

基于机器学习的盾构隧道掘进地表沉降预测与控制研究

李垂忝¹, 林晓琼², 张季², 许开成², 陈梦成²

(1. 南昌轨道交通集团有限公司, 南昌 330038; 2. 华东交通大学土木建筑学院, 南昌 330013)

摘要: 预测和控制盾构隧道掘进诱发的地表沉降, 是地下空间开发的重要工程问题。随着人工智能技术的发展, 机器学习算法在地表沉降预测与控制方面取得良好的应用效果。概述机器学习理论, 围绕数据库搭建、数据预处理、模型选择与评估、基于沉降控制下的盾构施工参数优化这4个方面展开讨论, 分析现有研究的不足之处。当前研究面临忽略地表构筑物荷载、交通流动及行人活动所带来的附加影响等问题, 模型缺乏可解释性以及预测准确性与实用性之间的平衡。后续研究应聚焦于构建综合性测量与评估体系将地表建筑、交通及地面堆载的动态效应纳入沉降预测模型, 同时加强模型的可解释性, 推动实时监测数据与机器学习模型的动态更新, 为盾构施工的安全控制提供更加科学的指导。

关键词: 城市轨道交通; 盾构隧道; 机器学习; 沉降预测; 沉降控制

中图分类号: U231

文献标志码: A

文章编号: 1672-6073(2026)01-0076-11

Review of Prediction and Control of Surface Settlement Induced by Shield Tunnelling Based on Machine Learning

LI Chuitian¹, LIN Xiaoqiong², ZHANG Ji², XU Kaicheng², CHEN Mengcheng²

(1. Nanchang Rail Transit Group Co., Ltd., Nanchang 330038;

2. College of Civil Engineering and Architecture, East China Jiaotong University, Nanchang 330013)

Abstract: Predicting and controlling the surface settlement induced by shield tunneling is a critical engineering issue in underground space development. With the development of artificial intelligence technology, machine learning algorithms have demonstrated significant effectiveness in surface settlement prediction and control. We summarize the theory of machine learning, focusing on four key aspects: database construction, data preprocessing, model selection and evaluation, and shield tunneling parameter optimization under settlement control. Additionally, it critically examines the limitations of existing research in this domain. Current research often neglects the additional impacts of surface structure loads, traffic flow, and pedestrian activities, lacks model interpretability, and struggles to balance prediction accuracy with practical applicability. Future research should focus on developing a comprehensive measurement and evaluation system that incorporates the dynamic effects of surface buildings, traffic, and ground surcharge into settlement prediction models. Furthermore, future work should enhance model interpretability and promote the dynamic updating of machine learning models with real-time monitoring data, thereby providing more scientifically sound guidance for safety control in shield tunneling construction.

Keywords: urban rail transit; shield tunneling; machine learning; settlement prediction; settlement control

收稿日期: 2025-03-28 修回日期: 2025-07-24

第一作者: 李垂忝, 男, 本科, 高级工程师, 从事城市轨道交通施工技术与管理工作, liliinn123@163.com

通信作者: 张季, 男, 博士, 教授, 主要从事地下结构抗震、盾构隧道掘进安全控制等方面的研究, jizhang@ecjtu.edu.cn

基金项目: 国家自然科学基金项目(52468070)

引用格式: 李垂忝, 林晓琼, 张季, 等. 基于机器学习的盾构隧道掘进地表沉降预测与控制研究[J]. 都市轨道交通, 2026, 39(1): 76-86.

LI Chuitian, LIN Xiaoqiong, ZHANG Ji, et al. Review of prediction and control of surface settlement induced by shield tunnelling based on machine learning[J]. Urban rapid rail transit, 2026, 39(1): 76-86.

以地铁区间隧道和地铁车站为基础枢纽的城市轨道交通系统,能高效利用城市地下空间并有效节约地面土地资源,对缓解城市交通压力具有重要作用。地铁区间隧道施工主要有明挖法、盖挖法和盾构法等。其中,盾构法施工因施工效率高、对道路交通影响小以及施工精度高等优点,在城市隧道建设中得到广泛应用。

盾构机下穿城市建筑密集区,会对既有建筑周边土体产生扰动,引起隧道周围地层发生不均匀沉降。易引起建筑物倾斜与开裂,甚至造成建筑物倒塌、地表塌陷和人员伤亡等重大安全事故。例如:2019年5月,青岛地铁4号线某区间发生突泥涌水事故,形成 $3\,956\text{ m}^3$ 的地表坍塌,给社会带来严重的生命危害和财产损失^[1]。因此,在盾构掘进过程中,需对地表沉降实施监测和预测,并采用严格的沉降控制标准^[2-3]。针对盾构掘进引起的地表沉降预测问题,研究人员已提出多种预测方法,传统的预测方法包括经验公式法^[4]、理论解析法^[5]、模型试验法^[6]和数值模拟法^[7]。这些方法虽然能够提供初步的沉降预测,但由于依赖特定的假设条件,忽略盾构掘进参数对地表沉降的影响,难以适用于复杂的地层环境。

人工智能和大数据技术的发展,推动新一轮的科技革命和产业升级。基于人工智能和大数据技术的盾构隧道掘进安全控制技术已成为地下空间开发的重要发展方向。通过数据挖掘与分析整合历史施工记录、地质勘察信息和实时监测数据,筛选出与地表沉降相关的参数。结合机器学习算法,通过其强大的非线性拟合能力,预测多参数跨量纲耦合作用下盾构施工所引起的地表沉降。例如,LUO等^[8]提出一种基于经验模态分解、支持向量回归和小波神经网络的组合模型,预测精度达到99.19%;沈一鸣等^[9]基于人工神经网络的预测模型对监测点进行沉降预测,预测绝对误差范围保持在1.3 mm以内。

另外,有效的地表沉降预测手段还需进一步结合地表沉降控制技术才能确保盾构掘进施工安全性,盾构掘进参数调整是控制地表沉降的重要手段之一。目前,盾构掘进参数的控制主要依赖人工经验,存在滞后性并且难以保证施工精度^[10]。综合考虑工程的实际状况和控制标准,通过机器学习算法优化施工参数,可实现盾构施工中地表沉降的控制,减少对人工经验的依赖^[11-12]。例如,WU等^[11]采用由随机森林和第二代非支配排序遗传算法组合的智能算法对施工参数进

行优化,优化后的地表沉降与原始监测数据样本的平均值相比降低12.5%。

现阶段,虽有多种预测模型可选择,但仍缺乏系统性的评价体系,不同模型与数据条件差异较大,影响结果的可比性。为此本文简要概述机器学习理论,并围绕数据库搭建、数据预处理、模型选择与评估、基于沉降控制下的盾构施工参数优化4个方面展开讨论。在此基础上,深入分析现有研究的不足,并指出后续研究方向。以期为研究人员和工程实践提供科学合理的地表沉降预测与控制方法指导。

1 机器学习理论

2000年代初期,反向传播神经网络(back propagation neural network, BPNN)凭借其较强的非线性映射能力,成为最早应用于盾构地表沉降预测的神经网络模型,并为相关研究奠定基础。进入2010年后,随机森林(random forest, RF)与支持向量回归(support vector regression, SVR)等集成学习与核方法逐渐崭露头角,显著提升了模型的泛化能力和鲁棒性。到2016年,以极致梯度提升树(extreme gradient boosting, XGBoost)为代表的增强树模型凭借高效与稳定的性能,成为工程实践中的热门工具。与此同时,长短时记忆网络(long short-term memory, LSTM)在动态预测与趋势分析方面展现出独特优势,推动时间序列沉降数据的预测精度。

