0 ——猎物的初始能量, 每次迭代时在 $[-1, 1]$ 中随机自动更新;

M_a ——最大迭代数;

t ——当前迭代数。

当 $|C| \geq 1$ 时, 猎物逃逸能量高, 猎物容易逃脱, 则返回 2.3.1 的搜索阶段; 当 $|C| < 1$ 时, 猎物能量较低, 则进入下一阶段。

2.3.3 开发阶段

在此阶段, 哈里斯鹰通过 4 种策略对猎物进行围捕, 其数学模型见式(11)~(17), 设猎物的逃脱概率为 r , 当 $r < 0.5$ 时猎物逃脱, 当 $r \geq 0.5$ 时逃脱失败。

(1) 软包围策略

$$X(t+1) = \Delta X(t) - E|JX_{\text{rabbit}}(t) - X(t)| \quad (11)$$

$$\Delta X(t) = X_{\text{rabbit}}(t) - X(t) \quad (12)$$

式中: J ——猎物逃逸的跳跃距离, 逃逸时在 $0 \sim 2$ 之间随机选择;

ΔX ——哈里斯鹰的最优个体与当前个体的差值;

E ——猎物动态逃逸能量。

(2) 硬包围策略

$$X(t+1) = X_{\text{rabbit}}(t) - E|\Delta X(t)| \quad (13)$$

(3) 渐进式快速俯冲软包围策略

$$X(t+1) = \begin{cases} Y & f(Y) < f(X(t)) \\ Z & f(Z) < f(X(t)) \end{cases} \quad (14)$$

$$Y = X_{\text{rabbit}}(t) - E|JX_{\text{rabbit}}(t) - X(t)| \quad (15)$$

$$Z = Y + S \cdot LF(D) \quad (16)$$

式中: $f()$ ——适应度函数;

D ——已知种群维度;

S —— D 维随机矩阵;

$LF()$ ——莱维(Levy)飞行函数。

(4) 渐进式快速俯冲硬包围策略

$$Y = X_{\text{rabbit}}(t) - E|JX_{\text{rabbit}}(t) - X_m(t)| \quad (17)$$

2.4 PCA-HHO-ELM 预测模型

由于 ELM 模型的输入层权值和隐含层阈值都是随机产生的, 这些参数在不确定的情况下可能导致 ELM 模型预测精度降低或者模型产生过拟合现象, 因此本文利用 HHO 算法对 ELM 模型的权值和阈值参数进行优化, 寻求全局最优解, 从而使 ELM 具有更好的学习和预测能力。基于以上原理, 本文提出了一种集 ELM、PCA、HHO 于一体的混合人工智能模型。ELM 用于构建盾构隧道地表最大沉降与其影响因素之间的关系; PCA 用于数据降维, 简化 ELM 网络拓扑结构; HHO 用于优化 ELM 的权值和阈值参数。PCA-HHO-ELM 模型的计算步骤如下, 流程图如图 2 所示。

