

使用 CNN (卷积神经网络)-LSTM(长短期记忆) 联合神经网络预测盾构隧道施工引起的地面沉降

黄茂庭 徐金明

(上海大学土木工程系, 200444, 上海)

摘要 [目的] 地铁盾构隧道施工会引起周围地面沉降, 影响周围环境。传统地面沉降预测方法难以综合考虑沉降影响因素, 对此, 为提高地面沉降的预测精度, 使用 CNN(卷积神经网络)-LSTM(长短期记忆)联合神经网络, 对盾构隧道施工引起的地面沉降进行预测。[方法] 以某地铁施工区间地面沉降监测数据为研究对象, 使用 CNN 对影响参数(压缩模量、黏聚力、内摩擦角、泊松比、土层厚度、隧道埋深和施工参数)与地面沉降监测值进行连接, 使用 LSTM 神经网络对地面沉降进行分析, 建立了基于 CNN-LSTM 联合神经网络的地面沉降预测模型, 探讨了同时考虑多个因素对地面沉降预测值的影响。[结果及结论] 使用 CNN 对地面沉降相关的影响参数特征提取效果较好; 所建 CNN-LSTM 模型的准确率比单独使用 LSTM 模型的准确率提高了 3%、比传统 BP(反向传播)神经网络模型准确率提高了 9%; 所建 CNN-LSTM 模型, 对单测点短时间地面沉降预测准确率达到 93%, 预测值与监测值吻合较好。

关键词 盾构隧道施工; 地面沉降; 预测; 卷积神经网络; 长短期记忆神经网络

中图分类号 TU433; TP391.7

DOI:10.16037/j.1007-869x.2024.06.031

used to connect the influencing parameters (including compressive modulus, cohesion, internal friction angle, Poisson's ratio, soil thickness, tunnel buried depth, and construction parameters) and monitored land subsidence data. The LSTM neural network is used to analyze the land subsidence, and a land subsidence prediction model based on the CNN-LSTM joint neural network is established. Simultaneous consideration of the multiple factor influence on land subsidence prediction is explored. [Result & Conclusion] Using CNN has a good effect on extracting the parameter features related to land subsidence. The prediction accuracy of the established CNN-LSTM model is 3% higher than that of the LSTM model alone, and 9% higher than that of the traditional BP (back propagation) neural network model. The prediction accuracy of the established CNN-LSTM model reaches 93% when predicting the short time land subsidence in single measuring point, and the predicted value is in good agreement with the monitored value.

Key words shield tunnel construction; land subsidence; prediction; convolutional neural network; long-short-term memory neural network

Prediction of Land Subsidence Caused by Shield Tunnel Construction with Joint CNN- LSTM Neural Network

HUANG Maoting, XU Jinming

(Department of Civil Engineering, Shanghai University, 200444, Shanghai, China)

Abstract [Objective] Metro shield tunnel construction may cause surrounding land subsidence, affecting the surrounding environment. Traditional land subsidence prediction models are difficult to comprehensively consider the influencing factors of land subsidence. Therefore, in order to improve the prediction accuracy of land subsidence, the CNN (convolutional neural network)-LSTM (long-short-term memory) joint neural network is used to predict the land subsidence caused by shield tunnel construction. [Method] With the monitored land subsidence data of a metro section as the research object, CNN is

地铁隧道施工过程中不可避免地会对邻近土体产生附加沉降。这一沉降超过一定数值, 会对地下管线、附近建筑物等造成损害, 甚至引发安全事故。因此, 有必要研究地铁隧道施工过程引起周围地面沉降的预测问题。

地面沉降的传统预测方法有经验公式法、数值模拟法、理论解析法等, 但传统预测方法存在参数难以确定、模型比较复杂、非线性不强等问题, 需要新的方法来提高地面沉降的预测精度。近年来, 很多学者将机器学习方法用于地面沉降的预测。文献[1]使用平滑相关向量机预测了隧道掘进过程中地面沉降; 文献[2]基于退火算法, 对软土地区盾构隧道长期沉降进行了预测; 文献[3]使用 BP(反向传播)神经网络预测了地面沉降, 并与最小二乘法拟合值、实测值进行了对比。但是, 传统机器学习

