

李达,沈军宏,陈义源,等.基于数据驱动的双护盾TBM施工参数优化[J].辽宁工程技术大学学报(自然科学版),2026,45(4):445-451.DOI:10.11956/j.issn.1008-0562.20260049

Li Da,Shen Junhong,Chen Yiyuan,et al.Optimization of construction parameters of double shield TBM based on data-driven method [J].Journal of Liaoning Technical University (Natural Science),2026,45(4):445-451.DOI:10.11956/j.issn.1008-0562.20260049

基于数据驱动的双护盾TBM施工参数优化

李 达, 沈军宏, 陈义源, 王阜昊

(河南科技大学 土木建筑学院, 河南 洛阳 471023)

摘 要: 为解决双护盾隧道掘进机在复杂地质条件下施工时, 隧道变形控制与掘进效率提升之间的内在矛盾, 融合分类提升 (CatBoost)、极端梯度提升 (XGBoost), 以及序列最小二乘二次规划 (SLSQP) 算法, 构建一种基于数据驱动的双护盾TBM掘进参数优化模型。CatBoost作为核心算法用于精准预测隧道变形, XGBoost用于建立TBM参数间的非线性映射关系, SLSQP算法在约束条件下优化掘进参数。依托四川某山地轨道交通项目的实际数据, 进行模型构建与预测。研究结果表明: CatBoost变形预测模型的 R^2 为0.923, MSE为0.023, 预测效果较好; 优化后推进速度较优化前平均提高17.6%, 变形预测值基本维持在原始水平附近, 变化率控制在3.45%以下; 该模型在控制隧道变形不超过安全阈值的前提下, 显著提升推进效率。研究结论为TBM的施工决策提供参考。

关键词: 双护盾TBM; 机器学习; 施工参数优化; 隧道变形控制; CatBoost模型

中图分类号: U455

文献标志码: A

文章编号: 1008-0562(2026)04-0445-07

Optimization of construction parameters of double shield TBM based on data-driven method

Li Da, Shen Junhong, Chen Yiyuan, Wang Fuhao

(School of Civil Engineering and Architecture, Henan University of Science and Technology, Luoyang 471023, China)

Abstract: In order to solve the internal contradiction between tunnel deformation control and tunneling efficiency improvement when the double shield tunnel boring machine operate under complex geological conditions, this study proposes a data-driven optimization model to optimize TBM tunneling parameters. The model integrates CatBoost, XGBoost and sequential least squares quadratic programming (SLSQP) algorithm. CatBoost servers as the core algorithm to accurately predict tunnel deformation. XGBoost captures the nonlinear mapping relationship between TBM parameters, and the SLSQP algorithm optimizes tunneling parameters under constraints. The proposed mode was developed and validated using field data of a mountain rail transit project in Sichuan, China. The results show that the R^2 of the CatBoost deformation prediction model is 0.923, the MSE is 0.023, and the prediction result is better. After optimization, the average propulsion speed is increased by 17.6% compared with that before optimization, the predicted deformation value is basically maintained near the original level, and the change rate is controlled below 3.45%. The model significantly improves the propulsion efficiency under the premise that the tunnel deformation does not exceed the safety threshold. The research conclusions provide reference for TBM construction decision-making.

Keywords: double shield TBM; machine learning; construction parameter optimization; tunnel deformation control; CatBoost model

0 引言

双护盾隧道掘进机 (TBM) 对复杂地质条件

适应性强且支护效率高, 已成为山岭隧道及深埋地下工程中的关键施工装备^[1-2]。由于其对地质条件和操作参数较为敏感^[3-4], 若施工参数设置不合

收稿日期: 2026-01-26 修回日期: 2026-04-09 接受日期: 2026-04-14 责任编辑: 朱含露

基金项目: 盾构及掘进国家重点实验室开放课题 (SKLST-2024-01); 河南省科技攻关项目 (242102220037)

