

# 数据不完备下基于 CNN-GRU 神经网络的 地铁基坑变形预测方法研究\*

周 意<sup>1</sup> 王章琼<sup>1</sup> 邹原耕<sup>2</sup> 蔡永辉<sup>1</sup> 徐晓雅<sup>1</sup> 赵歧林<sup>1</sup>

(1. 武汉工程大学土木工程与建筑学院, 430074, 武汉; 2. 中国水利水电第八工程局有限公司, 410004, 长沙)

**摘 要** [目的]为应对地铁基坑变形监测数据不完备导致的预测滞后和精度下降问题,提出一种基于 CNN-GRU 神经网络(卷积神经网络-门控循环单元神经网络)的基坑变形预测方法,并对此方法进行验证。[方法]利用基坑不完备变形监测数据和缺失监测点附近点位监测数据构建数据样本集,输入 CNN 模型中,完成缺失数据的填补修复,得到完整连续的基坑变形监测数据。利用小波分解提取变形监测数据中低频趋势分量和高频误差分量,利用 GRU 神经网络模型和 ARMA(自回归滑动平均)模型分别对低频趋势分量和噪声分量进行预测,再将预测结果合并得到最终变形预测结果。结合南京某地铁车站基坑工程案例,对该方法的有效性进行了验证。[结果及结论]采用基于 CNN-GRU 神经网络的基坑变形预测方法对缺失率达到 18.5% 和 10.1% 的基坑变形数据修复后进行预测时,预测误差分别为 1.926 6% 和 1.274 6%,预测精度分别提高了 35% 和 6%,可以看出该方法的数据修复能力表现良好,数据修复可靠度较高。对比 GA-BP 神经网络预测方法和 LSTM 预测方法,该方法的预测精度提升了 1 倍以上,且较好解决了预测滞后的问题,预测精度能够满足实际工程需要。

**关键词** 地铁; 基坑变形预测方法; CNN-GRU 神经网络; 数据不完备

**中图分类号** U231.3

**DOI**:10.16037/j.1007-869x.20230612

## Metro Foundation Pit Deformation Prediction Method Based on CNN-GRU Neural Network under Incomplete Data Condition

ZHOU Yi<sup>1</sup>, WANG Zhangqiong<sup>1</sup>, ZOU Yuangeng<sup>2</sup>, CAI Yonghui<sup>1</sup>, XU Xiaoya<sup>1</sup>, ZHAO Qilin<sup>1</sup>

(1. School of Civil Engineering and Architecture, Wuhan Institute of Technology, 430074, Wuhan China; 2. Sinohydro Engineering Bureau 8 Co., Ltd., 410004, Changsha, China)

**Abstract** [Objective] To address the issues of prediction delay and accuracy degradation caused by incomplete deformation monitoring data in metro foundation pits, a prediction

method based on a CNN-GRU (convolutional neural network-gated recurrent unit) neural network is proposed and verified. [Method] A data sample set is constructed using incomplete foundation pit deformation monitoring data and missing monitoring data from nearby monitoring points, and then input into the CNN model to complete data imputation and obtain continuous and complete monitoring data. Wavelet decomposition is applied to extract low-frequency trend components and high-frequency error components from the deformation data. The GRU neural network model and ARMA (autoregressive moving average) model are respectively used to predict the low-frequency trend and noise components, which are then combined to yield the final deformation prediction results. The foundation pit project at a metro station in Nanjing is used as case study to verify the effectiveness of the proposed method. [Result & Conclusion] When the proposed CNN-GRU-based prediction method is applied to foundation pit deformation data imputation with missing rates of 18.5% and 10.1%, the resulting prediction errors are 1.926 6% and 1.274 6%, respectively, and the prediction accuracy improves by 35% and 6%, respectively. These results demonstrate strong data recovery capability and high reliability of this method. Compared to the GA-BP neural network and LSTM prediction methods, the proposed method improves prediction accuracy by more than 100% and effectively addresses the issue of prediction lag. The accuracy of this method could meet the requirements of practical engineering applications.