方法存在容易陷入局部极小值、对缺失值较敏感等问题。

地面沉降监测数据属于时间序列数据,基于RNN(循环神经网络)及其相应的LSTM(长短期记忆)神经网络对等时序数据有较好的预测效果、已被许多学者用于地面沉降分析。文献[4]通过聚类分析多个地面测点的关联性,使用RNN构建沉降预测模型;文献[5]基于RNN模型,将地质、几何及盾构机参数作为输入,预测了隧道施工引起的地面最大沉降;但RNN对长期的时间序列数据特征学习能力不足。

LSTM神经网络能较好地处理具有长期依赖特性的序列数据。文献[6]使用RF(随机森林)算法以最优特征作为输入,结合LSTM神经网络进行地面沉降预测;文献[7]将盾构机掘进参数作为输入,使用LSTM神经网络对地面沉降进行预测;文献[8]基于沉降数据的小波分解,使用LSTM神经网络预测地面沉降;文献[9]基于多主影像相干目标小基线干涉技术反演出大区域的沉降时序数据,使用LSTM神经网络进行地面沉降预测。但测点的沉降数据不仅与时间维度有关,还与空间维度有关,而LSTM难以学习到不同数据之间的空间特征。

CNN(卷积神经网络)有较好空间特征提取能力,一些学者将其与LSTM进行组合、并用于沉降预测;文献[10]基于大数据和CNN-LSTM模型,将气象数据、地质数据和测点监测数据作为输入,预测了高速地铁运营期间地面产生的沉降;文献[11]考虑多个测点之间的相互影响,将多个测点的监测数据作为输入,使用CNN-LSTM模型预测了基坑开挖过程中引起的地面沉降;但是,这类组合模型需要重视动态施工过程及土层性质。

针对上述不足,本文以某地铁盾构隧道区间(以下称为“区间A”)施工引起的地面沉降数据为研究对象,将盾构机掘进过程中反映施工动态过程的量化参数(盾构机埋深、盾构机推进速度、盾构机推力、同步注浆量)、反映局部土层特性的量化参数(压缩模量、黏聚力、内摩擦角、泊松比、土层厚度)与测点沉降监测值作为原始数据输入,提出基于CNN-LSTM联合神经网络构建沉降预测模型(以下简称“CNN-LSTM模型”)来预测盾构隧道施工引起地面沉降的方法,即使用CNN对这些参数进行连接,并使用基于LSTM的神经网络进行训练,以

期给隧道工程的安全施工和正常运营提供参考。

1 工程概况及测点布置

区间A中新建隧道5号线上穿既有隧道2号线,5号线为双线隧道,其中上行线单圆隧道长1184.09 m,下行线单圆隧道长1195.88 m。本文选择典型监测断面SD970中测点SD970-5的监测数据。该测点为5号线下行线与2号线下行线交汇处,具有典型性。地面沉降监测时间为2020年9月21日至2020年12月31日(共102 d),为5号线上行线和下行线开挖时间范围。区间A的测点SD970-5位置如图1所示。

