

文章编号:1673-9469(2024)04-0082-08

DOI:10.3969/j.issn.1673-9469.2024.04.011

基于深度学习的盾构姿态预测及纠偏研究

桂林¹,王飞¹,张雯超²

(1. 苏州市轨道交通集团,江苏 苏州 215000;2. 南通职业大学 建筑工程学院,江苏 南通 226007)

摘要: 以苏州某在建隧道工程为研究背景,基于机器学习技术提出一种盾构姿态预测模型和纠偏方法。首先通过卷积神经网络挖掘盾构姿态数据的空间特征,然后通过双向长短期记忆神经网络挖掘数据的时序特征,紧接着通过注意力机制挖掘重要的时间特征信息。在预测结果的基础上,引入Apriori算法对盾构数据的关联规则提取,并提出盾构姿态纠偏方法。实验结果表明该文提出的盾构姿态预测模型具有较好的泛化能力,且相较于选取的3种基准模型,得到的均方根误差和平均绝对误差值最小,具有更高的预测精度。基于姿态理论控制模型,构建多环姿态控制模型,实现对姿态调整获取参数建议值,为智能化姿态控制提供参考依据。

关键词: 盾构隧道;机器学习;姿态预测;纠偏方法;注意力机制

中图分类号: TU472

文献标识码: A

Study on Shield Attitude Prediction and Deflection Correction Based on Deep Learning

GUI Lin¹, WANG Fei¹, ZHANG Wenchao²

(1. Suzhou Rail Transit Group, Suzhou, Jiangsu 215000, China; 2. School of Architecture and Engineering, Nantong Vocational University, Nantong, Jiangsu 226007, China)

Abstract: Taking a tunnel project under construction in Suzhou as the research background, this paper proposes a shield attitude prediction model and correction method based on the machine learning technology. Firstly, the spatial features of shield posture data were mined through a convolutional neural network. Then, the temporal features of data were mined through a bidirectional long short-term memory neural network. Afterwards, the important temporal feature information was mined through the attention mechanism. On the basis of the prediction results, the Apriori algorithm is introduced to extract the association rules of shield data, and the shield attitude correction method is proposed. Experiments show that the proposed prediction model in this paper has good generalizability. Compared to the three selected baseline models, it achieves the smallest root mean square error and mean absolute error values, indicating higher prediction accuracy. Based on the attitude theory control model, a multi-loop attitude control model is constructed to obtain parameter suggestions for attitude adjustment, which provides a theoretical reference for intelligent attitude control.

Key words: shield tunnelling; machine learning; attitude prediction; correction method; attention mechanism

在盾构掘进过程中的盾构机轴线直接决定了
成环管片的轴线,进而影响着成型的隧道轴
线^[1-2],因此对盾构机姿态的预测可以为后续盾构

机轴线的调整提供参考,有效地提升盾构施工的
工程质量。

目前国内外学者对盾构姿态的预测研究主要

收稿日期:2023-08-20

基金项目:国家自然科学基金资助项目(51978430);中天控股集团技术研发项目(ZTCG-GDJTYJS-JSKF-2021001)

作者简介:桂林(1969-),男,江苏苏州人,博士,高级工程师,研究方向:城市轨道交通,机器学习。

包括理论分析、数值模拟和机器学习。许多学者构建了盾构姿态力学模型,并通过实际工程案例对其进行验证^[3-4]。理论计算实施简便,便于操作,但其很难对盾构姿态进行实时预测。借助于模拟软件的发展,数值模拟因其直观性强、计算效率高优点也被广泛用于盾构姿态预测^[5-6]。数值模拟可以动态性展示盾构姿态的变化过程,但其需要详细的地质参数,这些参数往往较难准确地获取。

机器学习技术是一种新兴的预测手段,其依靠各类模型对数据的挖掘能力实现后续的精准预测。陈昱竹^[7]采用支持向量机来预测盾构姿态偏差引起的轨迹轴线变化。该方法以盾构历史数据为输入参数,挖掘数据之间的内在联系,实现了对盾构姿态的预测。但该方法只是建立起了一种传统上的回归模型,忽略了盾构轴线偏差数据的序列性。因此一些学者开始尝试利用深度学习方法来预测盾构姿态变化。杨宏燕^[8]利用神经网络模型建立盾构姿态预测模型,相比于其他的机器学习模型,神经网络预测模型的输入参数种类更全面,预测的准确率更高。高兵^[9]构建了基于神经网络模型的专家系统,并在工程中得到了成功点的运用。Zhou 等^[10]提出一种新的盾构姿态预测组合模型,融合了小波变换、卷积神经网络和长短时记忆网络的优势,通过监测数据对模型进行验证。