**Key words** metro; foundation pit deformation prediction method; CNN-GRU neural network; incomplete data

基坑变形预测对工程人员掌握基坑变形趋势,保证基坑安全施工方面具有重要意义<sup>[1]</sup>。人工神经网络技术凭借其出色的数据处理分析能力在变形预测中得到了广泛的应用。众多学者利用人工神经网络对基坑施工过程中的变形监测数据进行

\* 国家自然科学基金项目(52278369);武汉工程大学第十四届研究生教育创新基金项目(CX2022165)

处理分析,以得到基坑后续变形趋势<sup>[2-4]</sup>。

在基坑监测过程中,常常会因为天气、施工影响等因素造成监测数据部分缺失。在利用监测数据建立基坑变形预测模型时,数据缺失会造成变形预测结果滞后和精度下降的问题<sup>[5-7]</sup>,导致最终预测结果无法满足实际工程需求。由于基坑监测数据的缺失量一般较大,基于邻近数据的插值方法难以满足填补修复要求。根据深基坑支护结构计算理论,基坑变形是由基坑开挖形成的围护结构内外压力差造成的,基坑外部土压力则是由基坑围护结构和支撑体系共同承担<sup>[8]</sup>,故考虑利用故障监测点附近的支撑内力监测数据和其他监测数据对该监测点缺失值进行回归分析,以完成对原始数据的修复<sup>[9]</sup>,即将数据补全问题转化为回归分析问题。

为此,本文提出一种基于 CNN-GRU 神经网络(卷积神经网络-门控循环单元神经网络)的基坑监测数据补全和变形预测方法,并以南京市某地铁基坑工程为例,验证该模型的数据修复效果和预测精度。

## 1 基坑变形预测方法基本原理

### 1.1 基于 CNN 的数据修复补全

利用神经网络可以将缺失数据修复问题转换为回归问题进行处理<sup>[10]</sup>。

在利用 CNN 模型进行数据修复时,需要构建数据样本集,包括完整数据样本集和缺失数据样本集。完整数据样本集为不完备变形数据中未缺失部分和对应日期的其他监测点数据,缺失数据样本集则为不完备变形数据中缺失部分对应日期的其他监测点数据。数据集构建完成后,利用完整数据样本集训练 CNN 模型,之后将缺失数据样本集输入训练好的模型中,输出缺失数据,并将其填充至不完备变形数据中以完成缺失数据的修复。

### 1.2 基于 GRU 神经网络的基坑变形预测方法

GRU 神经网络是 RNN(循环神经网络)的变体,对长期依赖关系具有较强学习能力,因此在时序数据预测方面具有显著优势<sup>[11]</sup>。基坑变形监测数据正是一种典型的时序数据。

考虑到基坑变形监测数据中含有大量噪声数据,若直接将其输入 GRU 神经网络中预测会极大降低预测精度,故应对数据进行预处理。小波分析是一种常用的传统数据处理方法,在时频数据处理方面具有独特优势,可以通过分离数据中的噪声

值,获得变形数据中的趋势分量和误差分量<sup>[12]</sup>。在以往的变形预测中,对噪声值(误差分量)的处理方法是直接删除,只利用趋势分量进行预测,但该方法可能会造成数据特征丢失,造成预测精度下降。因此,本文考虑利用 GRU 神经网络和 ARMA(自回归滑动平均)模型分别对低频趋势分量和噪声分量进行预测,再将预测结果合并得到最终变形预测结果。

### 1.3 基于 CNN-GRU 神经网络的基坑变形预测方法

根据上述理论方法和模型,提出一种数据不完备下基于 CNN-GRU 神经网络的基坑变形预测方法。该方法主要流程如下:①构建数据样本集,包括完整数据样本集和缺失数据样本集;②数据补全修复,利用 CNN 回归对缺失值进行补全修复,以得到完整连续的基坑变形监测数据;③数据分解,利用小波分解提取变形监测数据中低频趋势分量和高频误差分量;④趋势分量预测,使用 GRU 神经网络模型,获得低频趋势分量预测结果和预测残差,然后将预测残差和误差分量结合形成重构误差分量;⑤误差分量预测,利用 ARMA 模型对重构误差分量进行预测,输出误差分量预测结果;⑥重构最终预测结果,将误差预测结果和趋势预测结果重构得到最终预测结果。

