

DOI:10.16544/j.cnki.cn43-1494/u.20240912002

文章编号:1674-599X(2025)01-0051-09

引用格式:蒋磊,翁晓轩,谭泽,等.融合自注意力机制的PSO-LSTM地下管线沉降预测方法[J].交通科学与工程,2025,41(1):51-59.

Citation: JIANG Lei, WENG Xiaoxuan, TAN Ze, et al. A PSO-LSTM method integrated with self-attention mechanism for prediction of underground pipeline settlement [J]. Journal of Transport Science and Engineering, 2025, 41(1): 51-59.

融合自注意力机制的PSO-LSTM地下管线沉降预测方法

蒋磊¹, 翁晓轩^{2,3}, 谭泽^{2,3}, 刘晶^{2,3}, 黎永索^{2,3}, 胡达^{2,3}

(1. 长沙市轨道交通集团有限公司, 湖南 长沙 410021; 2. 湖南城市学院 城市地下基础设施结构安全与防灾湖南省工程研究中心, 湖南 益阳 413002; 3. 湖南城市学院 土木工程学院, 湖南 益阳 413002)

摘 要:【目的】地下管线沉降是矩形顶管隧道施工过程中的关键参数。传统的预测方法往往依赖于经验模型和统计分析,难以准确地预测复杂隧道结构的沉降。【方法】针对这一挑战,提出一种融合自注意力(Self-Attention)机制基于粒子群优化(particle swarm optimization, PSO)算法及长短期记忆(long short-term memory, LSTM)神经网络的地下管线沉降预测方法。首先,引入自注意力机制,通过自适应地为不同时间步赋予不同的权重,增强LSTM神经网络对关键时间节点的关注,捕捉时间序列中的重要信息。然后,利用PSO算法优化LSTM神经网络的超参数,确保LSTM神经网络能够以最优的结构处理输入数据,提取输入数据中的时序特征,捕捉长短期依赖关系。最后,通过LSTM神经网络的全连接层输出地表沉降的预测值。为了验证该算法的优越性和鲁棒性,利用长沙市轨道交通6号线工程的实测数据构建地下管线沉降数据集,针对LSTM、LSTM-Self-Attention及PSO-LSTM-Self-Attention模型对不同位置顶管沉降的预测情况展开对比分析。【结果】融合自注意力机制的PSO-LSTM地下管线沉降预测模型的均方误差、均方根误差、平均绝对误差及决定系数四个指标均为最优。【结论】融合自注意力机制的PSO-LSTM模型具有更优的地下管线沉降预测性能。

关键词:地下管线沉降预测;深度学习;长短期记忆神经网络;自注意力机制;粒子群优化算法

中图分类号:U45

文献标志码:A

A PSO-LSTM method integrated with self-attention mechanism for prediction of underground pipeline settlement

JIANG Lei¹, WENG Xiaoxuan^{2,3}, TAN Ze^{2,3}, LIU Jing^{2,3}, LI Yongsuo^{2,3}, HU Da^{2,3}

(1. Changsha Metro Group Co., Ltd., Changsha 410021, China; 2. Hunan Engineering Research Center of Structural Safety and Disaster Prevention for Urban Underground Infrastructure, Hunan City University, Yiyang 413002, China; 3. College of Civil Engineering, Hunan City University, Yiyang 413002, China)

Abstract: [Purposes] Underground pipeline settlement is a key parameter during the construction of rectangular pipe jacking tunnels. Traditional prediction methods mostly rely on empirical models and statistical analysis, which struggle to accurately predict settlement in complex tunnel structures. [Methods] To address this challenge, this paper proposes a Self-Attention mechanism integrated prediction method for underground pipeline settlement based on particle swarm optimization (PSO) and a long short-term memory (LSTM) neural network. First, the Self-Attention mechanism is

收稿日期:2024-09-12

基金项目:国家自然科学基金项目(51678226);湖南省自然科学基金项目(2023JJ30110);湖南省教育厅科学研究重点项目(23A0568)

通信作者:蒋磊(1986—),男,高级工程师,主要从事城市轨道交通与隧道工程方面的研究工作。E-mail:724514248@qq.com

投稿网址:https://jtkxygc.csust.edu.cn/jtkxygc/home

introduced to adaptively assign different weights to different time steps, which enhances focus of the LSTM neural network on critical time points and is conducive to capturing important information from the time series. Next, the PSO algorithm is used for hyperparameter optimization of the LSTM neural network to ensure that it can process the input data with optimal configuration. The LSTM neural network is responsible for extracting temporal features from the input data and capturing long short-term dependencies. Finally, the model outputs the predicted surface settlement through a fully connected layer of the LSTM neural network. To verify the superiority and robustness of the proposed algorithm, a dataset of underground pipeline settlement was constructed using measured data from the Changsha Metro Line 6 project. The prediction performance of pipe jacking settlement at different tunnel locations was compared using the LSTM, LSTM-Self-Attention, and PSO-LSTM-Self-Attention models. [Findings] The results show that the PSO-LSTM-Self-Attention model outperforms the others in terms of mean squared error, root mean squared error, mean absolute error, and the coefficient of determination. [Conclusions] This study validates that the PSO-LSTM-Self-Attention model exhibits superior performance in predicting underground pipeline settlement.