作者简介: 李 达 (1983-), 男, 河南 洛阳人, 博士, 教授, 主要从事岩土及地下工程理论和不良地质灾害治理方面的研究。

E-mail: 9905639@haust.edu.cn

理, 极易引发围岩过度变形、护盾卡滞等问题, 严重影响施工安全与进度。因此, 如何实现围岩变形的准确预测以及掘进参数的动态优化, 已成为双护盾 TBM 智能化施工的关键问题。

学者围绕隧道变形预测与掘进参数优化开展了诸多研究。在变形预测方面, 基于力学原理构建数字模拟模型开展预测, 虽机理明确但依赖地质参数与本构模型, 计算成本较高^[5-6]。经验公式法则存在模型参数确定困难、工况适应性有限等问题^[7-8]。近年来, 以机器学习为代表的驱动方法发展迅速, 但多依赖于高质量、大规模的标注数据, 且模型在复杂多变地质条件下的可解释性与泛化能力不足^[9-10]。在参数优化方面, 彭继慎等^[11]基于支持向量机 (SVM) 算法对 TBM 速度进行精确预测。Zhang 等^[12]通过融合卷积神经网络 (CNN) 和长短期记忆网络 (LSTM) 对隧道中软岩大变形进行风险分类、评估与预警。徐飞等^[13]构建一种基于目标检测 (YOLO-B) 算法的隧道衬砌渗漏水检测方法。陈礼博等^[14]融合梯度增强 (CatBoost) 模型与非支配排序遗传 (NSGA-III) 算法对隧道施工参数进行优化控制。傅蕾等^[15]基于随机森林算法和为多目标粒子群优化 (MOPSO) 算法预测盾构隧道掘进引起的沉降, 并对施工参数进行优化。Bo 等^[16]集成粒子群优化 (PSO) 算法与极端梯度提升 (XGBoost) 算法对隧道变形及 TBM 卡机进行预测分析。在隧道领域的研究中, 人工智能技术的应用已从单一的参数预测, 逐步转向预测、优化、决策的融合研究。相关研究涵盖基于深度学习的高精度预测、基于进化算法的参数搜索, 以及基于强化学习的控制等^[17-18]。

现有研究在隧道变形预测与掘进参数优化方面取得了显著进展, 但如何平衡高复杂性模型与实时性需求之间的矛盾, 以及如何在复杂环境中协调效率、质量与成本的关系, 仍有待进一步研究。因此, 作者以四川某山地轨道交通项目为工程背景, 提出一种融合分类提升 (categorical boosting, CatBoost)^[19]、极端梯度提升 (extreme gradient boosting, XGBoost)^[20]与序列最小二乘二次规划 (sequential least squares quadratic programming, SLSQP) 算法的双护盾 TBM 施工参数优化模型, 用以实现隧道变形预测、操作参数间的非线性映射以及约束条件下的参数优化, 并验证所提模型的工程有效性。

1 问题建模与模型原理

为在满足变形要求的前提下提升 TBM 掘进效率, 通过分析施工过程中对隧道最大累计变形影

响较大的特征, 最终选取刀盘速度 x_1 、总推进力 x_2 、后配套皮带机速度 x_3 、刀盘扭矩 x_4 , 以及推进速度 x_5 进行优化分析。其中刀盘速度、总推进力、后配套皮带机速度为操作参数, 可直接基于其取值范围随机设置, 而刀盘扭矩和推进速度为响应参数, 需要进行参数映射。

基于此, 本文以机器性能限制和隧道变形阈值为约束, 以推进速度最大化为目标, 采用分层设计, 融合机器学习模型与数学优化算法, 构建双护盾 TBM 施工参数优化模型, 模型组成见图 1。




图 1 模型组成

Fig.1 Model structure

1.1 参数映射模块

为保证模型精度, 针对 x_4 、 x_5 两个响应参数分别使用两个 XGBoost 模型进行映射, 预测函数为

$$\begin{cases} \hat{x}_4 = \sum_{k=1}^K \omega_{4k} f_k(X') \\ \hat{x}_5 = \sum_{k=1}^K \omega_{5k} g_k(X') \end{cases}, \quad (1)$$