## 2 实例验证

### 2.1 工程概况

南京某地铁车站基坑全长 232.2 m,标准段基坑宽度为 23.1 m,深度为 16.86 m。基坑安全等级为一级,采用钻孔灌注桩排桩+内支撑的支护形式。基坑监测内容主要为位移监测、支撑轴力监测及变形监测等,其中针对桩顶位移的监测点共有 24 个。

### 2.2 缺失数据修复补全

#### 2.2.1 构建数据样本集

选取桩顶位移监测点 ZQS9 和 ZQS10 自 2021 年 3 月 25 日至 12 月 24 日共 275 d 的监测数据作为原始数据。两个监测点分别缺失第 51 天和第 28 天的监测数据,缺失率分别为 18.5% 和 10.1%。

为填补缺失位移数据以供下一步预测,将桩顶位移监测数据作为模型因变量样本,将附近 3 道横支撑内力、地下水水位监测数据作为模型的自变量样本构建缺失数据集。缺失数据集包括缺失数据

样本集和完整数据样本集两部分。

### 2.2.2 数据补全

利用完整数据样本集训练 CNN 模型<sup>[13-14]</sup>,将缺失数据集样本输入其中,输出缺失数据的估计值,再将估计值填补至初始不完备数据中,即完成缺失数据的修复。补全后的基坑桩顶位移时程曲线见图 1。




图 1 补全后的基坑桩顶位移时程曲线

Fig. 1 Foundation pit pile top displacement time-history curve after data completion


## 2.3 基坑变形预测

### 2.3.1 小波分解


本文选取 Sym8 小波基函数将补全后的数据分解为低频趋势分量和高频误差分量<sup>[15-16]</sup>,见图 2。小波分解后的低频趋势分量波动幅度较小,能够较好地反映基坑桩顶位移的趋势;高频误差分量则表现出无规律的波动性<sup>[17]</sup>。

### 2.3.2 低频趋势分量预测

利用 GRU 神经网络对低频趋势分量进行预测,时间步长为 8 d,即以 9 d 的数据作为 1 组样本(前 8 d 数据作为网络输入,第 9 天数据为网络输出)构建数据样本集,如表 1 所示。数据集重构后



a) ZQS9



b) ZQS10

图 2 小波分解后的基坑桩顶位移时程曲线

Fig. 2 Foundation pit top displacement time-history curve after wavelet decomposition

表 1 构建的数据样本集

Tab.1 Constructed data sample set

样本序号	输入数据	输出数据
1	$x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8$	$x_9$
2	$x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9$	$x_{10}$
$\vdots$	$\vdots$	$\vdots$
267	$x_{267}, x_{268}, x_{269}, x_{270}, x_{271}, x_{272}, x_{273}, x_{274}$	$x_{275}$

注: $x$ 为数据。

共 267 组样本,将前 90% 的数据作为训练集,后 10% 数据作为测试集。

为提高 GRU 神经网络模型预测的准确性和预测效率,利用 PSO(粒子群算法)对 GRU 神经网络模型的学习率、隐藏节点个数和正则化参数进行优化<sup>[18]</sup>。将低频趋势分量重构并输入经 PSO 优化的 GRU 神经网络模型中,输出低频趋势分量预测结果和预测残差。

### 2.3.3 重构误差分量预测

将低频趋势分量预测结果的预测残差与小波分解得到的高频误差分量结合形成重构误差分量,利用 ARMA 对重构误差分量进行预测<sup>[19]</sup>,并将输出的预测结果和低频趋势分量预测结果合并为最终的预测结果。

## 2.4 预测结果分析

为客观评价预测效果,选取平均绝对误差  $E_{MA}$ 、均方误差  $E_{MS}$ 、均方根误差  $E_{RMS}$ 、平均绝对百分比误差  $E_{MAP}$ 、拟合优度  $R^2$  对模型的预测效果进行评价和对比<sup>[20]</sup>。