Key words: prediction of underground pipeline settlement; deep learning; long short-term memory neural network; Self-Attention mechanism; particle swarm optimization

随着我国城市地下空间开发利用的快速发展,矩形顶管隧道施工以其安全、环保、高效和适应性强等优点被广泛应用于市政、地铁及公路等项目的隧道工程中^[1]。顶管的沉降过大,可能会导致地面塌陷、地下水位变化、地基承载力减小、周围建筑物基础破坏及地下管线破裂等问题,也可能会改变地下土体的含水量和力学性质,引发土体的压缩或膨胀变形,对地下设施的安全运营构成威胁。由于现场地质环境和施工工艺的复杂性,预测矩形顶管隧道施工时地下管线的沉降具有很大的不确定性。当前,国内外学术界尚没有找到获得一致认可的预测方法,因此,探索一种准确有效的地下管线沉降预测模型对降低超浅埋大断面矩形顶管隧道的施工风险,减少生态破坏,促进矩形顶管隧道设计理论的发展具有重要的理论和工程实践意义。

目前,顶管沉降的预测方法主要有试验分析法、统计法^[2-3]、数值模拟法^[4-6]、监测方法^[7]、PECK法^[8-9]和经验公式法^[10-12]等。试验分析法受施工工艺、操作的不确定性、模型尺寸及材料参数的影响,极易导致试验结果与工程实际相差较大,难以指导实际工程。数值模拟法受本构模型和边界条件的限制,易导致预测结果与实际情况存在偏差。统计方法需要大量的历史施工数据作为支撑,如果数据量不足或数据质量不高,预测结果可能不准确。经验公式法具有一定的地域性,对于不同的地区或不同的工程条件,可能需要调整参数或选择其他公式,且公式缺乏充分的理论依据,可能无法考虑所有的影响因素,预测结果亦存在较大误差。

采用监测方法时,监测设备受施工环境的影响,可能导致监测数据不准确或无法获取,因此,监测方法通常只能提供实时的沉降数据,对于未来沉降趋势的预测能力有限。PECK法主要适用于预测盾构隧道施工引起的地面沉降^[13],对于顶管施工引起的地面沉降不完全适用,且其公式中的某些参数受施工环境的影响可能发生变化,导致预测结果不准确。

随着人工智能技术的快速发展,机器学习预测方法也逐渐被应用于岩土工程和隧道工程领域,如隧道施工地面沉降预测^[14-19]、掘进参数预测^[20-22]、姿态控制^[23-25]等。由于矩形顶管隧道穿越的城市建筑密集区的地层环境比较复杂,加上受地表随机荷载、施工工艺的影响,顶管沉降呈现出高度非线性的特征。相较于传统方法,机器学习预测方法在处理数据的随机性、不确定性和非线性方面有着独特的优势。由于顶管机及管道与地层之间存在着复杂的相互作用机理,人工智能在顶管沉降预测中的应用仍然较少。部分学者基于机器学习方法预测了隧道顶管的运动轨迹,如YANG等^[24]提出了一种基于门控循环单元的深度学习框架来动态预测顶管机的移动轨迹,用以辅助顶管隧道顶管机的施工。

近年来,长短期记忆(long short-term memory, LSTM)神经网络和融合自注意力(Self-Attention)机制^[26-28]的Transformer模型^[29-30]迅速发展,在自然语言处理领域得到广泛的应用,特别是用于文本生成和机器翻译任务^[31-32],但较少用于隧道顶管沉降的预测。

由于传统的机器学习算法不能考虑到前一时刻的沉降对后续沉降的影响,本文提出融合自注意力机制的矩形顶管沉降预测模型:1) 结合LSTM和自注意力机制在处理时间序列数据上的优点,建立融合自注意力机制的LSTM模型,在多个层次上捕捉序列中的关键信息(整体结构和上下文信息);2) 通过粒子群优化(particle swarm optimization, PSO)算法自动调整LSTM模型的参数,提升模型的性能,以期对矩形顶管隧道施工时地下管线沉降的预测提供一种新的、有效的研究手段。

1 算法简介

1.1 长短期记忆神经网络

循环神经网络(recurrent neural network, RNN)是一种专门用于处理时间序列数据的模型,具有允许跨网络共享参数的存储器,可以用来学习顶管隧道的地下管线沉降数据的非线性特征。RNN的当前状态可以通过隐藏层转移为下一时刻的状态,同时,当前状态也受隐藏层中存储的前一时刻状态的影响。这种机制意味着:RNN适合处理时间序列数据^[33],在自然语言处理领域表现良好^[34]。然而,当时间序列数据较长时,RNN会出现梯度消失或梯度爆炸的问题^[35]。