式中: $X' = (x_1, x_2, x_3)^T$; K 为集成树总数; ω_{4k} 、 ω_{5k} 分别为 x_4 、 x_5 预测模型中第 k 棵树的权重; $f_k = (\cdot)$ 、 $g_k = (\cdot)$ 分别为两组模型中第 k 棵回归树。

1.2 变形预测模块

变形预测模块采用 CatBoost 模型作为核心预测器, 预测隧道最大变形值, 并将该变形值作为优化过程中的关键安全约束指标。CatBoost 回归模型的预测值为对称树的加权和, 其表达式为

$$F_M(X_i^j) = \sum_{m=1}^M \eta \cdot h_m(X_i^j), \quad (2)$$

式中: M 为基学习器总量; η 为学习率; $h_m(\cdot)$ 为第 m 棵对称树; X_i^j 为输入特征集, 其构造形式为 $X_i^j = ((x_1^1, \dots, x_1^{11}), \dots, (x_5^1, \dots, x_5^{11}))^T$, 下标 $i=1, 2, \dots, 5$ 对应 5 类决策特征, 分别为刀盘速度、总推进力、后配

套皮带机速度、刀盘转矩以及推进速度,上标 $j=1, 2, \dots, 11$ 代表各个决策特征的数学统计特征,分别对应均值、标准差、方差、最小值、25%分位数、中位数、75%分位数、最大值、偏度、峰度、变异系数。

1.3 参数优化模块

参数优化模块采用SLSQP算法,在满足变形要求的前提下,通过调节待优化特征 $x_1 \sim x_5$ 使推进速度最大化。

优化过程中需统筹三类关键约束问题。其一, $x_1 \sim x_5$ 中包含无法由优化算法直接生成的响应参数,需构建XGBoost响应参数映射模型完成参数换算。其二,按照TBM基本使用参数限制划定5个待优化参数的响应范围,构成硬约束,并在数值求解代码中固定各参数上下界,引入边界惩罚项实现区间限制。其三,将围岩变形控制阈值设置为软约束条件,在目标函数中引入沉降超限惩罚项加以限制。为适配标准求解器,将最大化问题转换为最小化问题,最终构建目标函数为

$$f(\mathbf{X}_i^j) = -v(\mathbf{X}_i^j) + \lambda_1 \max(0, u_{X_i^j} - u_{\max})^2 + \lambda_2 \sum_{i=1}^5 \max(0, |x - x_{i,b}|)^2, \quad (3)$$

式中: $v(\mathbf{X}_i^j)$ 为推进速度; $u_{X_i^j}$ 为基于决策变量的隧道变形预测值; λ_1 、 λ_2 为惩罚系数,通过调整惩罚系数可平衡目标函数与约束条件的权重; $x_{i,b}$ 为优化问题中第 i 个决策变量的边界; $u_{\max}$ 为隧道围岩允许最大变形阈值。

具体优化流程见图2。




图2 优化流程

Fig.2 Optimization process

在优化前,训练并加载XGBoost参数映射模型和CatBoost变形预测模型。优化开始后,设定变形阈值、参数边界值。采用SLSQP算法生成 $x_1 \sim x_5$ 的预选值,基于 $x_1 \sim x_5$ 的预选值利用XGBoost参数映射模型映射出 x_4 、 x_5 ,从而构建完整的特征向量。由CatBoost模型预测隧道变形量。

2 数据库构建与模型实现

2.1 工程概况


本文数据来源于四川某山地轨道交通项目。隧址区位于川西高原东部、邛崃山脉北段,属四川盆地向川西高原的过渡地带,地貌类型为深切高山峡谷区,地面高程为2 750~4 300 m。该隧道为傍山隧道,左右分修。研究使用的数据来自DYK101+706.36~DYK102+532.6段,该段主要穿越三叠系中统杂谷组(T2z)地层,岩性为变质砂岩夹板岩、灰岩。

工程采用双护盾全断面岩石隧道掘进机,其开挖直径为6.48 m,主机长度约12 m,整机长度约194 m,总质量约1 000 t,推进速度为0~100 mm/min。待优化参数的额定取值范围见表1。