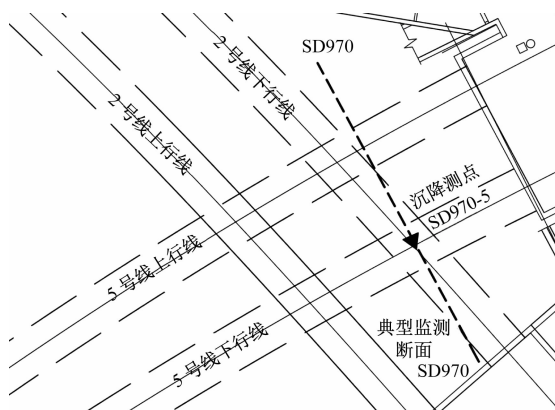


图1 区间A的地面沉降测点SD970-5位置

Fig. 1 Location of land subsidence measuring point SD970-5 in Section A

2 CNN-LSTM模型的建立

2.1 CNN-LSTM模型的结构

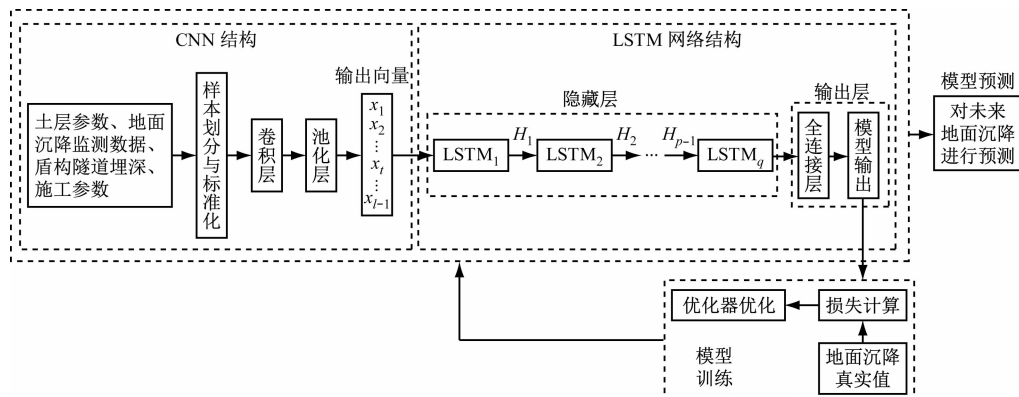
CNN的卷积运算擅长处理及提取序列数据中的空间信息,能较好地学习数据集中的空间特征。由于地面沉降同土层物理性质、土层厚度、动态施工过程等密切相关,所以,本文首先使用CNN将影响地面沉降的所有特征相连接,并作为模型输入数据来学习数据集的空间特征。LSTM神经网络是RNN中的一种特殊结构:一方面,通过增加遗忘门、输入门和输出门来判断数据是否符合网络输入要求,以实现数据的保留和舍弃;另一方面,通过将过去、现在和未来的信息有效关联,以有效学习序列数据中时间维度的特征。

CNN能将土层物理性质参数、土层厚度、施工参数、地面沉降监测数据等特征很好连接起来并提取不同参数的空间特征,而LSTM神经网络可以通

过数据特征来预测地面沉降。因此,可以将这两个网络结合起来,建立用于地面沉降预测的 CNN-LSTM 模型。

本文所建的 CNN-LSTM 模型框架如图 2 所示。图 2 展示了模型的主要结构(包括 CNN 的输入层、卷积层、池化层, LSTM 神经网络的隐藏层、输出层),以及模型训练和模型预测等。CNN 负责接收

输入特征、学习特征空间表示,并转换成一维特征序列。在 LSTM 神经网络中,隐藏层采用 LSTM 结构,对输入的一维特征序列学习数据集时间维度特征,输出层负责输出地面沉降的预测值。地面沉降预测值与真实值进行损失计算,并优化 CNN-LSTM 模型,随后对未来地面沉降进行预测。



注: H_1 、 H_2 等为 LSTM 单元在不同时间步的输出; $LSTM_1$ 、 $LSTM_2$ 等为 LSTM 隐藏层中不同的层单元; $[x_1 \ x_2 \ \cdots \ x_i \ \cdots \ x_{i-1}]$ 为由输入特征经 CNN 卷积层和池化层后形成的一维序列(向量),其中 x_i 表示某一特征在时间 t 内监测值经 CNN 后输出结果。

图 2 CNN-LSTM 模型框架

Fig. 2 CNN-LSTM model framework

2.2 模型输入

模型输入包含土层参数、地面沉降监测数据、盾构隧道埋深及施工参数。

1) 土层参数:土层参数包括隧道顶端和底端土层的压缩模量 E_s 、黏聚力 c 、内摩擦角 φ 、泊松比 ν 、土层厚度 H 。拟建场地地层主要为黏性土、淤泥质土、粉性土、砂土和基岩,隧道穿越的土层主要包括 ②_{2b} 淤泥质土、⑤_{1a} 黏土、⑤_{1t} 砂质粉土。各地层的土层主要参数如表 1 所示。

2) 地面沉降监测数据:仅取典型测点 SD970-5 在 102 d 施工期内的地面沉降监测数据。

3) 盾构隧道埋深:根据工程监测资料,盾构隧道埋深为 8.44 ~ 17.86 m。为计算方便,本研究的盾构隧道埋深统一取为 10.60 m。

表 1 盾构隧道穿越土层的主要参数

Tab.1 Main parameters of the shield tunnel crossing soil layers

土层名称	E_s/MPa	c/kPa	$\varphi/(\circ)$	ν	H/m
② _{2b} 淤泥质土	2.2	7.9	4.7	0.383	2.8
⑤ _{1a} 黏土	6.2	40.3	9.5	0.254	8.8
⑤ _{1t} 砂质粉土	10.0	7.0	28.3	0.275	7.0