LSTM是一种特殊的循环神经网络,旨在解决RNN在处理长序列数据时出现的梯度消失或梯度爆炸问题,其内部的处理单元包括遗忘门 f_t 、输入门 i_t 、输出门 o_t 及存储单元^[36-37]。LSTM神经网络如图1所示。

遗忘门 f_t 控制旧的信息被遗忘的程度:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

式中: σ 是sigmoid激活函数; W_f 是遗忘门的权重矩

阵; h_{t-1} 是上一时刻的隐藏状态; x_t 是当前时刻的输入; b_f 是遗忘门的偏置项。

输入门 i_t 决定哪些新的信息被添加到细胞状态中:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t \quad (3)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (4)$$

式中: c_t 为细胞更新后的状态; $\tilde{c}_t$ 表示当前细胞的状态; c_{t-1} 是上一时刻的细胞状态; W_i 、 W_c 为权重矩阵; b_c 为偏置项。

输出门 o_t 确定细胞状态的哪些部分作为输出:

$$o_t = \sigma(W_o[h_{t-1}, x_t]) \quad (5)$$

$$h_t = o_t \tanh(c_t) \quad (6)$$

式中: h_t 为当前时刻的隐藏状态; W_o 为输出门的权重矩阵。

上述公式表明,LSTM能够处理时间序列数据中的长期依赖关系,能够处理变长的输入序列,但LSTM结构复杂,训练时需要较大的数据集以避免过拟合。

1.2 自注意力机制

自注意力机制的计算过程基于查询(Query)、键(Key)和值(Value)三个核心向量的实现。首先,将输入数据通过线性变换映射为查询向量 Q 、键向量 K 和值向量 V ;然后,通过 Q 与 K 的转置矩阵的点乘计算^[38],得到表征序列元素间相关性的注意力分数矩阵;接着,为获得标准化的权重分布,采用归一化指数函数(Softmax)对注意力分数进行概率化处理;最后,通过加权求和运算将处理后的权重矩阵作用于值向量 V ,生成包含上下文关联信息的新特征 C ^[39]。

本文的预测模型,采用单头注意力机制架构,仅需构建单一的自注意力层。该层通过上述计算过程,建




图1 LSTM神经网络

Fig. 1 LSTM neural network

立输入序列各位置间的全连接注意力映射关系,即通过计算每个序列位置与其他位置的注意力权重,实现基于全局上下文信息的动态特征加权。这种机制可有效捕获序列内部的长距离依赖关系,最终输出具有增强表征能力的特征向量。

自注意力机制原理如图2所示。 X 为输入数据, W_q 、 W_k 、 W_v 为三个参数矩阵, C 为最终得到的结果。采用归一化指数函数(Softmax)对注意力分数进行概率化处理,得到 a_i ,公式为:

$$a_i = \text{softmax}\left(\frac{QK^T}{\sqrt{dk}}\right) \quad (7)$$

式中: d 为向量 Q 与 K 的维度; k 为输入序列中每个位置的维度。




图2 自注意力机制原理

Fig. 2 Principle of Self-Attention mechanism

1.3 粒子群优化算法

PSO是一种改进的全局寻优算法,起源于对大自然中鸟群或鱼群等生物群体觅食行为的研究^[40]。PSO因其能够自适应地调整搜索策略,在不同的环境中表现出较好的鲁棒性而被广泛使用。PSO优化LSTM-Self-Attention模型的流程如图3所示。PSO算法中每个粒子的速度和位置的更新公式为:

$$v_i^{(j)}(t+1) = C_1 r_1 [p_{best,i}^{(j)}(t) - x_i^{(j)}(t)] + C_2 r_2 [g_{best,i}^{(j)}(t) - x_i^{(j)}(t)] + w(t)v_i^{(j)}(t) \quad (8)$$

$$x_i^{(j)}(t+1) = v_i^{(j)}(t+1) + x_i^{(j)}(t) \quad (9)$$

$$w(t) = w_{max} - (w_{max} - w_{min}) \frac{t}{t_{max}} \quad (10)$$

式中: C_1 、 C_2 为学习因子; r_1 、 r_2 为(0,1)区间的随机数; i 为粒子编号; j 为迭代的代数; t 为当前的迭代次数; $v_i^{(j)}(t+1)$ 为第 i 个粒子在第 $t+1$ 次迭代的速度; $v_i^{(j)}(t)$ 为第 i 个粒子在第 t 次迭代的速度; $x_i^{(j)}(t+1)$ 为第 i 个粒子在第 $t+1$ 次迭代的位置; $x_i^{(j)}(t)$ 为第 i 个粒子在第 t 次迭代的位置; $p_{best,i}^{(j)}(t)$ 为第 i 个粒子迄今为止找到的最好位置; $g_{best,i}^{(j)}(t)$ 为整个粒子群体迄今为止找到的最好位置; $w(t)$ 为惯性权重因子,可以调整寻优算法的搜索能力; w_{max} 为初始的最大惯性权重; w_{min} 为最终的最小惯