表1 待优化参数的取值范围
Tab.1 Range of parameters to be optimized

参数	取值范围
刀盘转矩 $x_1/(\text{kN}\cdot\text{m})$	0~8 080
刀盘速度 $x_2/(\text{r}\cdot\text{min}^{-1})$	0~10
后配套皮带机速度 $x_3/(\text{m}\cdot\text{s}^{-1})$	0~100
总推进力 x_4/kN	0~20 000
推进速度 $x_5/(\text{mm}\cdot\text{min}^{-1})$	0~100

经掘进段提取与异常值剔除处理后,部分待优化TBM运行数据见图3。隧道围岩变形数据主要源自项目监测周报,DYK101+690断面的监测数据见图4。



(a) 刀盘转矩




图3 部分TBM运行数据

Fig.3 Partial TBM operational data




图4 DY1K101+690断面隧道围岩变形

Fig.4 Tunnel deformation of DY1K101+690 section

2.2 数据库构建

为训练 XGBoost 参数映射模块和 CatBoost 变形预测模块,构建对应的数据库。

XGBoost 数据库中,原始 TBM 传感器数据包含非掘进段数据和异常数据。采用二值判别法识别并剔除刀盘转速与总推进力同时为 0 的数据。采用箱线图法进行识别与剔除异常数据,按环段编号将经过处理的数据与特征 $x_1 \sim x_5$ 对齐。

CatBoost 数据库的输入特征为 $x_1 \sim x_5$, 其中,输入数据为 TBM 传感器数据,记录频率为每分钟 1 次。变形数据为人工记录数据,如图 4 所示,且仅取最大累计变形值。由于两类数据在时间与频率上不一致,构建过程中需要进行对齐处理。此外,在 TBM 掘进过程中,随着监测断面处围岩的缓慢卸载,隧道变形逐渐增大;当 TBM 掘进至 5 倍洞径后,卸载对隧道变形的影响基本消失。因此,选取监测断面前 5 倍洞径范围内的 $x_1 \sim x_5$ 数据,以 11 维数学统计值代替原始的 n 维时序数据,再将该统计值与该断面的最大累计变形值进行对齐,构建完整的 CatBoost 数据集。

2.3 超参数寻优

为提升模型性能并避免过拟合,采用贝叶斯优化对 CatBoost 模型的超参数进行自动搜索,优化目标为最小化验证集上的均方误差 (MSE)。搜索空间涵盖学习率、树深度、L2 叶节点正则化系数、随机强度等关键参数,并允许迭代次数动态调整,同时配合早停机制,以避免不必要的训练。优化过程在独立划分的训练集与验证集上进行,最终模型在保留的测试集上完成无偏评估。优化过程的收敛曲线见图 5。




图 5 优化过程收敛曲线

Fig.5 Convergence curve of the optimization process

由图 5 可知，优化过程呈现明显的阶梯式收敛特征：前 5 次迭代中，MSE 从 0.036 mm² 降至 0.031 mm² 左右；第 5 至第 15 次迭代期间进入平台期，性能基本保持稳定；从第 16 次迭代开始，曲线再次小幅降低并稳定于 0.029 mm² 附近，此后直至第 30 次迭代无明显改善。综合考虑计算效率与优化效果，将最大迭代次数设为 30 次。经 30 次贝叶斯优化搜索得到的最优超参数详见表 2。

表 2 优化后的超参数取值 Tab.2 Optimized hyperparameter values	
超参数	优化值
随机强度	1
学习率	0.05
早停	30
L2 叶节点正则化系数	3
迭代次数	500
树生长策略	对称树
树的最大深度	4
特征分割边界数量	32
Bootstrap 温度参数	0

3 应用及结果分析

为评估所构建模型的预测精度与性能，选取决定系数 R^2 、均方误差 MSE、均方根误差 RMSE，以及平均绝对误差 MAE，对模型的拟合效果与预测偏差进行综合度量。