现有的机器学习方法对盾构姿态的预测取得了一定的成果,但其还有一些可以提升的地方:比如现有的机器学习模型主要考虑盾构姿态数据的时序特征,忽略了数据包含的空间特征和短期特征的重要度以及对于后续盾构掘进方案的调整涉及较少。针对以上不足,本文以某实际盾构隧道为研究背景,提出基于注意力机制(Attention)、卷积神经网络(Convolutional Neural Networks, CNN)和双向长短期记忆神经网络(Bi-directional Long Short-Term Memory, BiLSTM)的预测模型和基于Apriori算法的盾构姿态纠偏方法。该预测模型可以充分挖掘盾构姿态数据的时空特征和重要时序特征的影响,提升预测精度。同时基于Apriori算法提出盾构轴线纠偏方法,可以推荐合理的盾构纠偏参数,为施工人员提供决策支撑。

1 工程概况

1.1 下穿区间工程概况

苏州市轨道交通8号线时代广场站—右岸街

站区间线路从时代广场站出发后,主要沿华池街向南前进,需下穿1号线时代广场站。区间隧道采用盾构法施工,其中左线和右线长度分别为471.319 m和474.205 m。施工过程中需要破除的障碍物为既有时代广场车站的地下连续墙结构,厚度为0.6 m。图1展示了盾构下穿1号线时代广场站的工程剖面图。该区间施工环境复杂,盾构姿态控制严格。由于存在多种既有结构,盾构姿态的偏差不仅会影响新建隧道的建设质量,还会对既有结构的运行造成严重的影响。因此本文以盾构下穿既有1号线车站结构为研究对象,提出盾构姿态预测模型和纠偏方法,为施工提供有效的指导。




图1 工程剖面图

Fig. 1 Project profile

1.2 端头加固设计方案

端头加固体采用 $\Phi 850@600$ 三轴搅拌桩,土体加固区长度共12 m,加固区宽度为盾构隧道二衬结构外包边缘每侧水平外伸3 m,竖向加固区范围为盾构隧道二衬结构外包边缘竖向外伸上下各3 m。图2为工程加固平面图。加固处理过的土体应具有均质性、自立性好的特点,其中加固区A区28 d无侧限抗压强度应大于等于1.0 MPa,加固体渗透系数应不超过 1.0×10^{-7} cm/s, B区28 d无侧限抗压强度应不小于0.5 MPa,加固体渗透系数不超过 1.0×10^{-6} cm/s。

1.3 地质概况及盾构机配置

区间内盾构主要穿越②₄砂质粉土、③₅粉砂

分别通过输入门、遗忘门和输出门。更新内部单元的存储状态,通过三个门的运算可以得到下一时刻的输入,如此反复迭代,以姿态的时序性为计算顺序,得到最后的预测结果。

注意力机制通过对事物的不同部分赋予不同的权重,从而降低其无关部分的作用^[14]。在盾构姿态预测输入样本中不同历史时刻数据对当前姿态的影响并不一致,LSTM 依然会对其同等看待,这个问题限制了窗口化数据作为模型输入的优势。因此,在预测模型中融合注意力机制,使预测模型优先关注到对当前盾构姿态影响较大的时刻参数,并进一步提升模型预测的准确性。假设 LSTM 的输出隐藏状态为 $Y = [Y_1, Y_2, \dots, Y_p]$ 。注意力得分可表示为

$$u_j = \tanh(W_i Y_j + b_i) \quad (1)$$

$$\alpha_j = \text{softmax}(\alpha_j) = \frac{\exp(u_j^T)}{\sum_{j=1}^p \exp(u_j^T)} \quad (2)$$

$$S = \sum_{j=1}^p \alpha_j Y_j \quad (3)$$

其中 W_i 是权重; b_i 是偏置向量; α_j 的概率是注意力机制。

根据盾构姿态的数据时空特征和各神经网络的优点,本文将多种神经网络组合成为新的深度学习算法,提出基于注意力机制的 CNN 和 BiLSTM (CNN-BiLSTM) 的复合网络结构。具体算法流程如图 3 所示。