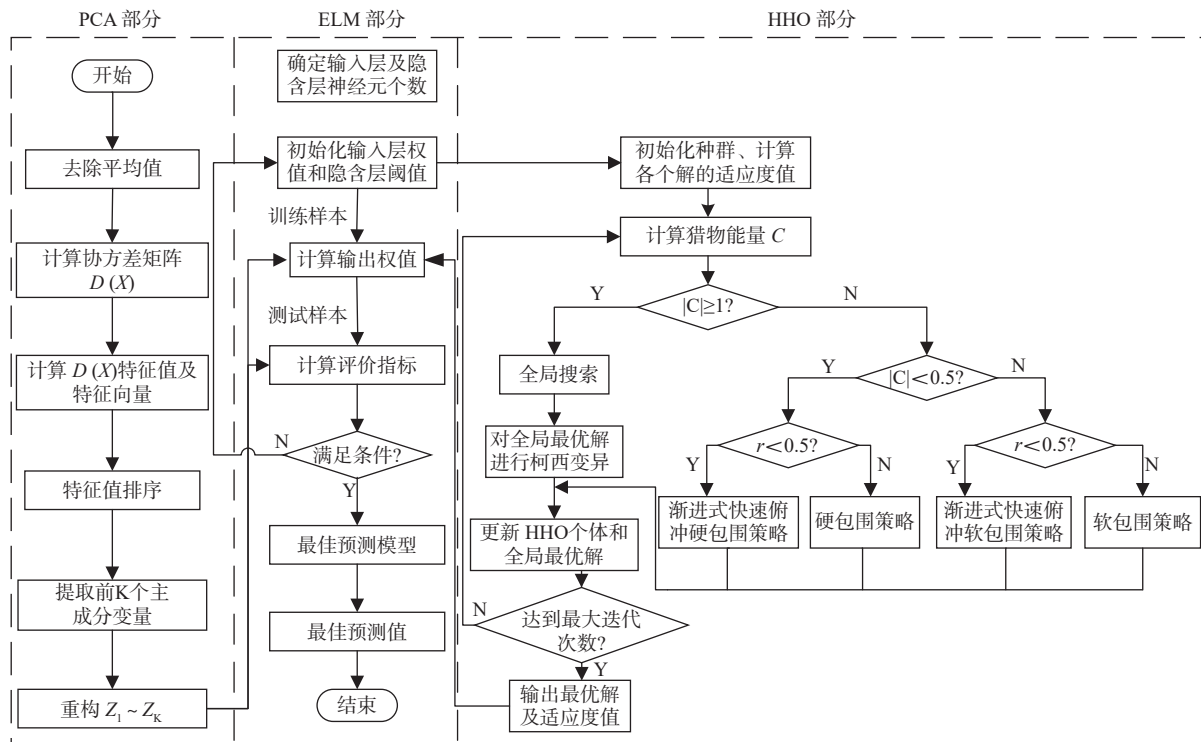


图 2 PCA-HHO-ELM 模型流程图

Fig. 2 Flow chart of PCA-HHO-ELM model

步骤 1: 对数据进行预处理, 剔除非正常数据, 利用 PCA 算法将数据降维, 提取出 K 个主成分因子。

步骤 2: 为使数据具有代表性, 将提出的主成分因

子及地表最大沉降值随机排列, 把数据分为训练集和测试集。

步骤 3: 对训练集及测试集归一化处理。

步骤 4: 利用 HHO 算法对 ELM 中的输入层权值和隐含层阈值参数进行优化, 重构 ELM 模型。

步骤 5: 迭代更新适应度值及位置, 将训练误差作为 HHO 适应度函数, 判定是否满足终止条件, 若满足则退出循环, 输出寻优结果; 否则, 重复步骤 5。

步骤 6: 将测试集输入优化后的 ELM 中, 输出预测结果。

3 模型建立

3.1 确定影响因子

由表 1 知, 盾构隧道地表最大沉降的影响因素具有 14 维, 属于高维数组, 为避免模型学习速度慢、计算复杂、精度低等问题, 现利用 PCA 算法对 14 维影响参数进行数据降维, 设定累计贡献率大于 80% 的影响参数为主成分因子。运用 Matlab 编写程序代码, 经多次试验分析, 最终确定出了 5 个影响因子, 其提取后的变量特征值与累计贡献率如图 3 所示。

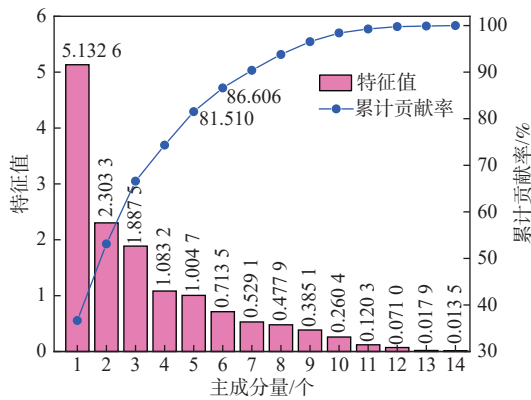


图 3 PCA 主成分提取变量

Fig. 3 PCA principal component extraction variables

由图 3 主成分提取变量结果可知, 前 5 个成分的累计贡献率分别为 36.661%、53.114%、66.596%、74.333%、81.510%, 到第 5 成分时累计贡献率达到了 81.510%, 大于 80%。因此, 在尽量减少信息损失的同时, 前 5 个成分能够较为全面地反映原始指标体系, 即能够将初始的 14 维变量数据降至 5 维, 并且由 5 个公因子表征出来。所得到的主成分系数矩阵如表 2 所示。