3.1 模型训练结果

为保证 XGBoost 参数映射模型的精度，针对两个响应特征分别构建基于贝叶斯优化的预测模型。使用 2.2 节的 XGBoost 数据集对模型进行训练，结果见图 6。




图 6 XGBoost 模型预测值与实测值对比

Fig.6 Comparison between measured values and predicted values by the XGBoost model

由图 6 可见，整体散点聚集在预测值与实测值等值参考线附近，二者契合度较高。其中，刀盘扭矩的 R^2 、RMSE、MAE 分别为 0.88、202.12 kN·m、127.52 kN·m，推进速度的 R^2 、RMSE、MAE 分别为 0.86、3.75 mm/min、5.88 mm/min，表明所构建的 XGBoost 模型拟合能力良好。

将 2.2 节构造的 CatBoost 数据集按 6 : 2 : 2 的比例划分为训练集、测试集和验证集，采用前文寻优得到的超参数组合完成模型训练并保存训练好的模型，结果见图 7。经量化计算，CatBoost 模型的 R^2 、MSE、RMSE、MAE 分别为 0.923、0.023 mm²、0.151 mm、0.090 mm，说明该模型预测精度较高。




图 7 CatBoost 模型预测值与真实值对比

Fig.7 Comparison of predicted and true values of the CatBoost model

3.2 特征重要性分析

模型特征重要性的量化结果见图 8。从 TBM 检测特征的角度可知,“刀盘速度”和“推进速度平均值”两个参数对结果的影响较大;从统计特征的角度可知,对结果影响较大的是方差、标准差等体现参数波动性的特征。




图 8 模型特征重要度量化分布

Fig.8 Quantified distribution of feature importance for the model

上述分析表明,隧道围岩变形是围岩在施工动态扰动下应力状态演化的宏观表现。其中,刀盘速度的波动主要关联于围岩扰动与松动压力的发展,推进速度的波动则主要关联于掌子面约束作用的有效性,二者共同作用于围岩的应力路径,进而影响变形的大小。因此,在进行 TBM 操作参数的优化时,不仅要关注最佳参数的选取,还必须将关键操作参数的波动性作为核心约束指标加以优化。

3.3 优化结果分析

采用 SLSQP 算法对构建的 TBM 掘进参数优化模型开展数值求解,选取 5 组工程实际数据进行寻优,各组样本的优化结果见表 3。

表 3 优化前后施工参数与围岩变形指标对比
Tab.3 Comparison of construction parameters and surrounding rock deformation indexes before and after optimization

序号	推进速度/(mm·min ⁻¹)		隧道围岩最大累计变形/mm	
	优化前	优化后	优化前	优化后
1	36.73	39.04	2.46	2.47
2	47.76	66.65	2.90	2.80
3	50.81	62.18	2.65	2.61
4	32.51	34.91	2.54	2.56
5	42.20	47.31	2.78	2.86

由表 3 可知,优化后 TBM 掘进推进速度较优化前提高 6.3%~39.6%,平均提高 17.6%。优化后隧道围岩最大累计变形量的变化率均在 3.45% 以下,其中 60% 样本的变形量小幅下降,剩余 40%

样本变形量微幅上升但均未超出安全阈值,验证了所构建优化框架的工程有效性。

4 结论

(1) CatBoost 隧道变形预测模型的决定系数 R^2 达 0.923,预测精度高;XGBoost 参数映射模型亦表现出良好的拟合能力 (R^2 分别为 0.88 和 0.86),为优化过程提供了准确的关键参数映射关系。

(2) 特征重要性分析表明,刀盘速度和推进速度平均值的统计波动性变量(如方差、标准差)对变形预测有一定影响,提示施工中不仅需关注参数设定值,更应控制其运行稳定性。

(3) 分析 5 组实际工程数据,结果显示优化后 TBM 掘进推进速度较优化前平均提升 17.6%,最高提升达 39.6%。基于优化后操作参数的变形预测值基本维持在原始水平附近,变化率控制在 3.45% 以内,表明构建的模型有效平衡了施工安全与掘进效率。