4) 施工参数:本文选择盾构机开挖过程中的盾构机推进速度、盾构机顶推力、同步注浆量 3 项参数作为施工参数,并按监测值取值。

2.3 数据标准化

为了减少量纲对地面沉降预测结果的影响、提高模型的泛化能力,本文采用均值标准化,将与地面沉降相关的输入参数和沉降监测数据进行标准化处理:

$$y_i = (x_i - \bar{x})/s \quad (1)$$

式中:

y_i ——经过标准化后的第 i 个输入数据;

x_i ——第 i 个原始输入数据;

\bar{x} ——原始输入数据的均值;

s ——原始输入数据的标准差。

2.4 CNN-LSTM 模型的评价指标

为了评价所建地面沉降预测模型的性能,本文使用均方根误差 R_{RMSE} 来进行模型评价,计算公式为:

$$R_{\text{RMSE}} = \sqrt{\sum_{j=1}^n (\hat{Y}_j - Y_j)^2 / n} \quad (2)$$

式中:

\hat{Y}_j ——地面沉降第 j 个预测值;

Y_j ——地面沉降第 j 个真实值;

n ——迭代次数。

3 地面沉降的预测结果

本文建立的地面沉降 CNN-LSTM 模型共有 6 个超参数,分别为 CNN 卷积层数、卷积核大小、LSTM 隐藏层层数、最小迭代批次、最大迭代周期、初始学习率。其中,CNN 卷积层数为 3,卷积核大小为 3×3 ;LSTM 隐藏层层数为 2;最小迭代批次为 32;最大迭代周期为 200;初始学习率取为 0.01,采用“7+1”的训练模式、即使用前 7 d 监测数据进行训练并预测第 8 天的沉降值。

3.1 测点沉降的预测

为了验证本文所建 CNN-LSTM 模型对单个测点沉降的预测效果,选择测点 SD970-5 的地面沉降监测数据进行分析。测点 SD970-5 的地面沉降监测值如图 3 所示。




图3 测点 SD970-5 的地面沉降监测值

Fig. 3 Measured land subsidence values at measuring point SD970-5

地面沉降的一般预测流程为:首先,将影响地面沉降的主要参数(土层参数、盾构隧道埋深、施工参数)与地面沉降监测数据组成原始输入数据集,并将数据集的数据标准化;然后,将标准化数据输入到 CNN 中,CNN 通过卷积层和池化层提取关键特征,输出由多个特征组成的一维序列,并输入到 LSTM 神经网络中进行训练,进而对单测点地面沉降进行预测。

从图 3 可知,测点 SD970-5 处的地面沉降在监测期间出现了回弹。这是因为盾构掘进时对盾构隧道周围土体进行了注浆加固,属于工况改变的情况。对于工况改变,可以调整输入数据集,从而体

现动态施工过程对测点地面沉降的影响。

在地面沉降一般预测流程的基础上,本研究根据测点 SD970-5 具体数据对预测流程进行调整:首先,将测点 SD970-5 处地面沉降主要影响参数及地面沉降第 1 天至第 82 天的监测值作为输入,对 CNN-LSTM 模型进行训练;然后,对第 83 天至第 102 天的地面沉降进行预测。为了验证本文所建模型的预测性能,将所用数据集作为输入数据集,输入到 LSTM 模型及 BP 神经网络模型中,对地面沉降进行预测。

测点 SD970-5 处不同方法得到的地面沉降预测值与监测值如图 4 所示。




图4 测点 SD970-5 处的地面沉降预测值与监测值

Fig. 4 Predicted and monitored land subsidence values at measuring point SD970-5

从图 4 可以看出:与 LSTM 模型和 BP 神经网络模型相比,使用影响地面沉降的主要参数和地面沉降监测值组成多输入变量后,CNN-LSTM 模型的预测值与监测值吻合性较好,预测结果更佳。在使用 CNN-LSTM 模型预测时,沉降预测值与监测值最大误差出现在第 100 天(监测值为 21.60 mm,预测值为 24.41 mm,预测误差为 13.01%),预测准确率达到 86.99%。单独使用 LSTM 模型时,沉降预测值与监测值相差最大同样出现在第 100 天(监测值为 21.60 mm,预测值为 25.56 mm,预测误差为 18.33%),模型预测准确率只有 81.67% 左右。与单独使用 LSTM 模型相比,使用 CNN-LSTM 模型预测地面沉降的准确率提高了 3%,说明在 LSTM 神经网络前叠加卷积层能更好地对原始输入数据的时空特征进行连接与特征提取,从而能更好地进行地面沉降预测。在 BP 神经网络模型中,沉降预测值与监测值相差最大出现在第 99 天(监测值为 21.87 mm,预测值为 26.61 mm,预测误差为