根据表 2 主成分系数矩阵, 赋予 $A_1 \sim A_{14}$ 相应权重, 得到重构后 $Z_1 \sim Z_5$ 的表达式, 如式(18)~(22)所示。

$$\begin{aligned}
 Z_1 = & 0.897A_1 + 0.937A_2 - 0.228A_3 - 0.271A_4 + 0.956A_5 \\
 & + 0.376A_6 + 0.683A_7 - 0.078A_8 - 0.474A_9 - 0.227A_{10} \\
 & - 0.809A_{11} - 0.790A_{12} - 0.201A_{13} - 0.445A_{14}
 \end{aligned}
 \tag{18}$$

表 2 主成分系数矩阵

Table 2 Principal component coefficient matrix

影响因子	主成分				
	1	2	3	4	5
A_1	0.897	0.023	0.086	0.077	0.052
A_2	0.937	-0.077	0.043	0.041	0.051
A_3	-0.228	0.586	0.376	-0.460	-0.163
A_4	-0.271	-0.259	-0.724	0.340	0.105
A_5	0.956	-0.068	-0.130	-0.007	-0.028
A_6	0.376	0.335	0.365	0.492	0.315
A_7	0.683	-0.093	-0.116	-0.520	0.060
A_8	-0.078	0.310	0.425	-0.053	0.748
A_9	-0.474	0.530	-0.582	0.019	0.216
A_{10}	-0.227	0.867	-0.247	0.123	-0.128
A_{11}	-0.809	-0.112	-0.056	-0.256	0.188
A_{12}	-0.790	-0.464	0.277	-0.071	0.080
A_{13}	-0.201	-0.636	0.046	0.019	0.247
A_{14}	-0.445	-0.011	0.622	0.384	-0.365

$$\begin{aligned}
 Z_2 = & 0.023A_1 - 0.077A_2 + 0.586A_3 - 0.259A_4 - 0.068A_5 \\
 & + 0.335A_6 - 0.093A_7 + 0.310A_8 + 0.530A_9 + 0.867A_{10} \\
 & - 0.112A_{11} - 0.464A_{12} - 0.636A_{13} - 0.011A_{14}
 \end{aligned}
 \tag{19}$$

$$\begin{aligned}
 Z_3 = & 0.086A_1 + 0.043A_2 + 0.376A_3 - 0.724A_4 - 0.130A_5 \\
 & + 0.365A_6 - 0.116A_7 + 0.425A_8 - 0.582A_9 - 0.247A_{10} \\
 & - 0.056A_{11} + 0.277A_{12} + 0.046A_{13} + 0.622A_{14}
 \end{aligned}
 \tag{20}$$

$$\begin{aligned}
 Z_4 = & 0.077A_1 + 0.041A_2 - 0.460A_3 + 0.340A_4 - 0.007A_5 \\
 & + 0.492A_6 - 0.520A_7 - 0.053A_8 + 0.019A_9 + 0.123A_{10} \\
 & - 0.256A_{11} - 0.071A_{12} + 0.019A_{13} + 0.384A_{14}
 \end{aligned}
 \tag{21}$$

$$\begin{aligned}
 Z_5 = & 0.052A_1 + 0.051A_2 - 0.163A_3 + 0.105A_4 - 0.028A_5 \\
 & + 0.315A_6 + 0.060A_7 + 0.748A_8 + 0.216A_9 - 0.128A_{10} \\
 & + 0.188A_{11} + 0.080A_{12} + 0.247A_{13} - 0.365A_{14}
 \end{aligned}
 \tag{22}$$