(4) 本文所提模型未显式引入地质参数,主要基于 TBM 运行数据构建,但 TBM 运行参数本质上是岩机耦合作用的综合响应,其变化特征在一定程度上间接反映围岩条件,未来研究将进一步结合地质参数以提升模型对复杂地质环境的泛化性。

参考文献(References):

[1] 王述红,杨润生,董福瑞,等. 基于 WOA-BP 神经网络的盾构地铁隧道拱顶沉降预测[J]. 应用基础与工程科学学报, 2025, 33(3): 770-778.
Wang Shuhong, Yang Runsheng, Dong Furui, et al. Prediction of settlement of shield tunnel subway tunnel roof based on WOA-BP neural network[J]. Journal of Basic Science and Engineering, 2025, 33(3): 770-778.

[2] Chen H Y, Liu J, Shen G Q, et al. Control of existing tunnel deformation caused by shield adjacent undercrossing construction using interpretable machine learning and multiobjective optimization[J]. Automation in Construction, 2025, 170: 105943.

[3] 王平安. 基于 IAO-SVM 的软岩隧道变形预测模型[J]. 铁道建筑技术, 2024(8): 93-96, 144.
Wang Ping'an. Deformation prediction model for soft rock tunnels based on IAO-SVM[J]. Railway Construction Technology, 2024(8): 93-96, 144.

[4] Liu W L, Li A, Liu C J. Multi-objective optimization control for tunnel boring machine performance improvement under uncertainty [J]. Automation in Construction, 2022, 139: 104310.

[5] 翁效林,李世鑫,杨晓东,等. 基于最优赋权-可拓云模型的缓倾围岩隧道底部变形风险综合评价[J]. 辽宁工程技术大学学报(自然科学版), 2023, 42(6): 656-663.
Weng Xiaolin, Li Shixin, Yang Xiaodong, et al. Comprehensive