21.67%),网络预测准确率只有78.33%左右,说明传统BP神经网络模型对序列数据的时空维度特征处理效果不足,无法较好学习到序列数据前后特征的关联性,对时序数据的预测效果不如CNN-LSTM模型。

3.2 不同预测时间的预测准确性

本文所用地面沉降监测原始数据集数量较少;但如果预测时间过长,会造成预测准确率下降、预测效果不佳。对此,分析不同预测时间范围对地面沉降预测准确率的影响。对于测点SD970-5,将长时间预测改为短时间预测,将测点处影响地面沉降的主要参数与前95 d的地面沉降监测值作为模型输入,分别对第96天(预测时间为1 d)、第98天(预测时间为3 d)及第100天(预测时间为5 d)的地面沉降值进行预测,并将预测值与监测值进行比较,结果如图5所示。




图5 测点SD970-5处地面沉降预测值与监测值的比较

Fig. 5 Comparison of monitored and predicted land subsidence values at point SD970-5

从图5可以看出,预测时间越短,地面沉降的预测准确率就越高:预测第96天的地面沉降时,预测值为25.64 mm,监测值为24.11 mm,预测误差为6.35%,预测准确率达到93.65%,预测值与监测值吻合较好;预测第98天的地面沉降时,预测值为25.74 mm,监测值为23.30 mm,预测误差为10.47%,预测准确率为89.53%;预测第100天的地面沉降时,预测值为24.52 mm,监测值为21.60 mm,预测误差为13.52%,预测准确率为86.48%。

经分析,地面沉降的短时间预测准确率高于长时间预测准确率,这与原始沉降数据集的数量大小及地面沉降监测数据变化趋势有关。

4 结论

1) 通过卷积神经网络(CNN)对土层参数、地

面沉降历史监测值、盾构隧道埋深和施工参数等关键特征的空间信息进行提取,能够有效提高单测点地面沉降预测的准确性。

2) 同单独使用LSTM模型及传统BP神经网络模型相比,采用CNN-LSTM模型对单测点地面沉降的预测准确率最高。

3) 采用CNN-LSTM模型对单测点地面沉降进行预测,预测时间为1 d时的预测准确率达到93%,预测时间为5 d时的预测准确率为87%。说明CNN-LSTM模型可用于隧道开挖过程的单测点地面沉降预测。

参考文献

- [1] WANG F, GOU B, QIN Y. Modeling tunneling-induced ground surface settlement development using a wavelet smooth relevance vector machine [J]. Computers and Geotechnics, 2013, 54: 125.
- [2] 朱春雷. 基于模拟退火算法的地铁盾构隧道长期沉降预测[J]. 城市轨道交通研究, 2015, 18(12): 36.
ZHU Chunlei. Long-term settlement prediction of subway shield tunnel based on simulated annealing algorithm[J]. Urban Mass Transit, 2015, 18(12): 36.
- [3] 夏志强, 周传波, 平雯, 等. 地铁隧道盾构法施工地表沉降特征及预测研究[J]. 城市轨道交通研究, 2014, 17(10): 98.
XIA Zhiqiang, ZHOU Chuanbo, PING Wen, et al. Study on the characteristics and prediction of ground subsidence in subway tunnel shield construction[J]. Urban Mass Transit, 2014, 17(10): 98.
- [4] 岳振华, 沈涛, 毛曦, 等. 循环神经网络的地面沉降预测方法[J]. 测绘科学, 2020, 45(12): 145.
YUE Zhenhua, SHEN Tao, MAO Xi, et al. Prediction method of land subsidence based on recurrent neural network[J]. Science of Surveying and Mapping, 2020, 45(12): 145.
- [5] 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.
LI Luobin, GONG Xiaonan, GAN Xiaolu, et al. Prediction of maximum ground settlement caused by shield tunnel based on recurrent neural network [J]. China Civil Engineering Journal, 2020, 53(S1): 13.
- [6] LEE H K, SONG M K, LEE S S. Prediction of subsidence during TBM operation in mixed-face ground conditions from realtime monitoring data[J]. Applied Sciences, 2021, 11(24): 12130.
- [7] RASHID K M, LOUIS J. Times-series data augmentation and deep learning for construction equipment activity recognition[J]. Advanced Engineering Informatics, 2019, 42: 100944.
- [8] 钱建固, 吴安海, 季军, 等. 基于小波优化LSTM-ARMA模