3.2 数据归一化

由表 1 可知, 数据集量纲不同, 需对数据进行标准化处理, 从而加快极限学习机模型的收敛, 并在训练过程中防止梯度爆炸。标准化处理算法将重构的 5 维主成分变量和地表最大沉降数据进行线性变换使其值域在 $[-1, 1]$ 附近。计算过程如下:

$$\tilde{x} = \frac{x - \mu}{\sigma}
 \tag{23}$$

式中: μ 、 σ ——输入数据某一维度的最小值及标准差;
 \tilde{x} ——标准化处理后的数据。

3.3 PCA-HHO-ELM 模型参数

为避免连续监测点位之间沉降差异较小, 导致

训练集沉降范围具有局限性, 现将 200 组经 PCA 算法降维的数据随机排列, 前 170 组用于模型训练(即训练集), 后 30 组用于模型性能测试(即测试集)。利用 HHO 算法对 ELM 的输入层权值和隐含层阈值参数进行寻优, 将得到的最优结果作为 ELM 的最优参数, 最大程度提高模型的预测性能。经反复试验, 将 HHO 种群大小设为 30, 最大迭代次数设为 100。

由前文知, Z_1-Z_5 作为模型输入且用于回归预测 ($S=1$), 故 ELM 输入层神经元和输出层神经元分别 5 和 1。选择 Sigmoid 函数作为激活函数 $g(x)$, 如式(24)所示。由式(24)知 $g(x)$ 无穷可微, 满足激活函数定义。根据 Kolomogorov 定理, SLFN 隐含层神经元不小于 $2K+1$, 即不小于 11 个。

$$g(x) = \frac{1}{1 + e^{-x}} \quad (24)$$

3.4 模型评价指标

为验证模型预测效果, 选用平均绝对误差(MAE)、均方根误差(RMSE)和决定系数(R^2)3个指标对模型进行评价。 $RMSE$ 弥补了 MSE 与目标变量量纲不一致的缺陷, MAE 避免了正负误差相抵消, R^2 用于评价模型与数据的相关性, R^2 的范围为 $[0,1]$, R^2 值越大, 模型拟合效果越好。具体公式如下:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m [h(x_i) - y_i]^2} \quad (25)$$

$$MAE = \left| \frac{1}{m} \sum_{i=1}^m [h(x_i) - y_i] \right| \quad (26)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m [y_i - h(x_i)]^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (27)$$

式中: m ——样本总数;

$h(x_i)$ ——模型的预测沉降值;

y_i ——实测沉降值;

\bar{y} ——实测沉降数据的平均值。

4 预测结果分析

4.1 模型预测性能分析

经反复试验, 将隐含层节点数设为 20, 预测效果较好。在 PCA-HHO-ELM 模型仿真训练后, 对 30 组测试样本进行测试, 训练及测试结果如图 4 所示。

从图 4(a)中可看出, 训练集数据点基本分布在理想拟合直线附近, 训练样本的 R^2 为 0.941 9、 $RMSE$ 为

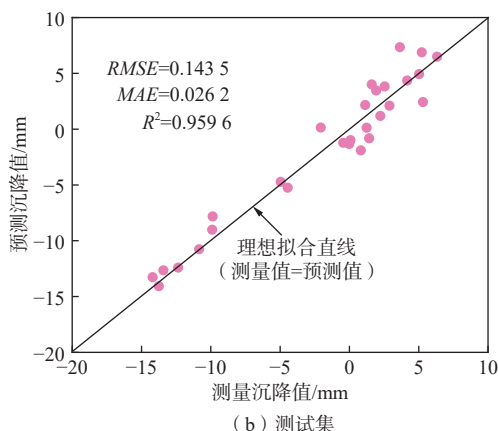
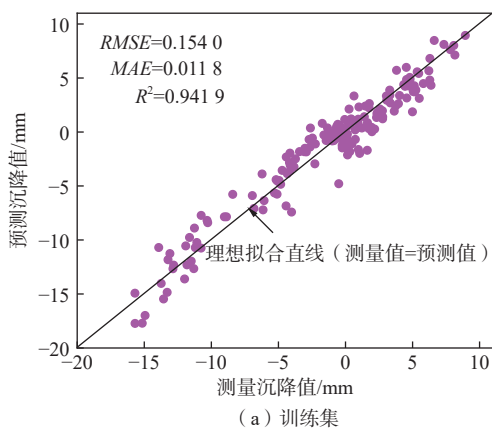