图3 模型结构图

Fig. 3 Model structural diagram

2.2 参数的选取及预处理

在盾构掘进过程中,影响盾构姿态的参数众

多,在本工程背景中主要可分为四类:盾构机操作参数、地质参数、隧道参数和障碍物参数。各参数里面又包含多种子参数。本文在已有研究^[15-16]和专家讨论论证的基础上,选取盾构推力、扭矩、注浆量、土仓压力、贯入度、钢筋强度、桩径、土体黏聚力和内摩擦角,共计 9 种参数作为模型输入参数。盾构姿态作为模型输出参数。数据主要来自于监测系统,数据量为 4 856 组。原始的数据集中各参数具有不同的量纲,在模型运算过程中不同的量纲会降低模型的运行效率,不利于模型的收敛。因此本文采用了 Min-Max 标准化,该方法是对原始数据进行线性变换,使数据映射到固定的区间 $[0, 1]$, 同时还能较好地保持原有数据结构。其数学表达式如式(4)所示

$$X' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

式中: x 表示数据的实际值, $x_{\min}$ 表示数据的最小值, $x_{\max}$ 表示数据的最大值。

2.3 评价指标

对于任意一组训练样本,输出的预测值 r_i 与真实值 p_i 之间都存在一定的误差。通常采用均方根误差 (Root Mean Square Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 两个指标对模型进行评估,其中 RMSE、MAE 越小,说明模型拥有更好的预测精度。RMSE、MAE 的计算公式如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |r_i - p_i| \quad (5)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (r_i - p_i)^2} \quad (6)$$

式中: n 是样本总数, r_i 是预测姿态值, p_i 是实测姿态值。

2.4 模型预测

模型搭建于 CPU 为 i7-6700HQ, GPU 为 960 的计算机平台,按照设计好的模型实施,建立由全连接输入层,卷积层,池化层, BiLSTM 层,注意力机制层构成的隐藏层,一个输出层构成的深度神经网络,网络涉及超参数。超参数设置情况如表 2 所示。

2.4.1 损失值

图 4 展示了模型在测试集和训练集上的损失值变化曲线。由图 4 可见,随着模型迭代次数的增加,训练集和测试集上的损失值快速下降,在迭代

次数达到 20 次之后,训练过程和测试过程的损失值下降幅度开始逐渐减缓,到 80 次之后可见曲线波动较小,表明模型已经收敛,其损失值也较低,表明模型具有较高的预测精度。对比测试集和训练集的损失值可以发现,最终两者的差值较小,表明模型在训练集和测试集上都取得了较好的效果,可以避免过拟合问题,具有较好的泛化能力。

表 2 模型超参数设置情况

Tab. 2 Hyperparameter settings of model

参数类型	激活函数	超参数	丢失率	优化器
输入层	relu	—	—	—
卷积层	sigmoid	filters = 128 kernel_size = 1	—	—
双向 LSTM 层	tanh	window = 4 lstm_units = 256 epoch = 100	0.01	nadam
注意力机制层	sigmoid	—	—	—
输出层	tanh	—	—	—




图 4 模型训练损失曲线图

Fig. 4 Model training loss curve

2.4.2 模型对比

本文选取现有的普通的循环神经网络 (Recurrent Neural Network, RNN)、LSTM 和 CNN 模型作为对比模型,各模型的计算结果如表 3 所示。从表 3 中可以看出相比其他模型,本文所提出的模型在 RMSE 和 MAE 上的值均为最小值,因此本文提出的模型的预测效果最优。这主要归因于本文提出的模型融合了 CNN 和 LSTM 模型的优势,既可以挖掘盾构姿态数据的时间和空间特征,还通过融合的注意力机制突出重要时刻对盾构姿态的影响,使得本文的模型具有更高的预测准确率。图 5 展示了预测数据和原数据在 653 环到 706 环的对比曲线。通过曲线图可以更直