BPNN是一种通过反向逐层调整权重和偏置最小化误差的多层前馈神经网络,又名反向传播网络。模型结构由输入层、隐含层、输出层3部分组成。训练过程可以分为2个步骤:输入信息前向传播和误差反向传递^[13]。采用梯度下降法逐层对各个节点的权重和偏置进行修正^[14],利用修正后的权重和偏置进行新一轮的训练,如此往复,直到达到输出要求。由于采用梯度下降法进行训练,网络可能在复杂问题中容易陷入局部最优解。

SVR是基于支持向量机理论上衍生的回归分析算法^[15]。通过核函数将非线性的输入样本数据映射在高维特征空间^[16],并在特征空间里寻找最优的回归平面,确保大多数数据样本点的预测误差在给定的容忍偏差范围内。与传统回归模型不同的是,SVR允许存在一定程度的误差,只有当误差超过容忍偏差范围时,才会对模型的损失函数产生影响。然而,SVR在面对高维数据时训练效率较低,且模型的性能受限于核函数和超参数的选择。

RF是基于集成学习的思想,组合多个相互独立、

各自训练的决策树构建的树模型^[15]。通过对训练数据集进行有放回抽样,创建多个不同的数据子集,每个子集用于训练一棵决策树^[15];同时,随机选择一部分特征进行树节点分裂,从而避免过于依赖某些特征,提高整体模型的泛化能力。但由于集成多棵树的复杂交互,虽具备出色的预测性能,但在解释性方面不如单模型直观。

XGBoost是通过迭代多个弱学习器(通常为分类回归树)形成强学习器的集成学习算法^[14]。在处理回归问题时,该算法对目标函数中的损失项进行二阶泰勒展开,将获得的1阶和2阶导数信息用于弱学习器的结构优化与权重的计算^[17]。弱学习器的输出经过学习率缩放后累加到当前模型中,从而实现梯度提升框架下的逐步优化。然而,XGBoost结构复杂,调参过程繁琐,对计算资源要求较高。

LSTM是一种基于循环神经网络(recurrent neural network, RNN)改进的模型,其网络结构与RNN相似,区别在于LSTM引入门控机制对传统RNN的隐藏状态进行改进;通过遗忘门、输入门和输出门控制信息的选择与传递,缓解传统RNN在反向传播过程中的梯度消失和梯度爆炸问题^[18]。尽管LSTM在时序预测中取得广泛应用,但其模型结构复杂、对超参数设置较为敏感。

综上所述,机器学习能够实现跨量纲、跨单位、多参数的高维度拟合,可以满足高效、实时的应用要求。尽管上述模型各有优势,但仍存在如模型解释性不足、参数调优复杂、对数据质量敏感等挑战。不同的模型算法在实际工程的应用效果迥异,需进一步对比分析不同算法在应用中的表现,评估其适用性。

2 地表沉降预测

现有研究在算法的选择上大相径庭,但模型构建的基本流程均可概括为以下3个步骤:数据库搭建、数据预处理、模型测试与评估。

2.1 数据库搭建

2.1.1 输入参数选取

盾构施工过程中地表沉降通常可分为短期沉降与长期沉降。短期沉降主要来源于盾构开挖前土体扰动、盾构推进期间盾构机机身及管片与周围土体之间的摩擦,以及盾尾空隙的填充不完全所导致的局部沉降;而长期沉降则包括土体固结排水、注浆固结以及管片变形等。综上,地表沉降变形响应是土体、隧道结构

与盾构机综合作用的结果。随着相关研究的深入与施工经验的积累,部分学者开始关注诸如:地下水位波动、盾构停机、风险源(穿越河流或交通干道)、溶洞处理方案、溶洞距隧道的距离以及溶洞的几何特征等^[19-25]非传统因素的潜在影响,并将其纳入系统性分析框架中。为便于进行模型的选择与结果的分析,相关输入参数通常被分为3类:地质参数、隧道几何参数和盾构掘进参数。

在地质参数的选取上,早期研究普遍基于均质连续假设对土体的分布进行简化处理,从而忽略了地质参数的空间变异性^[26],通常直接选取监测断面土层的物理力学特性作为地质参数,主要包括土层类型、弹性模量、内聚力、压缩模量、密度等。通过计算不同土层厚度占比对地质参数取加权值表征监测断面范围内不同土层的空间分布情况和物理力学性质的影响^[27]。近年来,为提升土层力学参数的空间适应性,优化土层力学参数的赋权策略。CHEN等^[28]提出将层厚因子(即土层厚度占覆土总厚度比)和层深因子(即土层深度占覆土总厚度比)相乘作为修正因子,并取修正后的标贯次数、动探次数、单轴抗压强度作为地质参数。不仅能够定量评估土层的密实度、抗剪强度及承载能力,而且对于复合地层适用性更强,目前已被广泛应用。为简化模型的输入,部分研究采用数字编码对不同土层类型进行量化处理^[25, 29];当隧道开挖面的土层类型分布相对均匀且类型单一,则地质参数对沉降的影响较小可忽略不计^[30]。若在整个工程施工过程中,地下水位高于隧道顶面且保持稳定,则地下水位波动带来的影响也可忽略不计^[31]。

通常选用隧道直径、隧道埋深为隧道几何参数。但在同一项目施工过程中,隧道直径通常保持不变,因此仅选用隧道埋深作为隧道几何参数^[21]。隧道埋深虽能反映盾构施工的垂向几何特征^[32],但无法体现监测点地表沉降所受邻近多环掘进扰动这一纵向影响,故部分研究引入盾构开挖面与监测点之间的距离作为隧道几何参数^[29]。YIN等^[33]还提出基于当层法原理的埋深等效策略,将既有隧道刚度对沉降的影响等效纳入隧道几何参数。目前的研究主要集中在预测单隧道开挖引起的最大地表沉降方面,对双隧道开挖的关注有限。双隧道开挖引发的沉降叠加效应及隧道间相互扰动对地表沉降的影响不可忽略,对于双隧道施工,还需考虑隧道间水平间距的影响^[31]。

盾构掘进参数是3类因素中,唯一的人为控制因

素。其中刀盘转速、盾构推力、掘进速度、土仓压力和刀盘扭矩直接影响切削效率和推进稳定性；注浆的压力和注浆量对土层的加固与稳定性起着关键作用。考虑到实际盾构掘进轨迹与设计路线存在工艺误差，盾构机需调整姿态，导致局部推力增加，引起土体剪切变形，影响地层稳定性。盾构离开后，盾构机外壳与周围地层之间会形成空隙；如果同步注浆填充不完全，土体会沿空隙移动或塌陷。故文献[23]在上述参数的基础上，选用隧道偏差、尾部空隙作为盾构掘进参数；并指出土仓压力、隧道开挖偏差和盾构推力是关键的控制因素。另外，文献[21，24-25，29]还将盾构姿态、泥浆流量差、盾构通过断面时间、盾尾相对于隧道中心线的水平偏差、盾尾相对于隧道中心线的垂直偏差、千斤顶速度、切削面水压、送(排)泥流量、送(排)密度等作为盾构掘进参数。