图 4 PCA-HHO-ELM 模型预测结果

Fig. 4 Prediction results of PCA-HHO-ELM model

0.154 0、 MAE 为 0.011 8, 这说明 PCA-HHO-ELM 模型的预测值与实测值基本一致, 模型训练效果较好。从图 4(b)中可看出, 测试样本数据点同样集中分布于理想拟合直线附近, 其 R^2 为 0.959 6、 $RMSE$ 为 0.143 5、 MAE 为 0.026 2, 这说明 PCA-HHO-ELM 模型具有很好的学习与预测能力, 能够有效预测盾构隧道地表最大沉降。

4.2 对比分析

为进一步验证 PCA-HHO-ELM 模型的泛化能力, 在同等试验条件下将未优化的 ELM 模型、BP 神经网络模型和 RBF 模型与 PCA-HHO-ELM 模型进行多次试验分析对比, 对比结果如图 5 所示。

从图 5 预测曲线可知, 4 种预测模型的预测值与实测值整体上变化趋势一致, 均能在一定程度上对盾构隧道地表最大沉降进行可靠预测, 但在局部区域, PCA-HHO-ELM 模型的预测结果较其他 3 种算法更接近地表沉降实测值, 其预测值与实测值咬合得更加紧密。相较于 RBF、ELM 模型, BP 神经网络模型同样具有较高的可靠性。将 4 类模型预测结果(表 3)带入式




图 5 各模型预测结果对比

Fig. 5 Comparison of prediction results of various models

(22)–(24), 得到各模型的预测性能指标, 其结果如表 4 所示。

从表 4 中可看出, 本文提出的 PCA-HHO-ELM 模型的 5 项评价指标基本优于其余 3 种预测模型, 仅平均误差略大于 BP 模型, 其 *RMSE* 与 *MAE* 分别为 0.143 5 和 0.026 2, 说明该模型更为接近实际沉降值且误差最小, R^2 高达 0.959 6, 说明预测值与实测值拟合效果较好, 可靠性较高。4 种模型的 *RMSE* 和 *MAE* 尽管都很小, 但是 ELM 模型误差是本文模型的近 4 倍, 经 HHO 优化后, PCA-HHO-ELM 模型的单样本最大误差值和平均误差均小于未优化的 ELM 模型, 决定系数也从 0.359 2 提升至 0.959 6, 其预测效果较好。综上所述, 4 类预测模型预测效果为: PCA-HHO-ELM 模型 > BP 模型 > RBF 模型 > ELM 模型, HHO 算法能够提高 ELM 的预测精度, PCA-HHO-ELM 模型具有更强的泛化能力。

表 3 4 类模型预测结果

Table 3 Prediction results of four types of models

组号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
实测值/mm	2.89	9.86	5.03	4.45	2.07	10.44	0.82	3.64	0.44	13.42	9.69	4.96	2.54	1.93	1.43
BP 预测值/mm	1.62	-8.49	3.61	-8.92	-0.56	12.08	-0.97	3.51	0.12	-13.78	10.10	-3.74	2.53	2.24	0.70
RBF 预测值/mm	5.04	0.49	2.12	2.00	-2.86	2.81	0.31	4.48	0.50	-11.03	5.07	-11.39	2.03	2.01	0.50
ELM 预测值/mm	-0.24	-6.17	4.21	0.11	-0.94	12.90	0.27	-0.51	-1.51	-11.13	11.95	-4.05	2.63	2.12	0.26
PCA-HHO-ELM 预测值/mm	2.11	-7.83	4.93	-5.25	0.14	9.38	-1.90	7.34	-1.23	-12.66	12.93	-4.72	3.83	3.46	-0.82

组号	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
实测值/mm	0.01	6.33	5.22	14.19	13.74	1.14	4.17	5.31	1.61	0.08	9.90	1.24	10.84	2.24	12.35
BP 预测值/mm	-0.06	4.85	4.89	-14.13	-14.25	0.49	4.10	5.93	1.73	-0.05	-9.73	-0.01	-10.46	1.30	-11.83
RBF 预测值/mm	0.50	3.59	2.56	-11.32	-7.45	0.50	4.47	5.07	0.50	0.50	-9.67	0.50	-8.02	0.58	-7.45
ELM 预测值/mm	-0.53	5.72	5.79	-11.76	-15.91	1.34	2.90	5.71	1.65	-0.58	-9.78	0.70	-8.43	-0.12	-14.09
PCA-HHO-ELM 预测值/mm	-1.33	6.50	6.89	-13.27	-14.07	2.16	4.35	2.43	4.00	-0.99	-9.01	0.13	-10.76	1.18	-12.41