观地看出本文模型预测的盾构姿态和实际盾构姿态曲线拟合得很好,进一步佐证了本文模型可以有效地预测盾构姿态的变化,为隧道施工提供参考。

表 3 评价指标对比

Tab. 3 Comparison of evaluation indicators

预测目标	评价指标	均方根误差	平均绝对误差
切口水 平偏差	本文模型	2.36	1.89
	RNN	9.57	8.94
	LSTM	7.05	5.32
切口垂 直偏差	CNN	13.32	11.43
	本文模型	2.39	1.62
	RNN	10.63	9.15
盾尾水 平偏差	LSTM	7.97	6.51
	CNN	15.07	13.75
	本文模型	3.36	3.10
盾尾垂 直偏差	RNN	10.53	8.21
	LSTM	6.87	4.87
	CNN	14.45	12.79
盾尾垂 直偏差	本文模型	4.12	2.95
	RNN	11.05	9.78
	LSTM	7.74	5.96
盾尾垂 直偏差	CNN	14.83	12.69

3 基于 Apriori 的姿态纠偏处理

在第三节的预测结果基础上,本节引入 Apriori 算法提出盾构后续姿态纠偏的实施方案。

3.1 数据离散化

Apriori 是一种常用的数据关联规则挖掘方法之一,其可以找出数据集中出现频率较高的数据集。Apriori 算法主要针对于分段型的数据,本文隧道盾构掘进数据主要是连续形点的数据,且盾构在掘进的过程中并不是所有的参数变化都会引起盾构姿态的变化,一定程度的推力,扭矩或其他参数变化在一定时间内并不会引起盾构姿态的明显变化。因此,我们需要将连续的数据进行离散化,将其转化为分段数据,这样才能作为 Apriori 算法的输入。有效的离散化不仅能提高算法计算效率,还能降低极端值和异常值对计算结果的影响,增强模型的健壮性。本文采用等宽法作为数据分段处理方法,即把属性值按照相同宽度的区间进行划分,将取值范围均匀地划分为 n 等份,每个属性值对应属于它的那个区间,如表 4 所示。




图5 盾构姿态预测结果

Fig. 5 Prediction results of shield attitude

表4 实验参数表

Tab. 4 Parameters of experients

总推进力/T	推进速度 /(mm · min ⁻¹)	刀盘转速 /(r · min ⁻¹)	上部土仓 压力/MPa	...	盾尾姿态水平 前/mm	盾尾姿态水平 中/mm
[700,750]	[30,38]	[1.1,1.3]	[1.8,2.0]	...	[1,21]	[-12,8]
[750,800]	[10,14]	[80,85]	[160,180]	...	[1,21]	[-12,8]
[800,850]	[14,20]	[75,80]	[160,180]	...	[1,21]	[-12,8]
⋮	⋮	⋮	⋮	⋮	⋮	⋮
[1 300,1 350]	[30,35]	[50,60]	[1.1,1.3]	...	[-32,-12]	[-27,-7]
[1 350,1 400]	[25,30]	[40,50]	[1.3,1.5]	...	[-32,-12]	[-27,-7]

标来筛选频繁项集,其数学表达式见式(7)(8)(9)。

3.2 Apriori 关联分析

3.2.1 算法介绍

Apriori 算法主要是进行数据集的关联分析,是数据挖掘领域重要的技术之一。计算步骤可以分为两步:(1)筛选频繁项集;(2)产生关联规则。假定 X 和 Y 是两类没有交集的数据集,在关联规则中的表现形式为 XY 。通常会采用支持度(Support)、置信度(Confidence)以及提升度(Lift)三个指

$$\text{Support}(X \rightarrow Y) = \frac{P(X \rightarrow Y)}{P(\text{All})} = \frac{\sigma(X \cup Y)}{N} \quad (7)$$

$$\text{Confidence}(X \rightarrow Y) = \frac{P(X, Y)}{P(X)} = \frac{\sigma(X \cup Y)}{\sigma(X)} \quad (8)$$