性权重; t_{max} 为最大迭代次数。

隧道施工引起地下管线沉降,沉降数据往往呈现出高度非线性的时序特性。传统的LSTM网络在捕捉较长的时间依赖性方面存在局限,而自注意力机制能够根据输入序列中不同时间点的信息的重要性,动态调整其对过去和未来数据的关注程度,从而更加有效地提取时间序列中的关键特征。通过这一机制,模型能够更加精确地反映地下管线沉降过程中的复杂时变特性,尤其是在考虑不同施工阶段的不同影响时。




图3 技术流程

Fig. 3 Technical flowchart

2 融合自注意力机制的 PSO-LSTM 模型

融合自注意力机制的LSTM神经网络能够动态地调整对不同时间步的关注度,建立全局的依赖关系,从而更好地处理长序列数据。PSO算法可以对LSTM神经网络的超参数进行优化,其超强的全局搜索能力确保了模型的鲁棒性,并帮助模型在复杂的环境中取得最佳性能。

2.1 网络结构设计

LSTM模型基于循环神经网络,可保留已知的合理特征,忽略不完美的特征,并继续前进。通过在两层LSTM神经网络的中间添加自注意力层,模型能够更灵活地关注输入序列中的重要部分,更好地捕捉和处理输入序列中的关键信息,同时也增强了模型的可解释

性。另外,模型可通过添加正则化随机失活防止过拟合。

2.2 PSO 优化

在模型训练的过程中,LSTM 神经网络的神经元数目、学习率、随机失活、批量大小对模型精度的影响很大,因此选择这些超参数作为优化的对象。

表 1 超参数取值范围

Table 1 Ranges of hyperparameter values

超参数	取值范围
神经元数目	100 ~ 200
学习率	0.000 1 ~ 0.010 0
随机失活	0.1 ~ 0.5
批量大小	16 ~ 128

模型其他的超参数采用自适应矩估计优化器进行选择,损失函数为均方误差(mean squard error, MSE),激活函数为修正线性单元,迭代次数为 200 次。

2.3 模型训练

本文试验在配备 Intel Core i5-13600KF、32GB 内存和 NVIDIA GeForce GTX 4070 显卡的计算机上进行。模型开发环境为 Python 3.9,代码实现基于 TensorFlow 2.15 深度学习框架。数据集划分、模型构建、模型评估和超参数优化等工作涉及的工具包括 JupyterLab、PyCharm、Keras 库和 Scikit-learn 库。

2.4 模型测试与评估

本文利用训练集对融合自注意力机制的 PSO-LSTM 模型进行训练,利用验证集对模型的超参数进行配置,利用测试集对模型进行测试,并评估模型的泛化能力和预测的准确性。本文选取 MSE、均方根误差(root mean squard error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数 R^2 作为评价指标^[41]。MSE、RMSE 和 MAE 越小, R^2 越接近 1,说明模型的预测效果越好。

3 数据库建立

3.1 项目概况

长沙市轨道交通 6 号线芙蓉区政府站(原东郡站) 2 号出入口的连接通道采用机械式矩形顶管法施工。芙蓉区政府站位于人民东路与万家丽路交叉口的西侧,沿人民东路东西向布置,2 号出入口的连接通道自西向东穿过万家丽路。

连接通道顶管的长度为 68.5 m,顶部覆土厚度为 3.8 ~ 6.3 m,与市政道路的最小竖向距离为 3.8 m,与高

架桥桩的最小水平距离为 2.9 m。顶管穿过雨污合流管,与周边管线的最小净距约为 1.0 m。同时,顶管上跨长沙市轨道交通 5 号线的盾构区间,其底部距离该盾构区间约 1.6 m。顶管卫星平面图如图 4 所示。




图 4 顶管卫星平面图

Fig. 4 Satellite plan of pipe jacking

顶管纵断面如图 5 所示。隧道穿越的土壤以强风化泥质粉砂岩为主,土层性质见表 2。项目涉及的地下管线数量为 31 条,为获取数据对这 31 条管线进行了为期 168 d 的监测。本文选取其中 4 条具有代表性的管线(GX7、GX14、GX17、GX18)建立顶管隧道地下管线沉降数据集。




图 5 顶管纵断面

Fig. 5 Longitudinal section of pipe jacking

表 2 土层性质

Table 2 Soil layer properties

土壤类型	平均揭露层厚/m	天然密度/($\text{g} \cdot \text{cm}^{-3}$)	黏聚力/kPa	内摩擦角/($^{\circ}$)	泊松比
杂填土	0.88	1.81	14	18	0.29
粉质黏土	3.66	1.90	25	20	0.25
强风化泥质粉砂岩	2.08	2.25	15	25	0.25
中风化泥质粉砂岩	1.60	2.35	30	28	0.29

