#### DOI: 10.11779/CJGE2024S20014

# 基于深度学习的基坑开挖引起地表位移时序预测

唐浩然<sup>1,2</sup>, 胡 垚\*1,<sup>2</sup>, 雷华阳<sup>3</sup>, 路军富<sup>1,2</sup>, 刘 婷<sup>4</sup>, 王 凯<sup>5</sup>

(1. 地质灾害防治与地质环境保护国家重点实验室(成都理工大学),四川 成都 610059; 2. 成都理工大学环境与土木工程学院,四川 成都 610059; 3. 天津大学建筑工程学院,天津 300350; 4. 中国电建集团西北勘测设计研究院有限公司,陕西 西安 710065;
 5. 中铁建设集团有限公司华东分公司,江苏 昆山 215300)

摘 要:为更精准预测基坑工程中数据的时间特性,结合卷积神经网络 CNN 模型与两种单一时间序列神经网络模型长 短期记忆网络 LSTM 模型、门控循环单元 GRU 模型,建立混合时间序列神经网络 CNN-LSTM 模型、CNN-GRU 模型。 基于杭州某邻近既有车站基坑开挖工程,采用滚动预测方法建立基坑开挖引起邻近地铁车站地表沉降数据集。通过平 均绝对误差 MAE、平均相对误差 MAPE 和均方根误差 RMSE3 种评价指标对预测结果进行评价。结果表明: CNN-GRU 模型预测效果最优,CNN-LSTM 模型次之,其次是 GRU 模型,最后是 LSTM 模型。CNN-LSTM 混合网络模型相较于 LSTM 模型对 3 种评价指标分别降低了 24.4%,53.8%,4.1%,CNN-GRU 混合网络模型相较于 GRU 模型分别降低了 13.9%,49.1%,1%。

关键词:基坑开挖;深度学习;卷积神经网络;长短期记忆网络;门控循环单元
 中图分类号:TU43
 文献标识码:A
 文章编号:1000-4548(2024)S2-0236-06
 作者简介:唐浩然(1999—),男,硕士研究生,主要从事岩土与地下工程方面的研究。E-mail:tanghaoran@stu.cdut.edu.cn。

# Time series prediction of surface displacement induced by excavation of foundation pits based on deep learning

TANG Haoran<sup>1, 2</sup>, HU Yao<sup>1, 2</sup>, LEI Huayang<sup>3</sup>, LU Junfu<sup>1, 2</sup>, LIU Ting<sup>4</sup>, WANG Kai<sup>5</sup>

(1. State Key Laboratory of Geological Disaster Prevention and Geological Environment Protection, Chengdu University of Technology, Chengdu 610059, China; 2. College of Environment and Civil Engineering, Chengdu University of Technology, Chengdu 610059, China;

3. School of Civil Engineering, Tianjin University, Tianjin 300350, China; 4. PowerChina Northwest Engineering Corporation Limited,

Xi'an 710065, China; 5. East China Branch of China Railway Construction Group Co, Ltd., Kunshan 215300, China)

**Abstract**: To predict the time characteristics of data more accurately in foundation pit engineering, two single time series neural network models are combined, the convolutional neural network (CNN) and long short-term memory network (LSTM), as well as the gated recurrent unit (GRU), to establish a hybrid time series neural network model CNN-LSTM and CNN-GRU. An excavation project of a foundation pit adjacent to an existing station in Hangzhou is selected, and a rolling prediction method is used to create a dataset of surface settlement caused by excavation of the foundation pit in the adjacent subway stations. The predicted results are evaluated by three evaluation indexes: mean absolute error (MAE), mean relative error (MAPE) and root mean square error (RMSE). The results demonstrate that the CNN-GRU has the best prediction effects, followed by the CNN-LSTM, GRU and LSTM. Compared with the LSTM model, the CNN-LSTM hybrid network model reduces the three evaluation indexes by 24.4%, 53.8% and 4.1%, respectively, and the CNN-GRU hybrid network model decreases by 13.9%, 49.1% and 1%, respectively, compared with the GRU model.