表 4 模型性能评价结果

Table 4 Performance evaluation results of the model

评价指标	<i>RMSE</i>	<i>MAE</i>	R^2	最大误差/mm	平均误差/mm
PCA-HHO-ELM 模型	0.143 5	0.026 2	0.959 6	3.70	1.29
BP 预测模型	0.232 3	0.042 4	0.894 3	4.48	0.82
RBF 模型	0.392 1	0.071 6	0.698 6	10.35	2.52
ELM 预测模型	0.571 8	0.104 4	0.359 2	4.56	1.48

5 结论

(1) 利用 PCA 算法进行数据降维, 在尽量减少信息损失的同时, 将原始 14 维影响参数降至 5 维, 根据主成分系数矩阵重构主成分变量, 将得到的主成分变量作为模型输入, 简化了 ELM 模型的网络拓扑结构, 从而减少所需优化的权值和阈值个数。

(2) 利用 PCA-HHO-ELM 模型进行盾构沉降预测, 训练集及测试集数据点基本分布在理想拟合直线附

近, 模型预测效果较好。PCA-HHO-ELM 预测模型的各项评价指标基本均优于 BP 神经网络模型、RBF 模型和 ELM 模型。

(3) 经 HHO 算法优化后, ELM 模型精度显著提高, R^2 从 0.359 2 提升至 0.959 6, 其单样本最大误差和平均误差也得到相应改善。PCA-HHO-ELM 模型在一定程度上提高了盾构沉降预测效果, 使其具有更优的泛化性能, 可为类似隧道工程提供一种更为可行的新思路。

参考文献 (References) :