本文选取 GA-BP(遗传算法-反向传播)神经网络预测方法、LSTM(长短期记忆网络)预测方法对

补全后的数据进行预测。同时对未补全的原始数据进行预测,并将其预测结果与本文预测结果相对

比。不同方法下桩顶水平位移预测结果对比见图3。不同方法下桩顶水平位移预测精度对比见表2。

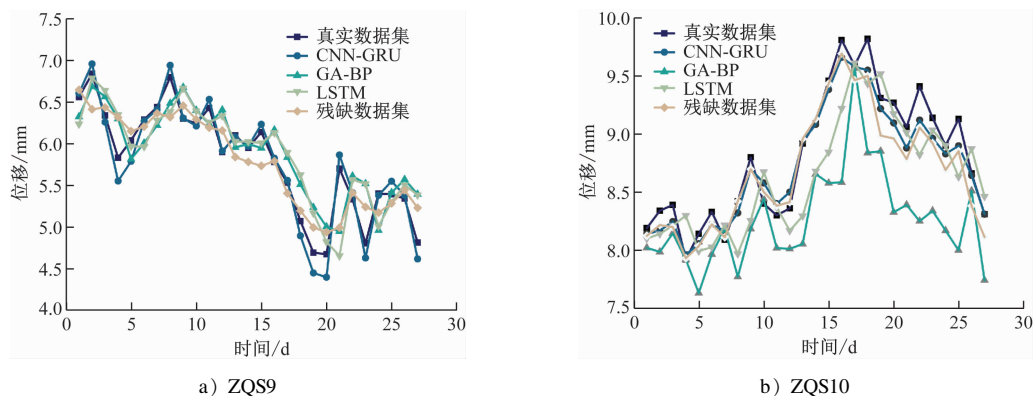


图3 不同方法下桩顶水平位移预测结果对比

Fig.3 Comparison of pile top horizontal displacement prediction results by different methods

表2 不同方法下桩顶水平位移预测精度对比

Tab.2 Comparison of pile top horizontal displacement prediction accuracy by different methods

方法	监测点	$E_{MA}/\text{mm}$	$E_{MS}/\text{mm}$	$E_{RMS}/\text{mm}$	$E_{MAP}/\%$	$R^2$
CNN-GRU	ZQS9	0.198 0	0.018 7	0.136 7	1.926 6	0.962 6
	ZQS10	0.113 4	0.018 7	0.136 8	1.274 6	0.937 3
GA-BP	ZQS9	0.319 9	0.175 2	0.418 6	5.502 1	0.586 1
	ZQS10	0.658 2	0.658 2	0.811 3	7.733 0	0.573 2
LSTM	ZQS9	0.334 5	0.162 3	0.402 8	6.050 4	0.529 9
	ZQS10	0.281 2	0.119 5	0.345 7	3.156 6	0.609 2
残缺数据集	ZQS9	0.233 2	0.083 3	0.288 6	4.105 1	0.710 7
	ZQS10	0.150 7	0.034 4	0.185 6	1.680 2	0.884 8

不难看出,相较于 GA-BP 神经网络预测方法和 LSTM 预测方法,本文采用的 CNN-GRU 神经网络预测方法在基坑变形预测方面表现更好。该模型对监测点 ZQS9 和 ZQS10 的变形预测  $E_{MA}$  分别为 0.198 0 和 0.113 4,拟合优度  $R^2$  分别为 0.962 6 和 0.937 3,预测精度较其他两种方法提升了 1 倍以上。GA-BP 神经网络预测方法和 LSTM 预测方法都出现了不同程度的预测滞后问题,而本方法的预测结果呈现出的变形趋势和拐点与真实数据表现一致。另外,与基于直接删除缺失数据的残缺数据集预测结果相比,本方法对于数据缺失率为 18.5% 和 10.1% 的 ZQS9 和 ZQS10 的变形预测精度分别提高了 35% 和 6%,说明本方法的数据修复能力表现良好,能够满足实际使用需求。

### 3 结论

1) 本文提出的基于 CNN-GRU 神经网络的地

铁基坑变形预测方法能够有效修复基坑变形缺失数据,并且基于修复后数据的预测精度较高,预测误差小于 2%,预测拟合优度能够达到 0.93 以上。

2) 与常用的 GA-BP 神经网络预测方法和 LSTM 预测方法相比,本方法的预测精度更高,且能解决时序数据预测时常见的预测滞后问题,预测结果能够满足实际工程需求。