2.1.2 输出参数选取

基于 Peck 经验公式的假设，工程上认为盾构掘进

引起的地表沉降符合正态分布的形态，最大的沉降点通常位于隧道中心轴线上，与坍塌风险呈正相关。故通常将隧道中心轴线上的沉降值视为最大地表沉降值，作为输出参数^[33]。现有研究主要关注单隧道开挖引起的最大地表沉降预测或单个监测点的沉降演化过程(研究长期沉降变化)^[34]。针对沉降槽曲线的研究，目前使用数值模拟法和 Peck 经验公式法居多，机器学习在其上的应用案例相对有限。

综上，基于文献[20-25，27-39]的输入、输出参数选择汇总见表 1 所示。从现有研究来看，地面堆载荷载^[40]、上部既有建筑荷载和刚度^[41]、临近隧道的列车移动荷载^[42]的空间非均质性与叠加效应与地表沉降之间存在相关性。由于尚未形成统一的特征衡量标准，在沉降预测模型参数的选择过程中，往往被忽略。这种简化处理在一定程度上限制了模型对复杂城市环境下沉降响应的捕捉能力，因此，在未来的研究中应当将这些区域的荷载纳入考虑范围。

表 1 输入、输出参数选择

Table 1 Selection of input and output parameters for the model

输入参数	地质参数	地下水位、黏聚力、压缩模量、标贯次数、动探次数、单轴抗压强度、容重、刀盘面的地质条件、隧道拱顶的土壤类型、不同类型土层的厚度、岩溶洞高度、岩溶洞与隧道仰拱的距离、泊松比、隧道仰拱的土壤类型、密度、土层类型、处理情况、静止土压力、风险源
	隧道几何参数	隧道埋深、掌子面与监测点之间的距离、隧道直径、管片宽度、管片厚度、双隧道间距、两隧道掘进面之间的距离、盾构机锥度、盾构机长度、盾尾外壳壁厚、隧道埋深与直径之比、双隧道间距与直径之比
	盾构参数	盾构推力、刀盘扭矩、注浆量、注浆压力、推进速度、贯入度、掌子面压力、土仓压力、刀盘转速、盾尾空隙、排泥流量、注浆管压力、盾构通过断面时间、注浆速率、盾构姿态、泥浆流量差、土方体积、隧道偏差、岩溶洞处理方案、盾尾与隧道中心线的水平偏差、盾板尾部与隧道中心线的垂直偏差、辊筒位移、千斤顶速度、切削面水压、送泥流量、送泥密度、排泥密度、浆料入口管密度、膨润土压力、螺杆转速、输送机扭矩、输送机速度、平均推进位移
	其他参数	盾构停机状态、地下水波动、测量误差、无法测量的因素
输出参数	地表最大沉降、地表时序沉降、沉降槽曲线	

2.2 数据预处理

2.2.1 数据清洗

由于外部环境条件无法进行钻孔取样、试验人员的失误操作和设备故障等原因，数据库中会包含大量的停机数据、无效数据、数据空值等噪声数据需要进行数据清洗，包括缺失值填补、异常值剔除和数据归一化，以提升数据质量并确保数据完整性。对于缺失比例较小、数据分布相对稳定的参数通常采用均值、众数、插值等方法进行缺失值的填充。采用均值和众数填充并不能代表数据的真实分布，尤其在偏态或多峰分布下，容易引入偏差；插值方法则依赖数据的连续，不适用于非时间序列数据且对异常值敏感。对于

缺失较为严重的数据，可直接删除对应区间段数据；但易造成信息丢失或在某些特征上分布不均，影响模型稳定性和泛化能力。对于明显偏离整体的异常值，在岩土工程中通常用 3σ 准则法^[9]、马氏距离法^[31]、Z-score 法^[36]、箱型图法^[43]和孤立森林法进行检测后剔除，再对空值处进行填充。各方法的适用条件见表 2 所示。其中，箱型图法更加直观，且不需要数据服从正态分布，筛选异常值更加方便，因此应用范围更加广泛。删除异常值后留下的空值处按缺失值进行处理。对于时间序列数据，相邻时间点的数据点之间通常存在自相关性，可以采用滑动窗口平均值法^[44]替换异常值；既避免由数据突变带来的影响，又保留数据的整体规律。

表 2 异常值检测常用方法

Table 2 Common methods for outlier detection

方法	适用条件	缺点
3 σ 准则法	服从或近似服从正态分布且数据集较大的单变量检测。	极端异常值会显著影响标准差的计算，导致其他潜在的异常值无法被识别。
马氏距离法	变量间具有相关性的多维数据检测，当数据服从正态分布时，检测效果更佳。	当数据偏离正态分布、样本量较小、存在缺失值或变量间关系存在非线性时，可能会导致正常值误判为异常值。
Z-score 法	服从正态分布的单变量检测	依赖平均值和标准差进行异常值判别，在样本量较小时，这 2 个指标容易受极端值和数据波动的干扰，影响检测结果。
箱型图法	任意分布的数据尤其适合中小样本的单变量的异常值检测，也可以用于多维数据的逐变量检测。	使用 1.5 倍四分位距划定异常值范围，但这一阈值是基于经验的，不一定适用于所有数据集。
孤立森林法	数据分布复杂的多维数据检测，尤其适用于大规模数据集。	对于分布集中但整体偏离的异常群体，往往不易检测。

为避免数量级较大的特征主导预测结果，消除特征间单位差异和避免数量级差异对模型的影响，需对数据进行标准化或归一化处理。归一化适用于数据范围较大且分布不均匀的情况，尤其在神经网络类算法中有利于提高训练稳定性，而标准化适用于接近正态分布的数据。数据经过归一化或标准化处理后进行训练，模型的输出值通常不是实际值，还需要进行反归一化或反标准化处理还原为实际输出值^[29]。

2.2.2 特征选择

对于多输入的回归问题，过多的输入参数(特征)往往会导致“维度灾难”、特征间存在高度相关性等问题。故需通过相关性分析进行特征选择，优化模型输入，并将分析结果可视化成散点图或热图，更直观地观察特征之间的关系。常用的相关性分析方法有 Pearson 相关系数法和 Spearman 相关系数法。

当特征间相关系数的绝对值大于等于 0.8 时，说明特征之间高度相关，可能存在多重共线性问题。部分研究如^[31]为进一步加强判断特征间是否存在多重共线性问题，在进行相关性分析后，进一步采用方差膨胀因子(variance inflation factor, VIF)进行检测，当 $VIF \geq 10$ 存在高度共线性，应对特征进行处理。可考虑删除对沉降影响较小的特征，避免共线性问题或使用主成分分析(principal component analysis, PCA)^[37]进行降维。PCA 通过线性变换将多个相关特征合并成新特征(又称主成分)，减少输入维度的同时保留重要的特征信息。

最后，将预处理后的数据库按照训练集(70%~80%)、测试集(20%~30%)进行划分；同时，可采用 K 折交叉验证或设置独立验证集减少数据划分的不确定性。对于时序数据，建议采用时间窗口划分，以保持数据的时序特性，避免信息泄露干扰预测结果。