- 型的岩土工程非线性时间序列预测[J]. 同济大学学报(自然科学版), 2021, 49(8): 1107.
- QIAN Jiangu, WU Anhai, JI Jun, et al. Nonlinear time series prediction of geotechnical engineering based on LSTM-ARMA model optimized by wavelet[J]. Journal of Tongji University (Natural Science), 2021, 49(8): 1107.
- [9] 刘青豪, 张永红, 邓敏, 等. 大范围地表沉降时序深度学习预测法[J]. 测绘学报, 2021, 50(3): 396.
- LIU Qinghao, ZHANG Yonghong, DENG Min, et al. Time series deep learning prediction method for large-scale surface subsidence[J]. Acta Geodaetica et Cartographica Sinica, 2021, 50(3): 396.
- [10] 杨俊超. 基于大数据分析 with 挖掘的铁路沉降灾害预警模型研究[D]. 成都: 电子科技大学, 2021.
- YANG Junchao. Research on early warning model of railway subsidence disaster based on big data analysis and mining[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [11] 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 spatio-temporal correlation characteristics in deformation prediction of foundation pit engineering[J]. Chinese Journal of Geotechnical Engineering, 2021, 43(S2): 108.
- 收稿日期:2022-01-21 修回日期:2022-02-24 出版日期:2024-06-10
Received:2022-01-21 Revised:2022-02-24 Published:2024-06-10
• 第一作者:黄茂庭, 硕士研究生, Huangmaoting916@163.com
通信作者:徐金明, 教授, xjming@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 165 页)

参考文献

- [1] 黄宏伟. 隧道及地下工程建设中的风险管理研究进展[J]. 地下空间与工程学报, 2006, 2(1): 13.
- HUANG Hongwei. State-of-the-art of the research on risk management in construction of tunnel and underground works[J]. Chinese Journal of Underground Space and Engineering, 2006, 2(1): 13.
- [2] LI B, WANG Z Z. Numerical study on the response of ground movements to construction activities of a metro station using the pile-beam-arch method[J]. Tunnelling and Underground Space Technology Incorporating Trenchless Technology Research, 2019, 88: 209.
- [3] 张成平, 张顶立, 吴介普, 等. 暗挖地铁车站下穿既有地铁隧道施工控制[J]. 中国铁道科学, 2009, 30(1): 69.
- ZHANG Chengping, ZHANG Dingli, WU Jiepu, et al. Construction control of a newly-built subway station undercrossing the existing subway tunnel[J]. China Railway Science, 2009, 30(1): 69.
- [4] 白明洲, 许兆义, 时静, 等. 复杂地质条件下浅埋暗挖地铁车站施工期地面沉降量 FLAC^{3D} 分析[J]. 岩石力学与工程学报, 2006, 25(增刊2): 4254.
- BAI Mingzhou, XU Zhaoyi, SHI Jing, et al. Analysis of ground settlement of a subway station undercut with shallow overburden during construction with FLAC^{3D} under complex geological conditions[J]. Chinese Journal of Rock Mechanics and Engineering, 2006, 25(S2): 4254.
- [5] LIU J, WANG F, HE S, et al. Enlarging a large-diameter shield tunnel using the Pile-Beam-Arch method to create a metro station[J]. Tunnelling and Underground Space Technology, 2015, 49: 130.
- 收稿日期:2022-06-14 修回日期:2022-08-14 出版日期:2024-06-10
Received:2022-06-14 Revised:2022-08-14 Published:2024-06-10
• 作者:胡赛鸿, 高级工程师, 2483877200@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

《城市轨道交通研究》被 Research4Life-HINARI 数据库收录

2024 年 4 月 20 日,《城市轨道交通研究》被国际知名数据库 Research4Life-HINARI 数据库正式收录。Research4Life 是世界卫生组织、粮农组织、联合国环境规划署、知识产权组织、国际劳工组织、康奈尔大学和耶鲁大学与多达 155 家科学出版社之间合作伙伴关系的总称,其宗旨是促进发展中国家科学研究的发展。

Research4Life 包括健康研究(HINARI)、农业研究(AGORA)、环境研究(OARE)、发展与创新研究(ARDI)和全球正义研究(GOALI)五个项目计划。自 2002 年以来,Research4Life 为超过 125 个中低收入国家的 11 500 多家机构的研究人员,免费或低成本提供了 203 000 多种领先期刊和书籍,包括卫生、农业、环境、应用科学和法律信息等领域。

(供稿:《城市轨道交通研究》编辑部)