Key words: excavation of foundation pit; deep learning; convolutional neural network; long short-term memory network; gated recurrent unit

# 0 引 言

随着中国软土地区城市地下空间工程的大规模建 设,基坑工程朝着更大、更深、更复杂的趋势发展。 基坑开挖卸荷作用会打破土体原有平衡状态,引起基 坑周边土体应力重分布,进而导致地层产生位移和变 形,最终对邻近既有建筑产生不利影响[1-2]。而软土由

基金项目:国家自然科学基金项目(42307260);四川省自然科学基金项目(2023NSFSC0882);地质灾害防治与地质环境保护国家重点实验 室开发基金(SKLGP2023K024) 收稿日期: 2024-06-22 \*通信作者(E-mail: hyjiaoliu@163.com)

于物理力学特性差和结构性强等特点,受扰动后极易 发生性能劣化,产生较大应力变化和变形<sup>[3]</sup>。因此, 预测基坑开挖引起地表位移对确保既有建筑物的风险 预警具有重要意义。

学者们对基坑开挖引起地表位移预测开展了深入 研究,研究方法主要包括数值模拟[4]、解析解法<sup>[5]</sup>等。 这些方法在一定程度上反映了土体本构关系和基坑开 挖与土体之间的力学响应,但存在本构关系确定困难、 计算成本高、推导过程复杂和效率较低等缺点。机器 学习作为一种高效的代理模型,成为基坑开挖引起地 表位移的一种高效方法[6]。赵华菁等[7]基于实测数据, 对比反向传播算法 BP 和长短期记忆神经网络 LSTM 预测结果,得出 LSTM 模型具有较好的稳定性。张生 杰等<sup>[8]</sup>基于 LSTM 模型对地下连续墙的变形预测,并 与传统神经网络模型相比,证明了该模型的稳定性和 可靠性。徐长节等<sup>[9]</sup>通过支持向量机 SVM、多层感知 器模型 ANN、长短期记忆模型 LSTM 模型及门循环 单元模型 GRU 模型对支护结构最大侧移预测,得出 GRU 模型总体预测效果最好。单一神经网络预测模型 有较好的准确性和可靠性,但受限于数据特征提取能 力,并不能很好的处理非线性和非平稳序列<sup>[10]</sup>。

综上所述,本文结合 CNN 模型和单一时序神经 网络 LSTM 模型、GRU 模型,建立混合神经网络 CNN-LSTM 模型、CNN-GRU 模型。基于基坑开挖引 起邻近地表位移实测数据,对比单一时序神经网络 LSTM 模型、GRU 模型和混合时序神经网络 CNN-LSTM 模型、CNN-GRU模型的预测精度,并将 混合时序神经网络 CNN-LSTM 模型、CNN-GRU 模型 的优化效果进行比较,为基坑开挖引起邻近地表位移 预测提供参考。

# 1 时序预测模型建立

# 1.1 卷积神经网络 CNN 模型

卷积神经网络 CNN 模型具有局部连接和权值共 享特性,可高效实现输入特征的提取。其结构特征可 分为输入层、卷积层、池化层、全连接层和输出层, 如图1所示。其中,卷积层通过卷积运算对数据特征 提取,池化层通过去除数据进行特征降维,最后通过 全连接层特征加权,提高数据特征质量。



图 1 CNN 神经网络 Fig. 1 CNN neural network

#### 1.2 长短期记忆神经网络 LSTM 模型

长短期记忆神经网络LSTM 模型具有长效记忆能 力和在必要时更新信息的特性,实现考虑时序性输入 参数。其结构特征可分为遗忘门、输入门和传输门, 如图 2 所示。其中,输入门通过激活函数,决定输入 信息,遗忘门选择信息保留,输出门控制信息输出, 通过反向传播算法进行训练,以此适应数据特征。 LSTM 模型中参数计算公式为

$$f_{\iota} = \sigma \left( W_{\mathfrak{s}, \mathfrak{X}_{\iota}} + W_{\mathfrak{s}, \mathfrak{Y}_{\iota-1}} + b_{\mathfrak{s}} \right) \quad , \tag{1}$$

$$i_t = \sigma \left( \boldsymbol{W}_{ix} \boldsymbol{x}_t + \boldsymbol{W}_{ih} \boldsymbol{y}_{t-1} + \boldsymbol{b}_i \right) \quad , \tag{2}$$