综上所述，数据预处理在确保数据完整性的前提下，是构建高性能模型的基础；包括缺失值填补、异常值检测与剔除、数据归一化或标准化及特征选择 4 个关键步骤。目前的研究中对异常值的检测和替换在复杂数据集中可能存在误判，因部分异常值里可能包含重要特征或关键信息。直接剔除或替换这类异常值会导致信息丢失，且不恰当的替换方法会改变数据分布特征；如数据对应的是特殊工况如地层突变、盾构停机、地下水位突变、二次注浆等容易被检测为异常值并剔除，若使用均值、众数、插值进行填充，可能会掩盖原始数据中的波动特征，还可能破坏变量之间的相关性。故使用异常值检测及替换的方法还需结合数据背景综合考虑。

2.3 模型选择与评估

根据模型的结构和工作原理，盾构沉降预测中常用的模型可以大致分为 4 类：树模型、神经网络型、支持向量模型和其他类型。通过对比评估指标，分析不同机器学习算法的预测性能差异，选择出最优算法。常用的评价指标有均方误差(mean squared error, MSE)、绝对均方误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)以及决定系数(R^2)；误差越接近 0 且决定系数越接近 1，说明模型的拟合效果越好，预测结果越准确。

2.3.1 树模型

常用的树模型包括分类与回归树(classification and regression tree, CART)、梯度提升决策树(gradient boosting decision tree, GBDT)、RF 和 XGBoost。

早期使用的 CART 是单一决策树模型，模型结构简洁，训练时可能会过度依赖影响较大的特征，导致预测结果偏差。随后发展出的集成学习模型如 RF、GBDT 等通过特征重要性评估各个输入参数对沉降预

测的贡献, 识别关键影响因素提高预测的准确性。文献[45]结果表明 RF 和 GBDT 的预测性能优于 CART。基于 GBDT 进一步演化出的 XGBoost^[46]和轻量级梯度提升机(light gradient boosting machine, LGBM)在训练速度、精度上优于 RF 和 GBDT。其中 XGBoost 适用于高精度预测场景, 而 LightGBM 具有高效计算能力, 可满足实时预测需求。尽管集成模型性能优于 CART, 但其在噪声敏感性方面表现不一, RF 在高噪声环境中表现更稳定。面对小样本数据集, 文献[39]提出的极端随机树(extremely randomized trees, ERT)模型在地表沉降预测中表现要更优于 RF 和 XGBoost。由于树模型决策路径的可视化, 使得研究人员能够追踪每个输入参数对沉降趋势的影响, 提升预测的透明度, 在近几年沉降预测和控制中被广泛应用。

2.3.2 神经网络模型

神经网络类算法是在沉降预测里应用最广泛的机器学习算法^[22], 从简单神经网络发展为能够处理复杂时空关系的多层次模型体系。BPNN 具有良好的容错性和自适应的学习方式, 但输入参数存在突变时响应较慢; 且对时序变化较为敏感, 缺乏自适应的超参数优化机制, 限制其在复杂任务中的表现。为提升计算效率, 研究者引入结构简单、计算效率高的极限学习机(extreme learning machine, ELM)^[36], 并通过加入核函数形成核极限学习机(kernel extreme learning machine, KELM)^[47], 增强了处理非线性问题的能力, 但极限学习机类的算法对数据质量较为敏感且核函数选择上需谨慎。

过去的沉降预测地质参数通常基于独立测点的剖面数据, 盾构掘进参数通常取测点所在区间内的平均值输入; 却忽略地表沉降是一个贯穿时间和空间的动态过程。为能更有效捕捉沉降过程的动态趋势, 研究引入 LSTM^[29]和门控循环单元(gated recurrent unit, GRU)^[29]等循环神经网络的改进算法, 较 BPNN 能够更好地捕捉时间序列动态变化, 其中 GRU 是 LSTM 的变体, 结构更简洁, 在减少参数数量的基础上, 降低了计算的开销。为进一步提升预测精度, CHEN 等^[48]利用 Bi-LSTM 通过引入双向时间序列建模, 同时考虑历史与未来信息, 对沉降趋势进行修正, 弥补单向 LSTM 在信息利用上的不足; 然而, 其对空间局部信息的捕捉能力较弱。结合卷积神经网络(convolutional neural network, CNN)的融合注意力机制(self-attention, SA)的卷积神经网络-双向长短期记忆网络(CNN-BiLSTM-

SA)^[33]弥补 Bi-LSTM 局部信息捕捉能力的不足, 并通过 SA 的权重分配机制优化模型的信息选择能力。值得注意的是, 虽然注意力机制提高了模型灵活性, 但其控制稀疏性的参数调整策略目前尚缺乏理论依据, 普遍依赖经验设定。

近年来, 沉降过程的时空协同变化规律成为研究的新热点。文献[49]提出的时空融合网络(spatial-temporal fusion network, STF-Network)通过时空融合机制(spatial-temporal fusion mechanism, STFM)和 3D 残差单元(3D residual unit, 3D-ResUnit), 实现空间与时间序列的交互特征的提取, 改进了传统的机器学习算法无法同时捕捉沉降随时间变化的趋势与波动, 以及不同空间位置沉降差异的问题^[50]。在此基础上, 研究者进一步关注部分参数对地表沉降存在时延性影响, 如温度、土水压力和天气条件可能在盾构施工后数小时至数天才显现影响。针对这些影响, 模型构建由考虑“空间与时间”向融合“多尺度时间与环境因素”的方向发展, 例如, 利用稀疏注意力机制的 Informer^[51], 不仅能捕捉输入和输出之间的长期依赖关系, 还能有效应对短期波动带来的影响。

针对神经网络算法饱受诟病的“黑箱”问题, 现有研究将先验物理知识、沉降经验公式与神经网络算法相结合, 例如: 多域物理信息神经(multilevel physics informed neural network, MPINN)^[52]、网络物理信息神经网络(physics informed neural network, PINN)^[53]、经验公式神经网络(empirical formula based neural network, EFBNN)^[54]、经验信息约束神经网络(empirical information constrained neural network, EICNN)^[54]等。通过引入物理约束或经验公式, 增强模型的可解释性, 减少模型对数据的依赖。虽然机器学习与物理机制的相互融合在提升模型表现方面展现出巨大潜力, 但其缺乏跨学科统一的协同框架, 加之计算复杂、验证困难等挑战, 从而限制了在工程实践中的应用。

2.3.3 支持向量模型和其他类型

除了树模型和神经网络模型, 支持向量模型及其他数据驱动方法也被广泛应用在沉降预测中。支持向量机(support vector machine, SVM)^[22]和支持向量回归(SVR)^[25]在处理数据分布稀疏的小样本数据集时表现优异, 但与传统的线性回归和树模型算法相比, 模型的解释性较差。相比之下, 多基因遗传编程(multi-gene genetic programming, MGGP)^[31]可直观地量化各输入参数对沉降趋势的影响, 作为遗传编程的变体, 能

在有限的样本数据下,生成可解析的沉降预测公式,然而该方法目前在盾构隧道沉降预测中的应用仍较为有限。与复杂的非线性回归模型相比,DLinear^[55]等轻量级时序建模方法,以线性结构为基础,有效捕捉盾构施工沉降的长期趋势和周期性变化。在地质参数波动较小的自动化监测场景中具备实用性。