$$\text{Lift}(X \rightarrow Y) = \frac{P(X, Y)}{P(X)P(Y)} \quad (9)$$

表 5 实验结果

Tab. 5 Experimental results

规则	先导项	后继项	支持度	置信度
规则 1	{ '盾构姿态垂直中=[-5,15]' }	{ '盾构姿态垂直前=[8,28]' }	0.209 091	0.741 935
规则 2	{ '盾构姿态水平中=[-32,-12]' }	{ '盾构姿态垂直后=[-86,-66]' }	0.209 091	0.741 935
规则 3	{ '同步注浆压力左上=[2.1,2.7]' }	{ '盾构姿态垂直中=[-45,-25]' }	0.201 244	0.709 677
⋮	⋮	⋮	⋮	⋮
规则 155	{ '同步注浆压力左上=[2.6,3.1]', '同步注浆压力右上=[2.0,2.5]' }	{ '总推进力=[1 100,1 300]', '盾构姿态垂直中=[-45,-25]', '刀盘转速=[1.1,1.3]', '推进速度=[10,40]' }	0.200 644	0.758 621
规则 156	{ '同步注浆压力左上=[2.2,3.1]', '同步注浆压力右上=[2.0,2.6]', '推进速度=[10,40]' }	{ '总推进力=[800,100]', '盾构姿态垂直中=[-45,-25]', '刀盘转速=[1.1,1.3]' }	0.200 587	0.814 815
规则 157	{ '同步注浆压力左上=[2.6,3.0]', '推进速度=[10,30]' }	{ '总推进力=[900,950]', '同步注浆压力右上=[2.0,2.5]', '盾构姿态垂直中=[-45,-25]', '刀盘转速=[1.1,1.3]' }	0.200 245	0.758 621

表 6 实验参数表

Tab. 6 Parameters of experiments

纠偏环数	纠偏量/mm	偏差变化量(后继项)	掘进参数(先导项)
639	7.29	[5,10]	{ '总推进力=[1 000, 1 200]', '同步注浆压力左上=[2.1, 2.8]' }
640	5.33	[5,10]	{ '总推进力=[900,1 050]', '同步注浆压力左上=[2.0,3.1]', '同步注浆压力右上=[2.4,2.8]' }
641	5.25	[5,10]	{ '总推进力=[1 000,1 340]', '同步注浆压力左上=[2.6,3.0]', '同步注浆压力右上=[2.0,2.5]', '推进速度=[20,30]' }
642	5.78	[5,10]	{ '总推进力=[800,1 000]', '同步注浆压力左上=[2.3,2.9]', '推进速度=[30,37]' }
643	12.25	[10,15]	{ '总推进力=[800,1 000]', '同步注浆压力右上=[2.0,2.5]' }
644	9.35	[5,10]	{ '总推进力=[980,1 040]', '同步注浆压力右上=[2.1,2.9]', '推进速度=[20,36]', '刀盘转速=[1.1,1.3]' }
645	11.28	[10,15]	{ '总推进力=[760,890]', '同步注浆压力左上=[2.1,2.8]' }
646	4.35	[0,5]	{ '总推进力=[1 000,1 080]', '同步注浆压力左上=[2.6,3.1]', '同步注浆压力右上=[2.2,2.7]', '推进速度=[20,35]' }

3.2.2 关联规则挖掘

取 $\min\text{Support} = 0.2$, $\min\text{Conf} = 0.5$, 对盾构历史纠偏区间数据进行关联分析并导出关联规则, 总共导出 157 组关联规则, 关联规则整理如表 5 所示。对纠偏量以及掘进参数进行分开整理, 如表 6 所示。

3.3 迭代计算获取参数建议值

针对 8 环中每一环掘进参数区间, 将区间进行 10 等分划分, 进而每一环得到 10 组掘进数据, 通过第三小节的模型进行迭代计算, 获得 10 个预测偏差变化量, 将该 10 个偏差变化量与盾构轴线反向圆几何计算方法所计算的纠偏量计算绝对误

差, 取绝对误差最小的一组掘进数据作为该环掘进参数建议值。以 639 环为例, 实验结果如表 7 所示, 当推力为 1 040 T 时, 注浆压力为 2.45 MPa 时, 此时这两个参数对第 639 环的姿态调整作用最大, 可以作为姿态调整时的建议参数。

以此类推, 我们可以得出 639 环到 646 环的所有姿态调整建议参数, 其结果如表 8 所示。

4 结论

1) 本文以盾构姿态预测和轴线纠偏为研究对象, 基于机器学习方法构建了新的盾构姿态预测模型和轴线纠偏方法。

表 7 实验结果

Tab. 7 Experimental results

序号	推力 /T	注浆压力 /MPa	预测值 /mm	纠偏量 /mm
1	900	2.1	2.63	3.29
2	920	2.15	2.95	3.29
3	940	2.2	3.02	3.29
4	960	2.25	3.96	3.29
5	980	2.3	3.69	3.29
6	1 000	2.35	2.26	3.29
7	1 020	2.4	4.58	3.29
8	1 040	2.45	3.15	3.29
9	1 060	2.6	3.96	3.29
10	1 080	2.65	4.63	3.29