$$\tilde{S}_t = \tanh\left(\boldsymbol{W}_{cx}\boldsymbol{x}_t + \boldsymbol{W}_{ch}\boldsymbol{y}_{t-1} + \boldsymbol{b}_c\right) \quad , \tag{3}$$

$$S_t = f_t \otimes S_{t-1} + i_i \otimes S_t \quad , \tag{4}$$

$$O_t = \sigma \left( \boldsymbol{W}_{ox} \boldsymbol{x}_t + \boldsymbol{W}_{oh} \boldsymbol{h}_{t-1} + \boldsymbol{b}_o \right) \quad , \tag{5}$$

$$h_t = O_t \otimes \tanh S_t \quad \circ \tag{6}$$

式中:  $x_t$ 为输入特征;  $S_t$ ,  $S_{t-1}$ 为记忆单元中的状态向 量; W为输出门的权重; b为输入门的偏置项;  $\sigma$ 与 tanh 为激活函数;  $\otimes$  为矩阵元素相乘。



Fig. 2 Structure of LSTM cell

# 1.3 门控循环单元 GRU 模型

门控循环单元 GRU 模型是 LSTM 模型的改进模型,实现少于 LSTM 模型输入参数,取得与 LSTM 模型相同效果。其结构特征可分为更新门和重置门,如图 3 所示。其中,更新门控制保留多少前一时刻状态信息到当前状态程度。重置门控制当前状态与先前信息结合程度。GRU 模型中各参数的计算公式为

$$z_t = \sigma \left( \boldsymbol{W}_z \cdot [\boldsymbol{s}_{t-1}, \boldsymbol{x}_t] \right) \quad , \tag{7}$$

$$\mathbf{i} = \sigma \left( \boldsymbol{W}_r \cdot [\boldsymbol{s}_{t-1}, \boldsymbol{x}_t] \right) \quad , \tag{8}$$

$$\tilde{S}_t = \tanh\left(\boldsymbol{W} \cdot [\boldsymbol{s}_{t-1} \cdot \boldsymbol{r}_1, \boldsymbol{x}_t]\right) \quad , \tag{9}$$

$$s_t = (1 - z_t)s_{t-1} + z_t \tilde{s}_t \qquad (10)$$

 1.4 混合时序神经网络 CNN-LSTM 模型和 CNN-GRU 模型

混合时序神经网络CNN-LSTM模型是基于CNN 模型的空间特征提取能力,将数据进行多次重复卷积 和池化后,有效提取强化后的特征信息,通过LSTM 模型中门的控制机制,对CNN模型提取的特征值进行 长短期记忆训练。混合时序神经网络模型CNN-GRU 模型是在CNN模型提取特征信息基础上,引入GRU模 型中重置门和更新门,捕捉数据中的时序关系,实现 对未来数据的预测,其结构特征如图4所示。



图 3 GRU 模型结构

Fig. 3 Structure of GRU model



Fig. 4 Structure of CNN-LSTM and CNN-GRU

# 2 地表位移预测框架搭建

# 2.1 工程概况

本文选取杭州某邻近既有车站基坑开挖工程为依 托。基坑开挖工程平面尺寸约为210m×85m,深度约 为15m。南、北基坑工程的正中间是地铁1号线从打 铁关站至西湖文化站隧道运营段,地铁1号线车站主体 结构紧邻基坑东侧,在车站主体结构中设有多个监测断 面,站台两侧各设置两组监测棱镜,如图5所示。





#### 2.2 数据集建立

通过棱镜采集 DM33 断面中车站主体结构段地表 位移数据,共计 186 组。为提高模型收敛速度,对数 据集进行如下归一化处理:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad . \tag{11}$$

式中:  $x^*$ 为归一化后数据; x为归一化前数据;  $x_{max}$ 为样本最大值;  $x_{min}$ 为样本最小值。

将归一化后的数据集采用滚动预测方法,得到 180 组数据,滚动预测方法具体步骤如下:

(1)设置滚动窗口为7,输入层神经元数量为6, 输出层为神经元数量为1。

(2)进行地表位移滚动预测,将 k<sub>y</sub>-k<sub>y+6</sub> 时刻实 测数据作为 k<sub>y+7</sub> 时刻的数据的输入特征, k<sub>y+7</sub> 时刻数 据为输出层。