考虑到不同算法在同一工程背景下的适应性差异。有研究尝试通过模型集成方式提升预测性能,文献[21]提出 Stacking 通过多层结构(基础模型+元学习器)集成不同的异质学习器,提高预测的精度和稳定性,但面临计算成本较高以及参数调优复杂的问题。此外,当不同监测点的地质参数、盾构掘进参数及沉降变化较为相似时,神经网络类模型和树模型可能会出现欠拟合问题。有研究引入局部预测方法,如 K-近邻算法(k-nearest neighbors, KNN)^[56]利用与当前施工状态最接近的 K 个样本的沉降变化趋势进行预测,通过关注局部数据避免因忽略局部特征变化而带来的预测误差。

综上所述,综合考虑数据集的大小与完整性、输入数据的类型、模型的训练时间、结果的误差容忍以及计算资源等条件限制,选择适合实际工程需求的最优算法,确保模型的效率与精度。树模型适用于单点数据预测,神经网络模型适用于时序数据预测,而支持向量模型则在数据量较少时更具优势。目前,在盾构施工地表沉降预测中,机器学习模型的选择通常侧重于提高拟合效果,而对模型本身的可解释性关注相对不足,容易导致过拟合现象或“黑箱”问题。尽管已有研究引入 SHAP、LIME 等解释性算法^[57-58],通过计算输入特征对输出结果的贡献度量化输入对输出的影响程度,这类方法通常在模型训练完成后进行,而非在模型结构设计或训练机制中同步引入可解释性机制,因此难以从根本上增强模型的可解释性。如何平衡模型的预测准确性和可解释性,仍然是一个亟待深入研究的问题。

3 沉降控制下盾构掘进参数优化

当前盾构掘进参数优化主要围绕提高掘进效率、减少刀盘磨损及降低施工成本开展,对于地表沉降控制下的盾构掘进参数优化的关注相对较少。深埋、大断面、长距离成为盾构隧道工程不断发展的新标签,盾构掘进参数的优化在减小地表沉降控制上发挥重要的作用,但也面临地质变化的不确定性、施工进度与沉降控制的不平衡、掘进参数调整困难等挑战。得益

于人工智能的发展,机器学习为基于沉降控制的盾构掘进参数优化提供新的发展思路。

ZHANG 等^[59]最早提出基于沉降控制下的盾构掘进参数优化模型(PSO-RF),RF 算法用于预测地表沉降,并将其设置为粒子群优化算法(particle swarm optimization, PSO)的适应度函数即优化目标;优化后的盾构掘进参数预测出的地表沉降与实测值相比,最大沉降从 -31.63 mm 减少到 -4.23 mm。文献[11]通过构建 LSTM-PSO 掘进参数优化模型,并根据掘进参数的优化值实时指导盾构施工,各断面的地表沉降量均在 10 mm 以下。文献[60]利用 AG-PSO 对气泡舱压力进行优化,经调整后超过预警线的沉降值减少 37.1%。费瑞振等^[61]采用贝叶斯优化(bayesian optimization, BO)的极端梯度提升算法(BO-XGBoost)建立沉降预测模型,并结合 PSO 算法对掘进速度、刀盘转速、注浆压力、注浆压力作用范围进行优化,将盾构穿越高铁隧道的沉降值控制在 5 mm 以内。上述研究虽各自搭配不同的预测算法,但均选择 PSO 作为优化算法,一方面在于其算法原理清晰、实现简单,适合用于施工参数这类连续变量的搜索优化;另一方面,其强大的全局搜索能力与快速收敛特性,使其在高维空间内寻找最优施工组合时表现出较高效率。

与传统的单目标控制下的优化相比,多目标控制下的优化能够全面考虑各目标之间的平衡,并获得合理且全面的优化结果^[11]。吴贤国等^[62]建立 RF 与第二代非支配排序遗传算法(nondominated sorting genetic algorithm-II, NSGA-II)结合的多目标优化算法,以地表沉降和刀盘磨损为控制目标,得出相应岩溶地区盾构施工参数控制范围。文献[63]提出的分类助推(categorical boosting, CatBoost)和基于分解的多目标进化算法(multi-objective evolutionary algorithm based on decomposition, MOEAD)相结合的混合智能算法,选择地表沉降、贯入度和掘进比能为控制目标,对关键掘进参数进行优化后的地表沉降、贯入度和掘进比能的平均值提升幅度分别为 12.35%、7.47%和 10.70%。

综合现有研究成果,基于机器学习的沉降控制下盾构掘进参数的优化主要围绕沉降预测模型与优化算法展开,优化流程如图 1 所示。首先,利用机器学习模型建立盾构掘进参数、地质参数、隧道几何参数与地表沉降之间的映射关系即沉降预测模型。在 3 类参数中地质参数和隧道几何参数是不可变的既定因素,盾构掘进参数是唯一的可调整变量。因此,沉降预测

模型也可以简略地视为是盾构掘进参数与地表沉降之间的映射函数。这使得优化算法能够在已有的沉降预测模型上,对盾构掘进参数进行针对性调整。在此过程中,将沉降预测模型作为优化算法中的适应度函数用于评估得出的盾构掘进参数解的优劣,并以最小化地表沉降为目标函数。为确保优化后的盾构掘进参数在实际应用中的可行性,需设定变量约束条件,明确各个盾构掘进参数的寻优范围。最后,经过优化算法的迭代,不断更新盾构掘进参数,使其逐步趋向最优解并输出。此外,为减少调整多个施工参数所花费的时间和成本,可基于输入参数重要性排序结果和影响分析,选择关键的盾构掘进参数进行优化^[63]。




图1 地表沉降控制流程

Figure 1 Surface subsidence control process

综上所述,通过实时监控和动态调整盾构掘进参数,可以实现盾构掘进过程中沉降预警并优化控制策略,从而提高施工的精度和安全性。除 PSO 算法外,诸如遗传算法(genetic algorithm, GA)、蚁群算法(ant colony optimization, ACO)、差分进化(differential evolution, DE)等算法在约束建模、离散空间搜索和实时反馈控制等方面展现出显著的优势。然而,在沉降控制下的盾构参数研究中,对这些算法的实际应用较少,并且不同优化方法在多目标约束、动态环境和高维混合变量条件下的横向对比仍处于探索阶段,需进一步深入开展。

4 总结与展望

4.1 总结

本文回顾了机器学习的在盾构施工地表沉降预测

及控制的应用。针对该领域最新研究进展,从机器学习理论、数据库搭建、数据预处理、模型选择、沉降控制下盾构掘进参数优化等多个维度切入,深入剖析。综合来看,机器学习能满足实时、高效的工程需求,在盾构工程中发挥着重要作用。合理的参数选择是实现精准预测和优化的关键,数据预处理是保障模型稳定性的关键,同时模型选择需权衡计算资源、预测精度与数据适用性。然而,在盾构掘进参数优化的研究仍较为有限,需进一步深化,以提升施工精度和安全性。

4.2 展望

基于数据驱动的机器学习预测模型能够为沉降监测与控制提供精细化的技术支持,但仍存在一些亟待解决的问题,未来的研究方向大致可归纳为以下3个方面:

1) 当前盾构隧道地表沉降主要关注隧道几何特征、地质条件及盾构施工参数对沉降的影响,而对于地面环境的复杂动态因素,如地表构筑物荷载、交通流动及地面临时堆载所带来的附加影响,研究较为有限。未来的研究工作应该进一步构建综合性测量与评估体系,结合 InSAR 监测数据、交通流量信息与建筑信息模型(building information modeling, BIM)等多源数据。通过引入如堆载作用中心和大小的分布演变、交通流量强度、建筑密度等参数,作为地表附加荷载的代理变量,进一步探讨其对隧道上覆地表沉降的影响机制与空间分布特征。将地表建筑、交通及堆载的动态效应纳入沉降预测模型,以提高预测精度和工程安全性。