3.2 数据准备

本文先从 31 条地下管线中选取 4 条有代表性的管线,再从这 4 条管线的监测点分别获取 168 d 的监测数据,将监测数据按照 8:2 的比例划分为训练集和测试集。为提高模型的泛化能力,所有数据需进行归一化

预处理。考虑到样本量较小的实际情况,本文采用滑动窗口法构建输入序列,按照步长 4 对监测数据进行序列重组,通过滑动预测机制生成训练样本。

在模型的训练阶段,将训练集按照 8:2 的比例进一步细分为训练子集和验证集,验证集的数据用于对模型的参数进行调优,防止过拟合。模型训练完成后,利用测试集的数据对模型的性能进行评估,确保评估的结果真实反映模型的泛化能力。

4 结果与讨论

4.1 预测结果

本节主要内容是检验顶管隧道地下管线沉降预测的效果,比较融合自注意力机制的 PSO-LSTM 模型(PSO-LSTM-Self-Attention)、LSTM 模型、融合自注意力机制的 LSTM 模型(LSTM-Self-Attention)及基于粒子群算法优化的支持向量回归(support vector regression, SVR)模型(PSO-SVR)的预测性能。

模型的误差见表 3~6。模型的预测结果如图 6~9 所示。由表 3~6 可知,在多数情况下融合自注意力机制的 PSO-LSTM 模型的指标 MAE、MSE、RMSE 及 R^2 优于其他三种模型的相应指标。相较于传统的 LSTM、LSTM-Self-Attention 和 PSO-SVR 模型,融合自注意力机制的 PSO-LSTM 模型对矩形顶管隧道施工时地下管线沉降预测的精度更高。

4.2 分析与讨论

自注意力机制使得模型能够自适应地关注输入序列中的重要信息,并赋予不同时间步的输入不同的权重。PSO 能够有效避免局部最优解,保证 LSTM 神经网络能在更广泛的参数空间内找到最优解。试验证明,PSO-LSTM-Self-Attention 在多个任务和数据集上都表现良好,比传统的 LSTM 模型具有更好的泛化能力和稳定性。由图 6~9 可知,经过 PSO 优化过的模型,由于超参数的选择更合理,故拟合度更高,鲁棒性更好;PSO-LSTM-Self-Attention 模型的预测性能在四个模型中最优。

表 3 模型误差(GX7 管线)

Table 3 Model errors (GX7 pipeline)

模型	MSE/ mm ²	RMSE/ mm	MAE/ mm	R^2
LSTM	0.088	0.298	0.233	0.346
LSTM-Self-Attention	0.088	0.296	0.227	0.352
PSO-SVR	0.083	0.289	0.221	0.384
PSO-LSTM-Self-Attention	0.086	0.293	0.216	0.367

表 4 模型误差(GX14 管线)

Table 4 Model errors (GX14 pipeline)

模型	MSE/ mm ²	RMSE/ mm	MAE/ mm	R^2
LSTM	0.181	0.426	0.36	0.207
LSTM-Self-Attention	0.187	0.433	0.369	0.181
PSO-SVR	0.114	0.338	0.289	0.501
PSO-LSTM-Self-Attention	0.091	0.303	0.247	0.598

表 5 模型误差(GX17 管线)

Table 5 Model errors (GX17 pipeline)

模型	MSE/ mm ²	RMSE/ mm	MAE/ mm	R^2
LSTM	0.196	0.443	0.363	0.005
LSTM-Self-Attention	0.208	0.456	0.376	0.053
PSO-SVR	0.092	0.303	0.248	0.535
PSO-LSTM-Self-Attention	0.090	0.300	0.248	0.543

表 6 模型误差(GX18 管线)

Table 6 Model errors (GX18 pipeline)

模型	MSE/ mm ²	RMSE/ mm	MAE/ mm	R^2
LSTM	0.165	0.406	0.315	0.361
LSTM-Self-Attention	0.240	0.490	0.386	0.069
PSO-SVR	0.234	0.484	0.370	0.094
PSO-LSTM-Self-Attention	0.123	0.351	0.292	0.523




图 6 模型预测结果(GX7 管线)

Fig. 6 Prediction results of models (GX7 pipeline)




图 7 模型预测结果(GX14 管线)

Fig. 7 Prediction results of models (GX14 pipeline)




图8 模型预测结果(GX17管线)

Fig. 8 Prediction results of models (GX17 pipeline)




图9 模型预测结果(GX18管线)

Fig. 9 Prediction results of models (GX18 pipeline)

5 结论

本文提出了一种融合自注意力机制的PSO-LSTM地下管线沉降预测模型,对顶管隧道施工引起的地下管线沉降进行了预测,主要工作及结论如下:

1) 深度学习算法为顶管隧道地下管线沉降的预测提供了新方向。以长沙市轨道交通6号线的顶管隧道施工为案例,获取了31组长达168 d的地下管线沉降数据,通过对比选取了其中的4组数据用于模型的训练和预测。

2) 本文构建的融合自注意力机制的PSO-LSTM地下管线沉降预测模型结合了自注意力机制和LSTM神经网络的优点,具有较好的适用性,可作为顶管沉降预测的一种有效辅助手段,可为类似工程提供一定的参考。

参考文献(References):

- [1] 马安震,刘洋,左旭.我国矩形顶管隧道应用现状及面临的技术难题探析[J].科技创新与应用,2023,13(11):181-184. DOI: 10.19981/j. CN23-1581/G3.2023.11.044.
MA Anzhen, LIU Yang, ZUO Xu. Application status

and technical problems of rectangular pipe jacking tunnel in China [J]. Technology Innovation and Application, 2023, 13(11): 181-184. DOI: 10.19981/j. CN23-1581/G3.2023.11.044.

- [2] 张治成,林思,王金昌,等.矩形管廊顶管施工对邻近管线的影响研究[J].岩土工程学报,2020,42(增刊2):244-249. DOI:10.11779/CJGE2020S2043.
ZHANG Zhicheng, LIN Si, WANG Jinchang, et al. Influences of pipe-jacking of rectangular utility tunnels on adjacent pipelines [J]. Chinese Journal of Geotechnical Engineering, 2020, 42(sup 2): 244-249. DOI:10.11779/CJGE2020S2043.
- [3] MA W, WANG B, WANG X, et al. Soil layer disturbance caused by pipe jacking: measurement and simulation of a case study [J]. KSCE Journal of Civil Engineering, 2021, 25(4): 1467-1478. DOI: 10.1007/s12205-021-2262-4.
- [4] LI X, LI P, LIU X, et al. Surface subsidence pattern of construction of pipe jacking in water-rich sand layer cross passage measured and numerical simulation analysis [J]. Structures, 2024, 60: 105949. DOI: 10.1016/j.istruc.2024.105949.
- [5] 丰土根,周坤,张箭,等.大截面矩形顶管施工对既有管线影响研究[J].工程力学,2024,41(5):1-12. DOI: 10.6052/j.issn.1000-4750.2023.11.ST05.
FENG Tugen, ZHOU Kun, ZHANG Jian, et al. study on the impact of large cross-section rectangular pipejacking construction on existing pipelines [J]. Engineering Mechanics, 2024, 41(5): 1-12. DOI: 10.6052/j.issn.1000-4750.2023.11.ST05.
- [6] 邓婷,黄茂松,时振昊,等.软黏土深埋矩形顶管施工地层变形分析[J].土木工程学报,2023,56(增刊2):157-162. DOI: 10.15951/j.tmgcxb.2023.s2.wt10.
DENG Ting, HUANG Maosong, SHI Zhenhao, et al. Ground deformation response induced by jacking process of deep rectangular tunnel in soft clay [J]. China Civil Engineering Journal, 2023, 56(sup 2): 157-162. DOI: 10.15951/j.tmgcxb.2023.s2.wt10.
- [7] 陈聪,郑新定,陈扬勋,等.武汉首例矩形顶管地铁出入口施工监测及数值模拟分析[J].隧道建设,2013,33(5):354-361. DOI:10.3973/j.issn.1672-741X.2013.05.004.
CHEN Cong, ZHENG Xinding, CHEN Yangxun, et al. Construction monitoring and numerical simulation analysis of the first metro entrance/exit tunnel constructed by rectangular pipe jacking method in Wuhan [J]. Tunnel Construction, 2013, 33(5): 354-361. DOI: 10.3973/j.issn.1672-741X.2013.05.004.
- [8] FANG K, YANG Z, JIANG Y, et al. Surface subsidence characteristics of fully overlapping tunnels constructed using tunnel boring machine in a clay stratum [J]. Computers and Geotechnics, 2020, 125: 103679. DOI: 10.1016/j.compgeo.2020.103679.