### 参考文献

- [1] 郭健,陈健,胡杨. 基于小波智能模型的地铁车站基坑变形时序预测分析[J]. 岩土力学, 2020, 41(增刊1): 299.  
GUO Jian, CHEN Jian, HU Yang. Time series prediction for deformation of the metro foundation pit based on wavelet intelligence model[J]. Rock and Soil Mechanics, 2020, 41(S1): 299.
- [2] 赵华菁,张名扬,刘维,等. 基于神经网络算法的深基坑地连墙变形动态预测[J]. 地下空间与工程学报, 2021, 17(增刊1): 321.  
ZHAO Huajing, ZHANG Mingyang, LIU Wei, et al. Dynamic prediction of diaphragm wall deflection caused by deep excavation



- using neural network algorithm[J]. Chinese Journal of Underground Space and Engineering, 2021, 17(S1): 321.
- [3] 洪宇超, 钱建固, 叶源新, 等. 基于时空关联特征的 CNN-LSTM 模型在基坑工程变形预测中的应用[J]. 岩土工程学报, 2021, 43(增刊2): 108.
- HONG Yuchao, QIAN Jiangu, YE Yuanxin, et al. Application of CNN-LSTM model based on spatiotemporal correlation characteristics in deformation prediction of excavation engineering[J]. Chinese Journal of Geotechnical Engineering, 2021, 43(S2): 108.
- [4] 刘锦, 李峰辉, 刘秀秀. 优化 GA-BP 神经网络模型及基坑变形预测[J]. 隧道建设(中英文), 2021, 41(10): 1733.
- LIU Jin, LI Fenghui, LIU Xiuxiu. Optimized genetic algorithm-back propagation neural network model and its application in foundation pit deformation prediction[J]. Tunnel Construction, 2021, 41(10): 1733.
- [5] 周清, 王奉伟. 变形监测缺失数据序列灰色建模方法探讨[J]. 测绘工程, 2016, 25(12): 70.
- ZHOU Qing, WANG Fengwei. The gray modeling method in missing data sequence of deformation monitoring[J]. Engineering of Surveying and Mapping, 2016, 25(12): 70.
- [6] AYENSA-JIMÉNEZ J, DOWEIDAR M H, SANZ-HERRERA J A, et al. An unsupervised data completion method for physically-based data-driven models[J]. Computer Methods in Applied Mechanics and Engineering, 2019, 344: 120.
- [7] SILEI M, BELLAVIA S, SUPERCHI F, et al. Recovering corrupted data in wind farm measurements: a matrix completion approach[J]. Energies, 2023, 16(4): 1674.
- [8] 刘季富. 富水砂卵石地层大型地铁站基坑变形与支护结构受力分析[J]. 城市轨道交通研究, 2022, 25(6): 43.
- LIU Jifu. Foundation pit deformation and supporting structure stress analysis of large metro station in water-rich sandy cobble stratum[J]. Urban Mass Transit, 2022, 25(6): 43.
- [9] 张正智, 周赛, 王占伟, 等. 面向缺失数据基于 SVR-SVDD 的冷水机组故障检测方法[J]. 建筑科学, 2023, 39(2): 193.
- ZHANG Zhengzhi, ZHOU Sai, WANG Zhanwei, et al. Fault detection based on SVR-SVDD for chiller from the perspective of missing data imputation[J]. Building Science, 2023, 39(2): 193.
- [10] 张友, 李聪波, 林利红, 等. 数据不完备下基于 Informer 的离心鼓风机故障趋势预测方法[J]. 计算机集成制造系统, 2023, 29(1): 133.