2) 在盾构隧道施工中,机器学习模型的可解释性是应用的关键。许多机器学习模型,其内部决策过程难以直接解读,从而限制其在工程应用中的可解释性。尽管 SHAP、LIME 等主流解释性方法能通过量化输入特征对模型输出的边际贡献,但其核心是基于统计的相关性分析。传统的解释算法通常假设输入特征之间相互独立,忽略了地表沉降的样本之间具有时空关联性,难以区分特征贡献中的真实因果效应与伪相关性。未来的研究工作应聚焦于将因果推断机制与解释性算法相结合,发展适用于时空数据的因果解释算法,进一步推动算法与岩土工程、测绘与遥感、流体力学等多学科交叉发展,开发具有物理约束性和工程适用性的高解释性模型。

3) 在沉降控制中,传统的机器学习模型多依赖于

离线训练模式,而在盾构掘进参数的优化中,需要模型能够根据新收集到的沉降数据不断调整并优化。如何实现高效的在线学习与实时优化是沉降控制中的一个难点。未来可以利用建筑物联网技术、数字孪生等现代信息技术构建智能监测平台,结合深度强化学习算法与元启发优化算法,实现地表沉降、地质参数、盾构掘进参数的多源信息实时交互和盾构掘进参数的闭环控制。

参考文献

- [1] YAN Feiyue, QIU Wenge, SUN Keguo, et al. Investigation of a large ground collapse, water inrush and mud outburst, and countermeasures during subway excavation in Qingdao: a case study[J]. *Tunnelling and underground space technology*, 2021, 117: 104127.
- [2] 孙帅, 常连翠, 张煌, 等. 盾构隧道施工对邻近建筑物差异沉降与扭曲变形影响分析[J]. *防灾减灾工程学报*, 2024, 44(2): 459-466.
SUN Shuai, CHANG Liancui, ZHANG Huang, et al. Impact of shield tunnel construction on differential settlement and twist deformation of adjacent buildings[J]. *Journal of disaster prevention and mitigation engineering*, 2024, 44(2): 459-466.
- [3] HE Qinglun, SHI Lingyue, BAI Wenfeng, et al. Investigation and simulation analysis of ground collapse accident caused by shield tunnelling: The Foshan Metro Line 3 case[J]. *Engineering failure analysis*, 2024, 166: 108901.
- [4] GAO Yanxia, LIU Yiwen, TANG Pengju, et al. Modification of peck formula to predict surface settlement of tunnel construction in water-rich sandy cobble strata and its program implementation[J]. *Sustainability*, 2022, 14(21): 14545.
- [5] 周鹏远, 宋战平, 王军保, 等. 基于随机介质理论的偏压隧道地表沉降预测方法[J]. *岩土工程学报*, 2025, 47(3): 589-598.
ZHOU Pengyuan, SONG Zhanping, WANG Junbao, et al. Prediction method for ground surface settlement induced by bias tunnel based on stochastic medium theory[J]. *Chinese journal of geotechnical engineering*, 2025, 47(3): 589-598.
- [6] 张宇亭, 安晓宇, 晋亚斐. 隧道开挖引起上部建筑物沉降的离心模型试验研究[J]. *岩土工程学报*, 2022, 44(S2): 54-57.
ZHANG Yuting, AN Xiaoyu, JIN Yafei. Centrifugal model tests on settlement of structures caused by tunnel excavation[J]. *Chinese journal of geotechnical engineering*, 2022, 44(S2): 54-57.
- [7] WANG Haibo, ZHANG Rongjun, TAO Fengjuan, et al. Study on long-term surface settlement induced by shield tunneling in under-consolidated soft ground[J]. *Tunnelling and underground space technology*, 2024, 148: 105772.
- [8] LUO Xianglong, GAN Wenjuan, WANG Lixin, et al. A prediction model of structural settlement based on EMD-SVR-WNN[J]. *Advances in civil engineering*, 2020, 2020: 8831965.
- [9] 沈一鸣, 张冬梅, 黄忠凯, 等. 基于 EMD-多层 LSTM 的盾构隧道长期沉降预测[J]. *地下空间与工程学报*, 2025, 21(2): 684-694.
SHEN Yiming, ZHANG Dongmei, HUANG Zhongkai, et al. Long-term settlement prediction of shield tunnel based on EMD-multilayer LSTM[J]. *Chinese journal of underground space and engineering*, 2025, 21(2): 684-694.
- [10] SHEN Xiang, CHEN Xiangsheng, BAO Xiaohua, et al. Real-time prediction of attitude and moving trajectory in shield tunneling based optimal input parameter combination using random forest deep learning method[J]. *Acta geotechnica*, 2023, 18(12): 6687-6707.
- [11] WU Xianguo, WANG Lei, CHEN Bin, et al. Multi-objective optimization of shield construction parameters based on random forests and NSGA-II[J]. *Advanced engineering informatics*, 2022, 54: 101751.
- [12] 胡长明, 冯丽丽, 李靓, 等. 基于机器学习的盾构掘进地表沉降控制及参数优化研究[J]. *隧道建设(中英文)*, 2023, 43(12): 1985-1995.
HU Changming, FENG Lili, LI Liang, et al. Surface settlement control and parameter optimization of shield tunneling based on machine learning[J]. *Tunnel construction*, 2023, 43(12): 1985-1995.
- [13] WANG Qiankun, SHEN Chuxiong, TANG Chao, et al. Machine learning-based forecasting of ground surface settlement induced by metro shield tunneling construction[J]. *Scientific reports*, 2024, 14: 31795.
- [14] HU Min, SUN Junchao, WU Bingjian, et al. Shield tunnel (segment) uplift prediction and control based on interpretable machine learning[J]. *Sustainability*, 2024, 16(2): 910.
- [15] LIU Chao, WANG Zepan, LIU Hai, et al. Prediction of surface settlement caused by synchronous grouting during shield tunneling in coarse-grained soils: a combined FEM and machine learning approach[J]. *Underground space*, 2024, 16: 206-223.
- [16] MAHMOODZADEH A, NEJATI H R, MOHAMMADI M, et al. Forecasting face support pressure during EPB shield tunneling in soft ground formations using support vector regression and meta-heuristic optimization algorithms[J]. *Rock mechanics and rock engineering*, 2022, 55(10): 6367-6386.
- [17] ZHANG W G, LI H R, WU C Z, et al. Soft computing