- evaluation of flat rock tunnel bottom deformation risk based on optimal weighting-extension cloud model[J]. Journal of Liaoning Technical University (Natural Science), 2023, 42(6): 656-663.
- [6] 郭新新, 汪波, 王振宇, 等. 考虑蠕变特性的高应力软岩隧道变形预测方法与实践[J]. 岩土工程学报, 2023, 45(3): 652-660.
- Guo Xinxin, Wang Bo, Wang Zhenyu, et al. Methods and practices for deformation prediction in high-stress soft rock tunnels considering creep characteristics[J]. Chinese Journal of Geotechnical Engineering, 2023, 45(3): 652-660.
- [7] 李金奎, 庄文. 城市隧道同时侧穿桩基和下穿既有隧道变形分析[J]. 辽宁工程技术大学学报(自然科学版), 2023, 42(6): 664-670.
- Li Jinkui, Zhuang Wen. Analysis of deformation of power tunnel passing through pile foundation and underneath at the same time[J]. Journal of Liaoning Technical University (Natural Science), 2023, 42(6): 664-670.
- [8] 宋洋, 常泳涛, 李永启, 等. 小净距隧道洞口段围岩变形与坡体稳定性分析[J]. 辽宁工程技术大学学报(自然科学版), 2020, 39(1): 24-33.
- Song Yang, Chang Yongtao, Li Yongqi, et al. Analysis of surrounding rock deformation and slope stability of tunnel section in small clear distance tunnel[J]. Journal of Liaoning Technical University (Natural Science), 2020, 39(1): 24-33.
- [9] 王天宁, 王利宁, 薛亚东, 等. 山岭隧道收敛变形无线感知及预测方法[J]. 岩土工程学报, 2020, 42(增刊1): 224-228.
- Wang Tianning, Wang Lining, Xue Yadong, et al. Wireless sensing and prediction method for convergence deformation of mountain tunnels[J]. Chinese Journal of Geotechnical Engineering, 2020, 42 (Suppl.1): 224-228.
- [10] 曾鹏, 张志强, 李天斌, 等. 隧道围岩收敛变形预测模型动态选择与变形量概率预测[J]. 地质科技通报, 2024, 43(6): 15-25.
- Zeng Peng, Zhang Zhiqiang, Li Tianbin, et al. Dynamic selection of optimal tunnel convergence prediction model for a probabilistic deformation prediction[J]. Bulletin of Geological Science and Technology, 2024, 43(6): 15-25.
- [11] 彭继慎, 郝茗, 宋立业, 等. 基于TSSA-SVR算法的TBM掘进速度预测[J]. 辽宁工程技术大学学报(自然科学版), 2023, 42(5): 634-640.
- Peng Jishen, Hao Ming, Song Liye, et al. TBM tunneling speed prediction based on TSSA-SVR algorithm[J]. Journal of Liaoning Technical University (Natural Science), 2023, 42(5): 634-640.
- [12] Zhang X M, Wang M H, Dan F, et al. Risk classification assessment and early warning of large deformation of soft rock in tunnels based on CNN-LSTM model[J]. Scientific Reports, 2024, 14: 29944.
- [13] 徐飞, 苏振海, 段雪锋. 基于多尺度融合YOLO-B算法的隧道衬砌渗漏水检测方法[J]. 隧道建设(中英文), 2025, 45(12): 2389-2400.
- Xu Fei, Su Zhenhai, Duan Xuefeng. Tunnel lining leakage detection method based on multi-scale fusion YOLO-B algorithm[J]. Tunnel Construction, 2025, 45(12): 2389-2400.
- [14] 陈礼博, 张明书, 陈海勇, 等. 基于CatBoost-NSGA-III的盾构隧道施工参数分析及优化控制[J]. 隧道建设(中英文), 2024, 44(8): 1587-1598.
- Chen Libo, Zhang Mingshu, Chen Haiyong, et al. Analysis and optimal control of shield tunnel construction parameters using categorical boosting-nondominated sorting genetic algorithm-III[J]. Tunnel Construction, 2024, 44(8): 1587-1598.
- [15] 傅蕾, 吴惠明, 黄宏伟, 等. 基于随机森林和MOPSO-CD的盾构隧道掘进沉降预测与施工参数优化[J]. 隧道建设(中英文), 2025, 45(增刊1): 318-329.
- Fu Lei, Wu Huiming, Huang Hongwei, et al. Settlement prediction and construction parameters optimization induced by shield tunneling based on random forest and multi-objective particle swarm optimization algorithm-crowding distance[J]. Tunnel Construction, 2025, 45(Suppl.1): 318-329.
- [16] Bo Y, Guo X G, Liu Q S, et al. Prediction of tunnel deformation using PSO variant integrated with XGBoost and its TBM jamming application[J]. Tunnelling and Underground Space Technology, 2024, 150: 105842.
- [17] 费瑞振, 施成华, 张春雷, 等. 盾构下穿既有隧道扰动预测模型及掘进参数优化[J]. 岩土工程学报, 2026, 48(3): 590-598.
- Fei Ruizhen, Shi Chenghua, Zhang Chunlei, et al. Prediction model for disturbance induced by shield tunneling underneath existing tunnels and optimization of tunneling parameters[J]. Chinese Journal of Geotechnical Engineering, 2026, 48(3): 590-598.
- [18] 任旭东, 张凤凯, 丁万涛, 等. 基于神经网络的泥水盾构地表沉降预测与掘进参数优化[J]. 科学技术与工程, 2025, 25(5): 2090-2099.
- Ren Xudong, Zhang Fengkai, Ding Wantao, et al. Prediction of ground settlement and optimization of tunneling parameters of slurry shield based on neural network[J]. Science Technology and Engineering, 2025, 25(5): 2090-2099.
- [19] Prokhorenkova L, Gusev G, Vorobev A, et al. CatBoost: unbiased boosting with categorical features[J]. Advances in Neural Information Processing Systems, 2018, 31: 6639-6649.
- [20] Chen T Q, Guestrin C. XGBoost: a scalable tree boosting system [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco California USA. ACM, 2016: 785-794.