- ZHANG You, LI Congbo, LIN Lihong, et al. Centrifugal blower fault trend prediction method based on Informer with incomplete data[J]. Computer Integrated Manufacturing Systems, 2023, 29(1): 133.
- [11] 赵志宏, 李晴, 李春秀. 基于卷积 GRU 注意力的设备剩余寿命预测[J]. 振动·测试与诊断, 2022, 42(3): 572.
- ZHAO Zhihong, LI Qing, LI Chunxiu. Remaining useful life prediction based on ConvGRU-Attention method[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(3): 572.
- [12] 周兰庭, 柳志坤, 徐长华. 基于 WA-LSTM-ARIMA 的混凝土坝变形组合预测模型[J]. 人民黄河, 2022, 44(1): 124.
- ZHOU Lanting, LIU Zhikun, XU Changhua. Concrete dam deformation combination prediction based on WA-LSTM-ARIMA[J]. Yellow River, 2022, 44(1): 124.
- [13] 吉兴全, 曾若梅, 张玉敏, 等. 基于注意力机制的 CNN-LSTM 短期电价预测[J]. 电力系统保护与控制, 2022, 50(17): 125.
- JI Xingquan, ZENG Ruomei, ZHANG Yumin, et al. CNN-LSTM short-term electricity price prediction based on an attention mechanism[J]. Power System Protection and Control, 2022, 50(17): 125.
- [14] 吴莹莹, 赵雨宁, 袁志鑫, 等. 基于注意力机制的 CNN-GRU 船舶交通流预测模型[J]. 大连海事大学学报, 2023, 49(1): 75.
- WU Yingying, ZHAO Lining, YUAN Zhixin, et al. CNN-GRU ship traffic flow prediction model based on attention mechanism[J]. Journal of Dalian Maritime University, 2023, 49(1): 75.
- [15] 曾囡韵, 肖先勇, 徐方维, 等. 基于 CNN-BiGRU-NN 模型的短期负荷预测方法[J]. 中国电力, 2021, 54(9): 17.
- ZENG Youjun, XIAO Xianyong, XU Fangwei, et al. A short-term load forecasting method based on CNN-BiGRU-NN model[J]. Electric Power, 2021, 54(9): 17.
- [16] 李东升, 马金锋, 饶凯锋, 等. 基于小波变换的降雨时间序列去噪方法研究[J]. 人民长江, 2023, 54(5): 127.
- LI Dongsheng, MA Jinfeng, RAO Kaifeng, et al. Research on denoising method of precipitation time-series based on wavelet transform[J]. Yangtze River, 2023, 54(5): 127.
- [17] 林涛, 赵伊, 冯嘉冀. 基于特征分解的短期电负荷组合预测模型研究[J]. 计算机仿真, 2022, 39(9): 91.
- LIN Tao, ZHAO Yi, FENG Jiaji. Research on short-term electric load combination prediction model based on feature decomposition[J]. Computer Simulation, 2022, 39(9): 91.
- [18] 马杰, 刘晓青, 黄永涛. 基于 PCA-PSO-GRU 模型的重力拱坝诱导缝开合度预测[J]. 水电能源科学, 2023, 41(2): 95.
- MA Jie, LIU Xiaoqing, HUANG Yongtao. Prediction of inducing joint opening and closing degree of gravity arch dam based on PCA-PSO-GRU model[J]. Water Resources and Power, 2023, 41(2): 95.
- [19] 鲍燕妮, 沈丹祎, 石振明, 等. ARMA 模型在锚碇基坑变形预测中的应用[J]. 工程地质学报, 2021, 29(5): 1621.
- BAO Yanni, SHEN Danyi, SHI Zhenming, et al. Application of ARMA model in deformation monitoring and forecasting of anchorage foundation pit[J]. Journal of Engineering Geology, 2021, 29(5): 1621.
- [20] 海文龙, 王亚慧, 王怀秀. 基于 IPSO 算法优化 GRU 神经网络的燃气负荷预测[J]. 传感器与微系统, 2023, 42(2): 126.