- approach for prediction of surface settlement induced by earth pressure balance shield tunneling[J]. *Underground space*, 2021, 6(4): 353-363.
- [18] MEN Xiaoxiong, LI Yuanfei, GUO Baohe, et al. Advance rate predictions of tunnel boring machines using Bayesian-optimized CNN-LSTM[J]. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, 2025, 11: 04024086.
- [19] ZHANG Pin, WU Huaina, CHEN Renpeng, 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: 103383.
- [20] WANG Gan, FANG Qian, DU Jianming, et al. Deep learning-based prediction of steady surface settlement due to shield tunnelling[J]. *Automation in construction*, 2023, 154: 105006.
- [21] 郑一鸣, 李刚, 季军, 等. 基于Stacking集成学习的盾构掘进地表沉降预测方法[J]. *隧道建设(中英文)*, 2024, 44(11): 2233-2240.
ZHENG Yiming, LI Gang, JI Jun, et al. Surface settlement prediction method for shield tunneling based on stacking ensemble learning[J]. *Tunnel construction*, 2024, 44(11): 2233-2240.
- [22] SU Jie, WANG Yuzhe, NIU Xiaokai, et al. Prediction of ground surface settlement by shield tunneling using XGBoost and Bayesian Optimization[J]. *Engineering applications of artificial intelligence*, 2022, 114: 105020.
- [23] ZHANG Kun, LYU Haimin, SHEN Shuilong, et al. Evolutionary hybrid neural network approach to predict shield tunneling-induced ground settlements[J]. *Tunnelling and underground space technology*, 2020, 106: 103594.
- [24] ZHANG Ning, ZHOU Annan, PAN Yutao, et al. Measurement and prediction of tunnelling-induced ground settlement in Karst region by using expanding deep learning method[J]. *Measurement*, 2021, 183: 109700.
- [25] LIU Linan, ZHOU W, GUTIERREZ M. Effectiveness of predicting tunneling-induced ground settlements using machine learning methods with small datasets[J]. *Journal of rock mechanics and geotechnical engineering*, 2022, 14(4): 1028-1041.
- [26] 王长虹, 朱合华, 徐子川, 等. 考虑岩土参数空间变异性的盾构隧道地表沉降分析[J]. *岩土工程学报*, 2018, 40(2): 270-277.
WANG Changhong, ZHU Hehua, XU Zichuan, et al. Ground surface settlement of shield tunnels considering spatial variability of multiple geotechnical parameters[J]. *Chinese journal of geotechnical engineering*, 2018, 40(2): 270-277.
- [27] GE Shuangshuang, GAO Wei, CUI Shuang, et al. Safety prediction of shield tunnel construction using deep belief network and whale optimization algorithm[J]. *Automation in construction*, 2022, 142: 104488.
- [28] CHEN Renpeng, ZHANG Pin, WU Huaina, et al. Prediction of shield tunneling-induced ground settlement using machine learning techniques[J]. *Frontiers of structural and civil engineering*, 2019, 13(6): 1363-1378.
- [29] 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(S1): 13-19.
- [30] CHENG Zhiliang, KANNANGARA K K P M, SU Lijun, et al. Mathematical model for approximating shield tunneling-induced surface settlement *via* multi-gene genetic programming[J]. *Acta geotechnica*, 2023, 18(9): 4923-4940.
- [31] KANNANGARA K K P M, SU Lijun, ZHOU Wanhuan. Analysis of post-ground settlement induced during twin tunnelling in silty sand[J]. *Tunnelling and underground space technology*, 2024, 152: 105949.
- [32] WEN Zhu, GUO Limei, MENG Sipei, et al. IoT-assisted feature learning for surface settlement prediction caused by shield tunnelling[J]. *Computer communications*, 2023, 203: 276-288.
- [33] YIN Quan, ZHOU Yi, RAO Junying. An intelligent prediction method for surface settlement of shield tunnel construction based on CNN-BiLSTM-SA[J]. *KSCE journal of civil engineering*, 2025, 29(4): 100061.
- [34] WANG You, DAI Fang, JIA Ruxue, et al. A novel combined intelligent algorithm prediction model for the tunnel surface settlement[J]. *Scientific reports*, 2023, 13: 9845.
- [35] SHANG Wentao, LI Yan, WEI Huanwei, et al. Prediction method of longitudinal surface settlement caused by double shield tunnelling based on deep learning[J]. *Scientific reports*, 2024, 14(1): 908.
- [36] ZHANG Jian, ZHANG Chen, QIAN Hao, et al. Prediction of longitudinal surface settlement in composite formation using large-diameter shield machine based on machine learning techniques[J]. *Frontiers of structural and civil engineering*, 2024, 18(12): 1922-1936.
- [37] GENG Xiaojie, WU Shunchuan, YAN Qiong, et al. An optimized XGBoost model for predicting tunneling-induced ground settlement[J]. *Geotechnical and geological engineering*, 2024, 42(2): 1297-1311.
- [38] WANG Gan, FANG Qian, WANG Jun, et al. Artificial intelligence prediction of surface settlement induced by

- twin shields tunnelling[J]. Tunnelling and underground space technology, 2025, 161: 106606.
- [39] LIU Dejun, ZHANG Wenpeng, DUAN Kang, et al. Intelligent prediction and optimization of ground settlement induced by shield tunneling construction[J]. Tunnelling and underground space technology, 2025, 160: 106486.
- [40] 刘谨豪, 严远忠, 张琪, 等. 地面堆载对既有隧道影响离心试验和数值分析[J]. 上海交通大学学报, 2022, 56(7): 886-896.
- LIU Jinhao, YAN Yuanzhong, ZHANG Qi, et al. Centrifugal test and numerical analysis of impact of surface surcharge on existing tunnels[J]. Journal of Shanghai Jiao Tong University, 2022, 56(7): 886-896.
- [41] 徐敬民, 章定文, 刘松玉. 地表框架结构作用下隧道施工诱发的砂质地层变形[J]. 岩土工程学报, 2022, 44(4): 602-612.
- XU Jingmin, ZHANG Dingwen, LIU Songyu. Tunneling-induced sandy ground deformation affected by surface framed structures[J]. Chinese journal of geotechnical engineering, 2022, 44(4): 602-612.
- [42] HU Yao, TANG Haoran, XU Yinggang, et al. Effect of moving train load on ground movement and tunnel deformation due to stacked shield tunnelling[J]. Soil dynamics and earthquake engineering, 2024, 187: 108992.
- [43] WU Xianguo, FENG Zongbao, LIU Jun, et al. Predicting existing tunnel deformation from adjacent foundation pit construction using hybrid machine learning[J]. Automation in construction, 2024, 165: 105516.
- [44] 朱仔旭, 施成华, 陈海勇, 等. 考虑IPSO优化的CNN-LSTM盾构掘进参数混合预测模型[J]. 铁道科学与工程学报, 2025, 22(6): 2690-2702.
- ZHU Zixu, SHI Chenghua, CHEN Haiyong, et al. Hybrid CNN-LSTM shield tunneling parameter prediction model considering IPSOptimization[J]. Journal of Railway Science and Engineering, 2025, 22(6): 2690-2702.
- [45] HUANG Chongwei, DU Haohe, LI Lin, et al. Application of tree-based methods in predicting the surface settlement arising from the tunnel excavation with large mix-shield[J]. Soils and foundations, 2023, 63(6): 101379.
- [46] ZHAO Dukun, SUN Zhangang, HE Yueji, et al. Prediction of ground subsidence by shield tunneling using ensemble learning[J]. Tunnelling and underground space technology, 2023, 141: 105343.
- [47] LI Chuanqi, DIAS D. Intelligent prediction and visual optimization of surface settlement induced by earth pressure balance shield tunneling[J]. Tunnelling and underground space technology, 2024, 154: 106138.
- [48] Chen R P, Zou N, Cheng H Z, et al. Prediction of tunneling-induced surface settlement using a Bi-LSTM model with high generalization performance[M]. Smart Geotechnics for Smart Societies. CRC Press, 2023: 907-915.
- [49] CHEN Liang, HASHIBA K, LIU Zhitao, et al. Spatial-temporal fusion network for maximum ground surface settlement prediction during tunnel excavation[J]. Automation in construction, 2023, 147: 104732.
- [50] YANG Minghui, SONG Muyuan, GUO Yanwei, et al. Prediction of shield tunneling-induced ground settlement using LSTM architecture enhanced by multi-head self-attention mechanism[J]. Tunnelling and underground space technology, 2025, 161: 106536.
- [51] LAI Jianbo, ZHU Jun, GUO Yukun, et al. A multi-factor-driven approach for predicting surface settlement caused by the construction of subway tunnels by undercutting method[J]. Environmental earth sciences, 2024, 83(15): 442.
- [52] 潘秋景, 吴洪涛, 张子龙, 等. 基于多域物理信息神经网络的复合地层隧道掘进地表沉降预测[J]. 岩土力学, 2024, 45(2): 539-551.
- PAN Qiujing, WU Hongtao, ZHANG Zilong, et al. Prediction of tunneling-induced ground surface settlement within composite strata using multi-physics-informed neural network[J]. Rock and soil mechanics, 2024, 45(2): 539-551.
- [53] WANG Guankai, SHAN Yao, DETMANN B, et al. Physics-Informed Neural Network (PINN) model for predicting subgrade settlement induced by shield tunnelling beneath an existing railway subgrade[J]. Transportation geotechnics, 2024, 49: 101409.
- [54] ZHANG Dongmei, GUO Xiaoyang, SHEN Yiming, et al. Data- and experience-driven neural networks for long-term settlement prediction of tunnel[J]. Tunnelling and underground space technology, 2024, 147: 105669.
- [55] NIE Cong, ZHANG Dongming, OUYANG Linghan, et al. Dynamic prediction of longitudinal settlement of existing tunnel using ConvRes-DLinear model with integration of undercrossing construction process information[J]. Geosciences, 2023, 13(7): 189.
- [56] 管浩, 刘维, 王峰, 等. 基于数据增强和机器学习算法的盾构隧道引发地面沉降预测及应用[J]. 隧道建设(中英文), 2022, 42(增刊1): 331-341.
- GUAN Hao, LIU Wei, WANG Feng, et al. Prediction of Surface Settlement Caused by Shield Tunneling Based on Data Enhancement and Machine Learning Algorithm[J]. Tunnel construction, 2022, 42(S1): 331-341.