- [1] 胡群芳, 李敏, 王飞. 我国城市地铁隧道盾构施工刀具磨损性分区研究 [J]. 现代隧道技术, 2016, 53(2): 26 - 34. [HU Qunfang, LI Min, WANG Fei. Research on regionalization of cutting-tool wear conditions in shield tunnels of urban subways in China[J]. Modern Tunnelling Technology, 2016, 53(2): 26 - 34. (in Chinese with English abstract)]
- [2] 路德春, 马一丁, 王国盛. 近接隧道列车运行时地表振动响应数值模拟 [J]. 吉林大学学报(地球科学版), 2021, 51(5): 1452 - 1462. [LU Dechun, MA Yiding, WANG Guosheng. Numerical study on ground surface vibration response under train load in multi adjacent tunnels[J]. Journal of Jilin University (Earth Science Edition), 2021, 51(5): 1452 - 1462. (in Chinese with English abstract)]
- [3] XU Qianwei, ZHU Hehua, MA Xianfeng, et al. A case history of shield tunnel crossing through group pile foundation of a road bridge with pile underpinning technologies in Shanghai[J]. *Tunnelling and Underground Space Technology*, 2015, 45: 20 - 33.
- [4] 蒋彪, 皮圣, 阳军生, 等. 长沙地铁典型地层盾构施工地表沉降分析与预测 [J]. 地下空间与工程学报, 2016, 12(1): 181 - 187. [JIANG Biao, PI Sheng, YANG Junsheng, et al. Analysis and prediction of ground surface settlements due to EPB shield tunneling of Changsha metro[J]. Chinese Journal of Underground Space and Engineering, 2016, 12(1): 181 - 187. (in Chinese with English abstract)]
- [5] PARK K H. Analytical solution for tunnelling-induced ground movement in clays[J]. *Tunnelling and Underground Space Technology*, 2005, 20(3): 249 - 261.
- [6] 赖文杰, 齐昌广, 郑金辉, 等. 含分数阶的灰色模型及其在地基沉降预测中的应用 [J]. 水文地质工程地质, 2019, 46(3): 124 - 128. [LAI Wenjie, QI Changguang, ZHENG Jinhui, et al. Gray model with fractional order and its application to settlement prediction[J]. Hydrogeology & Engineering Geology, 2019, 46(3): 124 - 128. (in Chinese with English abstract)]
- [7] 郭社军, 郝晓龙, 舒国明. Peck 公式在小半径曲线隧道沉降分析的应用 [J]. 公路, 2020, 65(8): 405 - 408. [GUO Shejun, HAO Xiaolong, SHU Guoming. Application of Peck formula in settlement analysis of small radius curved tunnel[J]. Highway, 2020, 65(8): 405 - 408. (in Chinese).]
- [8] PECK R B. Deep excavations and tunneling in soft ground[C]//Mexico: Proceeding of 7th ICSMFE, 1969: 225 - 290.
- [9] 范珊珊, 郭海朋, 朱菊艳, 等. 线性回归模型在北京平原地面沉降预测中的应用 [J]. 中国地质灾害与防治学报, 2013, 24(1): 70 - 74. [FAN Shanshan, GUO Haipeng, ZHU Juyan, et al. Application of linear regression model for land subsidence prediction in Beijing plain[J]. The Chinese Journal of Geological Hazard and Control, 2013, 24(1): 70 - 74. (in Chinese with English abstract)]
- [10] KIM C Y, BAE G J, HONG S W, et al. Neural network based prediction of ground surface settlements due to tunnelling[J]. *Computers and Geotechnics*, 2001, 28(6/7): 517 - 547.
- [11] DIAS D, KASTNER R. Movements caused by the excavation of tunnels using face pressurized shields: Analysis of monitoring and numerical modeling results[J]. *Engineering Geology*, 2013, 152(1): 17 - 25.
- [12] 于德海, 舒娇娇, 秦凯凯. 盾构地铁隧道穿越既有铁路桥的沉降分析 [J]. 水文地质工程地质, 2020, 47(2): 148 - 152. [YU Dehai, SHU Jiaojiao, QIN Kaikai. An analysis of the settlement of a shield tunnel passing under the operating railway bridge[J]. Hydrogeology & Engineering Geology, 2020, 47(2): 148 - 152. (in Chinese with English abstract)]
- [13] 潘涛. 软土地区双线区间盾构隧道施工对周边地表以及建筑物沉降的影响 [J]. 水文地质工程地质, 2022, 49(1): 101 - 108. [PAN Tao. Influences of double-track shield tunnel construction on settlements of adjacent ground and buildings in a soft soil area[J]. Hydrogeology & Engineering Geology, 2022, 49(1): 101 - 108. (in Chinese with English abstract)]
- [14] 徐明祥, 黄强兵, 王庆兵, 等. 西安地裂缝地段浅埋暗挖地铁隧道施工沉降规律 [J]. 水文地质工程地质, 2020, 47(1): 161 - 170. [XU Mingxiang, HUANG Qiangbing, WANG Qingbing, et al. Settlement rules of shallow-buried metro tunnel construction in the Xi'an ground fissure section[J]. Hydrogeology & Engineering Geology, 2020, 47(1): 161 - 170. (in Chinese with English abstract)]
- [15] ZHANG Pin, CHEN Renpeng, WU Huaina. Real-time analysis and regulation of EPB shield steering using Random Forest[J]. *Automation in Construction*, 2019, 106: 102860.
- [16] 赵楠, 李洁. 基于 LSTM-SVM 的隧道围岩位移预测 [J]. 公路, 2021, 66(6): 404 - 407. [ZHAO Nan, LI Jie. Displacement prediction of tunnel surrounding rock based on LSTM-SVM[J]. Highway, 2021, 66(6): 404 - 407.