(下转第 53 页)

下水渗流场变化规律的影响[J]. 城市轨道交通研究, 2024, 27(8): 217.

ZHANG Xuhai. Seepage point impact in urban rail transit station foundation pit enclosure structure on the variation law of surrounding groundwater seepage field[J]. Urban Mass Transit, 2024, 27(8): 217.

· 收稿日期:2025-02-26 修回日期:2025-03-20 出版日期:2025-06-10

Received:2025-02-26 Revised:2025-03-20 Published:2025-06-10

· 第一作者:陈伟,工程师,819634337@qq.com

通信作者:曹占林,博士研究生,2210741@tongji.edu.cn

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议

© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

#### (上接第 31 页)

LIU Xian, ZHANG Chenguang, ZHANG Yan, et al. Experimental study on the longitudinal joint of shield tunnels reinforced with composite cavity[J]. Journal of Railway Science and Engineering, 2015, 12(2): 376.

[20] 柳献, 张乐乐, 李刚, 等. 复合腔体加固盾构隧道衬砌力学行为的宏观分析模型[J]. 现代隧道技术, 2014, 51(5): 78.

LIU Xian, ZHANG Lele, LI Gang, et al. A macroscopic analysis model for the mechanical behaviors of a shield tunnel segment lining reinforced with a composite cavity[J]. Modern Tunnelling

Technology, 2014, 51(5): 78.

· 收稿日期:2023-04-28 修回日期:2023-06-15 出版日期:2025-06-10

Received:2023-04-28 Revised:2023-06-15 Published:2025-06-10

· 第一作者:孙雪兵,正高级工程师,103982434@qq.com

通信作者:柳献,教授,xian.liu@tongji.edu.cn

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议

© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

#### (上接第 36 页)

HAI Wenlong, WANG Yahui, WANG Huaixiu. Gas load forecasting based on optimization of GRU neural network using IPSO algorithm[J]. Transducer and Microsystem Technologies, 2023, 42(2): 126.

· 收稿日期:2023-06-02 修回日期:2023-07-06 出版日期:2025-06-10

Received:2023-06-02 Revised:2023-07-06 Published:2025-06-10

· 第一作者:周意,硕士研究生,hbhg\_zy@163.com

通信作者:王章琼,副教授,wzqcug@163.com

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议

© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

#### (上接第 42 页)

[19] 张文彤. SPSS 统计分析基础教程[M]. 3 版. 北京:高等教育出版社, 2017.

ZHANG Wentong. Basic course of SPSS statistical analysis[M]. 3rd ed. Beijing: Higher Education Press, 2017.

[20] 段志强, 王力, 李立功, 等. 单盾盾隧道掘进机在砂岩、砂质泥岩地层中的掘进参数关系研究[J]. 城市轨道交通研究, 2019, 22(7): 120.

DUAN Zhiqiang, WANG Li, LI Ligong, et al. Relation of tunneling parameters of single shield TBM in sandstone and sandy mud-

stone stratum[J]. Urban Mass Transit, 2019, 22(7): 120.

· 收稿日期:2023-05-28 修回日期:2023-10-11 出版日期:2025-06-10

Received:2023-05-28 Revised:2023-10-11 Published:2025-06-10

· 第一作者:时健,博士研究生,924532404@qq.com

通信作者:张仕林,博士研究生,高级工程师,zhangshilin.2005@163.com

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议

© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

#### (上接第 47 页)

ZHANG Yingxin, WANG Zhansheng, TAO Yufan, et al. Thrust prediction during diagonal cutting of concrete diaphragm wall for TBM based on machine learning[J]. Henan Science, 2024, 42(12): 1792.

[10] 邱广宇, 房欣悦, 张旺. 基于机器学习的高速列车车头型多目标优化设计[J]. 大连交通大学学报, 2024, 45(4): 41.

QIU Guangyu, FANG Xinyue, ZHANG Wang. Multi-objective optimization design of high-speed train head shape based on machine learning[J]. Journal of Dalian Jiaotong University, 2024, 45(4): 41.

[11] 史刚. 基于机器学习的装载机铲装作业性能预测与优化研究[D]. 柳州:广西科技大学, 2024.

SHI Gang. Research on prediction and optimization of loader shoveling performance based on machine learning[D]. Liuzhou: Guangxi University of Science and Technology, 2024.

[12] YAO J, EDSON C P, YU S, et al. Bucket loading trajectory optimization for the automated wheel loader[J]. IEEE transactions on vehicular technology, 2023, 72(6): 6948.

[13] 陆怀民, 张云廉, 刘晋浩. 土壤切削弹粘塑性有限元分析[J]. 岩土工程学报, 1995, 17(2): 100.

LU Huaimin, ZHANG Yunlian, LIU Jinhao. Elastoviscoplastic finite element analysis of soil cutting[J]. Chinese Journal of Geotechnical Engineering, 1995, 17(2): 100.

· 收稿日期:2025-02-13 修回日期:2025-04-20 出版日期:2025-06-10

Received:2025-02-13 Revised:2025-04-20 Published:2025-06-10

· 通信作者:曹昱,工程师,515141032@qq.com

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议

© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license