(下转第105页)

- LIAO Haishan, LI Yingzhou. Application of automatic deformation monitoring system on operational metro tunnel monitoring[J]. Geomatics & spatial information technology, 2021, 44(2): 193-195.
- [6] 黄俊, 张顶立, 梁文灏, 等. 服役期隧道结构安全控制技术综述[J]. 铁道标准设计, 2024, 68(4): 1-19.
HUANG Jun, ZHANG Dingli, LIANG Wenhao, et al. Research status of safety control technology for tunnel structures during service period[J]. Railway standard design, 2024, 68(4): 1-19.
- [7] 北京市质量技术监督局. 城市轨道交通设施养护维修技术规范: DB11/T 718—2016[S]. 北京: 中国铁道出版社, 2016.
- [8] 中国科技产业化促进会. 城市轨道交通地下结构健康检测监测: T/CSPSTC 43—2019[S]. 北京: 中国标准出版社, 2019.
- [9] 胡昆昆, 蔡国军, 闫超, 等. 浸水条件对浅埋湿陷黄土隧道受力性状影响的大型模型试验研究[J]. 科学技术与工程, 2022, 22(27): 12156-12166.
HU Kunkun, CAI Guojun, YAN Chao, et al. Large scale model test study on the influence of soaking conditions on the mechanical behavior of shallow buried collapsible loess tunnel[J]. Science technology and engineering, 2022, 22(27): 12156-12166.
- [10] 王武刚, 胡昆昆, 李又云, 等. 浸水湿陷黄土隧道加固地基受力与变形性状数值研究[J]. 南京工业大学学报(自然科学版), 2022, 44(6): 664-674.
WANG Wugang, HU Kunkun, LI Youyun, et al. Numerical study on stress and deformation characteristics of foundation reinforced by water soaked and collapsible loess tunnel[J]. Journal of Nanjing Tech University (Natural Science Edition), 2022, 44(6): 664-674.
- [11] 邵生俊, 李骏, 李国良, 等. 大厚度湿陷性黄土隧道现场浸水试验研究[J]. 岩土工程学报, 2018, 40(8): 1395-1404.
SHAO Shengjun, LI Jun, LI Guoliang, et al. Field immersion tests on tunnel in large-thickness collapsible loess[J]. Chinese journal of geotechnical engineering, 2018, 40(8): 1395-1404.
- [12] 董飞. 地铁隧道衬砌结构破坏机理与安全性评价[D]. 北京: 北京交通大学, 2018.
DONG Fei. Failure mechanism and safety assessment of metro tunnel lining[D]. Beijing: Beijing Jiaotong University, 2018.

(编辑: 傅依萱)

(上接第 86 页)

- [57] KANNANGARA K K P M, ZHOU Wanhuan, DING Zhi, et al. Investigation of feature contribution to shield tunneling-induced settlement using Shapley additive explanations method[J]. Journal of rock mechanics and geotechnical engineering, 2022, 14(4): 1052-1063.
- [58] ZHAO Shisen, FENG Xianda, PENG Kefeng. Prediction and parameter optimization of surface settlement induced by shield tunneling using improved informer algorithm[J]. Applied sciences, 2025, 15(12): 6766.
- [59] 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.
- [60] 张孟喜, 范杰, 吴惠明, 等. 基于 AG-PSO 的泥水平衡盾构地表沉降掘进主控参数优化与应用[J]. 现代隧道技术, 2024, 61(增刊 1): 223-233.
ZHANG Mengxi, FAN Jie, WU Huiming, et al. Optimization of Main Control Parameters for Ground Settlement during Slurry Balance Shield Tunnelling Based on AG-PSO and Its Application[J]. Modern tunnelling technology, 2024, 61(S1): 223-233.
- [61] 费瑞振, 邹洋, 彭立敏, 等. 考虑变形控制的盾构穿越高铁隧道掘进参数研究[J]. 铁道科学与工程学报, 2025, 22(6): 2703-2716.
FEI Ruizhen, ZOU Yang, PENG Limin, et al. Research on tunneling parameters of shield tunneling through high speed railway tunnel considering deformation control[J]. Journal of Railway Science and Engineering, 2025, 22(6): 2703-2716.
- [62] 吴贤国, 冯宗宝, 刘俊, 等. 基于 RF-NSGA- II 的盾构施工地表沉降安全控制多目标优化[J]. 中国安全科学学报, 2022, 32(8): 45-51.
WU Xianguo, FENG Zongbao, LIU Jun, et al. Multi-objective optimization of surface settlement safety control during shield construction based on RF-NSGA- II [J]. China safety science journal, 2022, 32(8): 45-51.
- [63] 吴贤国, 刘俊, 苏飞鸣, 等. 基于 CatBoost-MOEAD 的大直径泥水盾构施工多目标预测优化[J]. 中国安全科学学报, 2024, 34(6): 57-64.
WU Xianguo, LIU Jun, SU Feiming, et al. Multi-objective prediction optimization for large-diameter slurry shield tunneling construction based on CatBoost-MOEAD[J]. China safety science journal, 2024, 34(6): 57-64.

(编辑: 傅依萱)