- (in Chinese)]
- [17] 李建生, 阳军生, 杨铠, 等. 改进遗传算法在浅埋隧道施工倾斜地表沉降预测中的应用 [J]. 公路工程, 2008, 33(6): 46 – 49. [LI Jiansheng, YANG Junsheng, YANG Kai, et al. Application of improved genetic algorithm in prediction of inclined ground settlement in shallow tunnel construction[J]. Highway Engineering, 2008, 33(6): 46 – 49. (in Chinese)]
- [18] CHEN Rengpeng, ZHANG Pin, KANG Xin, 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.
- [19] 乔金丽, 范永利, 刘波, 等. 基于改进 BP 网络的盾构隧道开挖地表沉降预测 [J]. 地下空间与工程学报, 2012, 8(2): 352 – 357. [QIAO Jinli, FAN Yongli, LIU Bo, et al. Predicting the surface settlement by shield tunneling based on modified BP network[J]. Chinese Journal of Underground Space and Engineering, 2012, 8(2): 352 – 357. (in Chinese with English abstract)]
- [20] WANG Fan, GOU Biancai, QIN Yawei. Modeling tunneling-induced ground surface settlement development using a wavelet smooth relevance vector machine[J]. *Computers and Geotechnics*, 2013, 54: 125 – 132.
- [21] 陈仁朋, 戴田, 张品, 等. 基于机器学习算法的盾构掘进地表沉降预测方法 [J]. 湖南大学学报(自然科学版), 2021, 48(7): 111 – 118. [CHEN Rengpeng, DAI Tian, ZHANG Pin, et al. Prediction method of tunneling-induced ground settlement using machine learning algorithms[J]. Journal of Hunan University (Natural Sciences), 2021, 48(7): 111 – 118. (in Chinese with English abstract)]
- [22] 官思艺, 孔宪光, 刘丹, 等. 融入复杂地层动态识别的盾构施工地表沉降预测方法研究 [J]. 仪器仪表学报, 2019, 40(6): 228 – 236. [GONG Siyi, KONG Xianguang, LIU Dan, et al. An approach for predicting shield construction ground surface settlement of complex stratum using dynamical strata identification[J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 228 – 236. (in Chinese with English abstract)]
- [23] 林荣安, 孙钰丰, 戴振华, 等. 基于 RS-SVR 的上软下硬地层盾构施工地表沉降预测 [J]. 中国公路学报, 2018, 31(11): 130 – 137. [LIN Rongan, SUN Yufeng, DAI Zhenhua, et al. Predicting for ground surface settlement induced by shield tunneling in upper-soft and lower-hard ground based on RS-SVR[J]. China Journal of Highway and Transport, 2018, 31(11): 130 – 137. (in Chinese with English abstract)]
- [24] 李洛宾, 龚晓南, 甘晓露, 等. 基于循环神经网络的盾构隧道引发地面最大沉降预测 [J]. 土木工程学报, 2020, 53(增刊 1): 13 – 19. [LI Luobin, GONG Xiaonan, GAN Xiaolu, et al. Prediction of maximum ground settlement induced by shield tunneling based on recurrent neural network[J]. China Civil Engineering Journal, 2020, 53(Sup 1): 13 – 19. (in Chinese with English abstract)]
- [25] LIU Peng, LI Zhengtian, ZHUO Yixin, et al. Design of wind turbine dynamic trip-off risk alarming mechanism for large-scale wind farms[J]. *IEEE Transactions on Sustainable Energy*, 2017, 8(4): 1668 – 1678.
- [26] TANG Jiexiong, DENG Chenwei, HUANG Guangbin. Extreme learning machine for multilayer perceptron[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(4): 809 – 821.
- [27] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: A new learning scheme of feedforward neural networks[C]//Budapest, Hungary: 2004 IEEE International Joint Conference on Neural Networks, 2005: 985 – 990.
- [28] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris Hawks optimization: Algorithm and applications[J]. *Future Generation Computer Systems*, 2019, 97: 849 – 872.
- [29] BOUAYAD D, EMERIAULT F. Modeling the relationship between ground surface settlements induced by shield tunneling and the operational and geological parameters based on the hybrid PCA/ANFIS method[J]. *Tunnelling and Underground Space Technology*, 2017, 68: 142 – 152.
- [30] BOUYEYRON C, LATOUCHE P, MATTEI P A. Exact dimensionality selection for Bayesian PCA[J]. *Scandinavian Journal of Statistics*, 2020, 47(1): 196 – 211.
- [31] 苗凤娟, 孙同日, 陶佰睿, 等. PSO 与 PCA 融合优化核极限学习机说话人识别算法仿真 [J]. 科学技术与工程, 2019, 19(21): 195 – 199. [MIAO Fengjuan, SUN Tongri, TAO Bairui, et al. Algorithmic research on kernel extreme learning machine for speaker recognition based on PSO and PCA optimization[J]. *Science Technology and Engineering*, 2019, 19(21): 195 – 199. (in Chinese with English abstract)]