(3)重复上述步骤,进行滚动迭代,最终建立所 有时刻的地表位移数据集,如图6所示。



图 6 滚动预测法



# 2.3 预测模型结构设计

将数据集以8:1:1比例分为训练集、验证集和测试集,分别输入到单一时序神经网络预测模型 LSTM模型、GRU模型和混合时序神经网络预测模型 CNN-GRU模型、CNN-LSTM模型中进行预测。

单一神经网络主要取决于神经元数目与层数对预 测模型结果的影响。GRU 模型网络模块:初始参数设 置为 1 层 GRU,神经元数目为 32,随机失活系数为 0.01。LSTM 网络模块:设置为 1 层 LSTM,神经元 数目为 32,随机失活系数为 0.01。

混合神经网络中主要设置 CNN 模型卷积层数和 时序预测中神经元目数对预测模型结果的影响<sup>[11]</sup>。混 合时序神经网络预测模块初始设置如下: CNN 模型特 征提取模块为一层 Conv1 D 层,卷积核数为 16,大小 为 2; LSTM 模型模块:神经元目数为 32,随机失活 系数为 0.01。GRU 模型模块,神经元数目为 32,随 机失活系数为 0.01。

# 2.4 模型预测精度

为检验模型预测精度,通过平均绝对误差 MAE、 平均相对误差 MAPE 和均方根误差 RMSE 对模型预测 结果进行评价,计算公式为

RMSE = 
$$\sqrt{\frac{1}{N} \sum_{i=1}^{N} (\hat{y}_i - y_i)^2}$$
 , (12)

MAPE = 
$$\frac{1}{N} \sum_{i=1}^{N} \left| \frac{\hat{y}_i - y_i}{y_i} \right|$$
, (13)

$$MAE = \frac{1}{N} \sum_{i=1}^{N} |\hat{y}_i - y_i| \quad \circ \tag{14}$$

式中: N 为样本个数;  $\hat{y}_i$  为输出预测值;  $y_i$  为真实值。

# 3 模型预测结果

## 3.1 模型预测结果分析

以 180 组实测地表位移数据为基础,分别通过 LSTM模型、GRU模型、CNN-LSTM模型和CNN-GRU 模型对数据集进行训练预测,4 种模型预测结果如图 7 所示。







由图 7 可知,4 种模型预测结果均能捕捉到地表 位移实测数据的变化趋势。对于单一神经网络模型, LSTM 模型和 GRU 模型均未能预测到地表由沉降到 隆起的变化,且 LSTM 模型整体拟合度较差,这可能 是预测误差随着时间序列长度增加而累积,引起 LSTM 模型预测值明显偏离实测值<sup>[12]</sup>。此外,地表由 沉降到隆起的过程存在复杂的非线性关系,LSTM 模 型和 GRU 模型虽然能够处理非线性问题,但是在小 样本数据情况下仍可能无法准确地捕捉到复杂的非线 性变化,忽略了由沉降变为隆起的相关性特征。对于 混合神经网络模型,CNN-LSTM 模型和 CNN-GRU 模 型预测效果均优于单一神经网络模型,且对于地表由 沉降到隆起的变化也有较好的预测效果。这可能是在 CNN 模型数据空间特征提取作用下,LSTM 模型<sup>[13]</sup> 和 GRU 模型能够更好地捕捉数据中的空间特征和序 列依赖关系。

## 3.2 预测精度及优化效果

图 8 是 4 种模型预测结果的平均绝对误差 MAE、 平均相对误差 MAPE 和均方根误差 RMSE 对比。从图 8 中可以看出,对于平均绝对误差 MAE,4 种模型预 测结果均在 0.1 以下, 即 4 种模型预测偏差较小。对 于均方根误差 RMSE, 4 种模型预测结果均处于 0.1 左右,即4种模型均有较好的拟合能力。对于平均相 对误差 MAPE, CNN-GRU 最小, 其次是 CNN-LSTM 模型, 然后是 GRU 模型, 最后是 LSTM 模型, 即 CNN-GRU 模型具有最优的预测准确性。表 1 是单一 时序神经网络预测模型和混合时序神经网络预测模型 预测精度对比。由表1可知,相较于单一时序神经网 络预测模型 LSTM 模型和 GRU 模型,混合时序神经 网络预测模型 CNN-LSTM 模型和 CNN-GRU 模型具 有较好优化效果。对于平均绝对误差 MAE、平均相对 误差 MAPE 和均方根误差 RMSE, CNN-LSTM 模型 较 LSTM 模型分别降低了 24.4%, 53.8%, 4.1%, CNN-GRU 模型较 GRU 模型分别降低了 13.9%, 49.1%,1%。由此可见,特征提取后的LSTM 模型和 GRU 模型均表现出较好的预测效果。