表 8 参数调整方案

Tab. 8 Parameter adjustment program

环号	推力 /T	刀盘扭矩 /(kN·m)	注浆压 力/MPa	螺旋机扭矩 /(kN·m)	刀盘转速/ (r·min ⁻¹)
639	1 040	—	2.45	—	—
640	1 140	—	2.65	—	1.12
641	1 180	1 300	—	45	—
642	1 220	—	2.45	—	—
643	1 320	1 350	—	41	1.32
644	1 140	—	—	—	—
645	1 200	—	2.55	44	1.38
646	1 100	1 150	—	—	—

2)以实际工程的数据库作为数据集,对本文提出的预测模型进行实验发现:本文提出的模型既可以挖掘盾构姿态数据的时间和空间特征,还通过融合的注意力机制突出重要时刻对盾构姿态的影响,相比于现有 3 种基准模型,本文的模型具有更高的预测准确率。

3)基于姿态理论控制模型,构建多环姿态控制模型,实现对姿态调整获取参数建议值,使智能化姿态控制有了理论参考依据。本文所述方法实现了对盾构施工的姿态偏差进行提前预测,在姿态超出预警时,及时提示施工人员进行纠偏,并且有效提高了姿态控制的准确度及控制效率,弥补了传统姿态控制方法的不足,对确保所建造隧道质量、工程工期以及施工人员及设备安全具有极其重要的意义。

参考文献:

[1] WANG P, KONG X, GUO Z, et al. Prediction of axis attitude deviation and deviation correction method based on data driven during shield tunneling[J]. IEEE Access, 2019, 99: 163487-163501.

[2] TANG L, KONG X X, LINGX Z, et al. Deviation correction strategy for the earth pressure balance shield based on shield-soil interactions[J]. Frontiers of Mechanical Engineering, 2022, 17(2): 1-15.

[3] 刘成,管会生,谢友慧,等. 盾构掘进姿态和纠偏曲线研究[J]. 现代隧道技术, 2019, 56(4): 105-112,126.

[4] 沈翔,袁大军. 盾构俯仰角变化对盾构-土相互作用影响研究[J]. 岩土力学, 2020, 41(4): 1366-1376.

[5] 钟小春,易斌斌,竺维彬,等. 粉细砂地层盾构机姿态数值模拟及姿态突变判断方法[J]. 华中科技大学学报(自然科学版), 2023, 8(14): 1-8.

[6] SUN W, YUE M, WEI J. Relationship between rectification moment and angle of shield based on numerical simulation[J]. Journal of Central South University, 2012, 19(2): 517-521.

[7] 陈昱竹. 盾构施工数据分析与可视化技术研究与实现[D]. 西安:西安电子科技大学, 2018.

[8] 杨宏燕. 盾构掘进方向计算机辅助控制技术研究[C]//中国设备管理协会,中国设备管理协会视讯信息技术中心. 中国设备工程专家代表会议论文集. 上海隧道工程股份有限公司, 2007: 130-133.

[9] 高兵. 土压平衡盾构机姿态与轨迹自动控制系统研究[D]. 沈阳:东北大学, 2011.

[10] ZHOU C, XU H C, DING L Y, et al. Dynamic prediction for attitude and position in shield tunneling: a deep learning method[J]. Automation in Construction, 2019, 105: 102840.

[11] YU G M, LEI J, ZHANG P H, et al. Exploration and prospect of “five-dimensional” space effect of ground surface settlement caused by shield tunnel construction[J]. Journal of Qingdao University of Technology, 2022, 43(02): 1-10.

[12] ZHOU C, XU H, DING L, et al. Dynamic prediction for attitude and position in shield tunneling: A deep learning method[J]. Automation in construction, 2019, 105: 102840.

[13] HOCHREITER S, SCHMIDHUBER. J. Long short? term memory[J]. Neural Computer, 1997, 9: 1735-1780.

[14] 刘映晶,卢敬科,陈城,等. 基于 CGA 模型的盾构扭矩预测研究[J]. 河北工程大学学报(自然科学版), 2024, 41(02): 51-58.

[15] LIU B, LI L, FANG X L, 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.

[16] ZHANG D M, ZHANG J Z, HUANG H W, et al. Machine learning-based prediction of soil compression modulus with application of 1D settlement[J]. Journal of Zhejiang University-SCIENCE A, 2020, 21(6): 430-444.

(责任编辑 周雪梅)