- [9] YANG X, LI Y. Research of surface settlement for a single arch long-span subway station using the pipe-roof pre-construction method [J]. Tunnelling and Underground Space Technology, 2018, 72: 210-217. DOI: 10.1016/j.tust.2017.11.024.
- [10] 魏纲, 徐日庆, 屠玮. 顶管施工引起的土体扰动理论分析及试验研究[J]. 岩石力学与工程学报, 2004, 23(3): 476-482. DOI: 10.3321/j.issn: 1000-6915.2004.03.022.
WEI Gang, XU Riqing, TU Wei. Theoretical analysis and experimental study on soil disturbance caused by pipe jacking construction [J]. Chinese Journal of Rock Mechanics and Engineering, 2004, 23(3): 476-482. DOI: 10.3321/j.issn: 1000-6915.2004.03.022.
- [11] 朱合华, 吴江斌, 潘同燕. 曲线顶管的三维力学模型理论分析与应用[J]. 岩土工程学报, 2003, 25(4): 492-495. DOI: 10.3321/j.issn: 1000-4548.2003.04.024.
ZHU Hehua, WU Jiangbin, PAN Tongyan. Theoretical analysis of three-dimensional mechanical model of curved pipe jacking and its application [J]. Chinese Journal of Geotechnical Engineering, 2003, 25(4): 492-495. DOI: 10.3321/j.issn: 1000-4548.2003.04.024.
- [12] 张坤勇, 李丹阳, 张梦, 等. 大断面管幕箱涵顶进引起地表变形的解析解答[J]. 岩土工程学报, 2025, 47(1): 184-191. DOI: 10.11779/CJGE20231118.
ZHANG Kunyong, LI Danyang, ZHANG Meng, et al. The analytical solution of large section pipe curtain box culvert jacking on surface deformation [J]. Chinese Journal of Geotechnical Engineering, 2025, 47(1): 184-191. DOI: 10.11779/CJGE20231118.
- [13] 严健, 何川, 吴海彬, 等. 基于Peck公式的藏区公路隧道施工地面沉降预测[J]. 公路交通科技, 2015, 32(1): 110-115, 139. DOI: 10.3969/j.issn.1002-0268.2015.01.018.
YAN Jian, HE Chuan, WU Haibin, et al. Prediction of ground settlement for highway tunnel construction in Xizang based on Peck formula [J]. Journal of Highway and Transportation Research and Development, 2015, 32(1): 110-115, 139. DOI: 10.3969/j.issn.1002-0268.2015.01.018.
- [14] HU D, HU Y, YI S, et al. Prediction method of surface settlement of rectangular pipe jacking tunnel based on improved PSO-BP neural network [J]. Scientific Reports, 2023, 13: 5512. DOI: 10.1038/s41598-023-32189-0.
- [15] XU C, LIU X, WANG E, et al. Prediction of tunnel boring machine operating parameters using various machine learning algorithms [J]. Tunnelling and Underground Space Technology, 2021, 109: 103699. DOI: 10.1016/j.tust.2020.103699.
- [16] HU M, LI W, YAN K, et al. Modern machine learning techniques for univariate tunnel settlement forecasting: a comparative study [J]. Mathematical Problems in Engineering, 2019, 2019(1): 1-11. DOI: 10.1155/2019/7057612.
- [17] CHEN R, ZHANG P, WU H, 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. DOI: 10.1007/s11709-019-0561-3.
- [18] 潘伟强. 软土地区管幕群顶管施工地面沉降监测与分析[J]. 岩土工程学报, 2019, 41(增刊1): 201-204.
PAN Weiqiang. Monitoring and analysis of ground settlement during pipe roof construction of pipe-jacking groups in soft soil areas [J]. Chinese Journal of Geotechnical Engineering, 2019, 41(sup 1): 201-204.
- [19] 喻军, 龚晓南. 考虑顶管施工过程的地面沉降控制数值分析[J]. 岩石力学与工程学报, 2014, 33(增刊1): 2605-2610.
YU Jun, GONG Xiaonan. Numerical analysis of surface settlement control considering pipe jacking construction process [J]. Chinese Journal of Rock Mechanics and Engineering, 2014, 33(sup 1): 2605-2610.
- [20] MAHMOODZADEH A, NEJATI H R, MOHAMMADI M, et al. Forecasting tunnel boring machine penetration rate using LSTM deep neural network optimized by grey wolf optimization algorithm [J]. Expert Systems with Applications, 2022, 209: 118303. DOI: 10.1016/j.eswa.2022.118303.
- [21] HUANG H, CHANG J, ZHANG D, et al. Machine learning-based automatic control of tunneling posture of shield machine [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(4): 1153-1164. DOI: 10.1016/j.jrmge.2022.06.001.
- [22] XU H, ZHOU J, ASTERIS P G, et al. Supervised machine learning techniques to the prediction of tunnel boring machine penetration rate [J]. Applied Sciences, 2019, 9: 3715.
- [23] CHEN L, TIAN Z, ZHOU S, et al. Attitude deviation prediction of shield tunneling machine using time-aware LSTM networks [J]. Transportation Geotechnics, 2024, 45: 101195. DOI: 10.1016/j.trgeo.2024.101195.
- [24] YANG Y, LIAO S, LIU M. Dynamic prediction of moving trajectory in pipe jacking: GRU-based deep learning framework [J]. Frontiers of Structural and Civil Engineering, 2023, 17(7): 994-1010. DOI: 10.1007/s11709-023-0942-5.
- [25] KANG Q, CHEN J, LI Z, et al. Attention-based LSTM predictive model for the attitude and position of shield machine in tunneling [J]. Underground Space, 2023, 13: 335-350. DOI: 10.1016/j.undsp.2023.05.006.
- [26] GUO M, LIU Z, MU T, et al. Beyond self-attention: external attention using two linear layers for visual tasks [J]. IEEE Transactions on Pattern Analysis and

- Machine Intelligence, 2023, 45(5): 5436-5447. DOI: 10.1109/TPAMI.2022.3211006.
- [27] PAN S, YANG B, WANG S, et al. Oil well production prediction based on CNN-LSTM model with self-attention mechanism [J]. Energy, 2023, 284: 128701. DOI: 10.1016/j.energy.2023.128701.
- [28] HONG J, ZHANG H, XU X. Thermal fault prognosis of lithium-ion batteries in real-world electric vehicles using self-attention mechanism networks [J]. Applied Thermal Engineering, 2023, 226: 120304. DOI: 10.1016/j.applthermaleng.2023.120304.
- [29] CHITTY-VENKATA K T, MITTAL S, EMANI M, et al. A survey of techniques for optimizing transformer inference [J]. Journal of Systems Architecture, 2023, 144: 102990. DOI: 10.1016/j.sysarc.2023.102990.
- [30] KHAN A, RAUF Z, SOHAIL A, et al. A survey of the vision transformers and their CNN-transformer based variants [J]. Artificial Intelligence Review, 2023, 56(3): 2917-2970. DOI: 10.1007/s10462-023-10595-0.
- [31] SEIFOSSADAT E, SAMETI H. Data-to-text generation using conditional generative adversarial with enhanced transformer [J]. Natural Language Engineering, 2024, 30: 696-721.
- [32] ZHANG Hanqing, SONG Haolin, LI Shaoyu, et al. A survey of controllable text generation using transformer-based pre-trained language models [J]. ACM Computing Surveys, 2023, 56: 1-37.
- [33] LIU Z, LI L, FANG X, et al. Hard-rock tunnel lithology prediction with TBM construction big data using a global-attention-mechanism-based LSTM network [J]. Automation in Construction, 2021, 125: 103647. DOI: 10.1016/j.autcon.2021.103647.
- [34] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444. DOI: 10.1038/nature14539.
- [35] HOCHREITER S. The vanishing gradient problem during learning recurrent neural nets and problem solutions [J]. International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, 1998, 6(2): 107-116. DOI: 10.1142/s0218488598000094.
- [36] 王宇胜, 陈德旺, 蔡俊鹏, 等. 基于LSTM-SVR的锂电池健康状态预测研究 [J]. 电源技术, 2020, 44(12): 1784-1787.
- WANG Yusheng, CHEN Dewang, CAI Junpeng, et al. Research on lithium battery state of health prediction based on LSTM-SVR [J]. Chinese Journal of Power Sources, 2020, 44(12): 1784-1787.
- [37] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780. DOI: 10.1162/neco.1997.9.8.1735.
- [38] 刘建伟, 王园方, 罗雄麟. 深度记忆网络研究进展 [J]. 计算机学报, 2021, 44(8): 1549-1589. DOI: 10.11897/SP.J.1016.2021.01549.
- LIU Jianwei, WANG Yuanfang, LUO Xionglin. Research and development on deep memory network [J]. Chinese Journal of Computers, 2021, 44(8): 1549-1589. DOI: 10.11897/SP.J.1016.2021.01549.
- [39] 李鸿飞, 刘盼雨, 魏勇. 基于自注意力和Lattice-LSTM的军事命名实体识别 [J]. 计算机工程与科学, 2021, 43(10): 1848-1855. DOI: 10.3969/j.issn.1007-130X.2021.10.019.
- LI Hongfei, LIU Panyu, WEI Yong. Military named entity recognition based on self-attention and Lattice-LSTM [J]. Computer Engineering & Science, 2021, 43(10): 1848-1855. DOI: 10.3969/j.issn.1007-130X.2021.10.019.
- [40] 李季, 孙秀霞, 李士波, 等. 基于遗传交叉因子的改进粒子群优化算法 [J]. 计算机工程, 2008, 34(2): 181-183. DOI: 10.3969/j.issn.1000-3428.2008.02.060.
- LI Ji, SUN Xiuxia, LI Shibo, et al. Improved particle swarm optimization based on genetic hybrid genes [J]. Computer Engineering, 2008, 34(2): 181-183. DOI: 10.3969/j.issn.1000-3428.2008.02.060.
- [41] 谭风雷, 陈昊, 何嘉弘. 基于K-means聚类方法和相似时段的特高压并联电抗器油温预测 [J]. 电力自动化设备, 2021, 41(6): 213-219. DOI: 10.16081/j.epae.202103001.
- TAN Fenglei, CHEN Hao, HE Jiahong. Oil temperature forecasting of UHV shunt reactor based on K-means clustering method and similar period [J]. Electric Power Automation Equipment, 2021, 41(6): 213-219. DOI: 10.16081/j.epae.202103001.

(责任编辑:熊怡)