Fig. 8 Comparison of prediction accuracies of surface displacement

Table 1 Evaluation indexes of prediction models						
评判指标	LSTM	CNN-LSTM	优化效果/%	GRU	CNN-GRU	优化效果/%
MAE	0.1019	0.0819	24.4	0.0902	0.0782	13.9
MAPE	1.2779	0.5909	53.8	1.0970	0.5581	49.1
RMSE	0.1251	0.1199	4.1	0.1185	0.1174	1.0

# 4 结 论

以杭州某邻近既有车站基坑开挖工程为研究对象,分别建立LSTM 模型、GRU 模型、、CNN-LSTM 模型以及 CNN-GRU 模型预测邻近基坑开挖引起地表 位移实测数据,分析模型预测效果和预测精度。得到 2 点结论。

(1)模型预测效果中 CNN-GRU 模型预测效果 最优, CNN-LSTM 模型次之,其次是 GRU 模型,最 后是 LSTM 模型。在 CNN 模型的数据空间特征提取 作用下,LSTM 模型和 GRU 模型能够更好地捕捉数 据中的空间特征和序列依赖关系。

(2) CNN-LSTM 模型和 CNN-GRU 模型相较于 LSTM 模型和 GRU 模型有较好的优化效果,对于平 均绝对误差 MAE、平均相对误差 MAPE 和均方根误 差 RMSE, CNN-LSTM 模型较 LSTM 模型分别降低了 24.4%, 53.8%, 4.1%, CNN-GRU 模型较 GRU 模型 分别降低了 13.9%, 49.1%和 1%。

#### 参考文献:

- LIU Bo, WU Wenwen, LIU Haipei, et al. Effect and control of foundation pit excavation on existing tunnels: a state-of-the-art review[J]. Tunnelling and Underground Space Technology, 2024, 147: 105704.
- [2] 王卫东. 软土深基坑变形及环境影响分析方法与控制技术
  [J]. 岩土工程学报, 2024, 46(1): 1-25. (WANG Weidong. Analytical methods and controlling techniques for deformation and environmental influence of deep excavations in soft soils[J]. Chinese Journal of Geotechnical Engineering, 2024, 46(1): 1-25. (in Chinese))
- [3] HU Y, LEI H Y, ZHENG G, et al. Assessing the deformation response of double-track overlapped tunnels using numerical simulation and field monitoring[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(2): 436-447.
- [4] XU Q W, XIE J L, LU L H, et al. Numerical and theoretical analysis on soil arching effect of prefabricated piles as deep foundation pit supports[J]. Underground Space, 2024, 16: 314-330.
- [5] 胡之锋,陈 健,邱岳峰,等. 挡墙水平变位诱发地表沉降的显式解析解[J]. 岩土力学, 2018, **39**(11): 4165-4175. (HU Zhifeng, CHEN Jian, QIU Yuefeng, et al. Analytical formula for ground settlement induced by horizontal movement of retaining wall[J]. Rock and Soil Mechanics, 2018, **39**(11):

4165-4175. (in Chinese))

- [6] 薛艳杰. 基于机器学习算法的土岩复合地层深基坑变形时 序预测[J]. 现代隧道技术, 2022, 59(增刊 2): 77-85. (XUE Yanjie. Deformation time series prediction of deep foundation pit in soil-rock composite stratum based on machine learning algorithm[J]. Modern Tunnelling Technology, 2022, 59(S2): 77-85. (in Chinese))
- [7] 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): 321-327. (ZHAO Huajing, ZHANG Mingyang, LIU Wei, et al. Dynamic prediction of deformation of diaphragm wall in deep foundation pit based on neural network algorithm[J]. Chinese Journal of Underground Space and Engineering, 2021, 17(S1): 321-327. (in Chinese))
- [8] 张生杰, 谭 勇. 基于 LSTM 算法的基坑变形预测[J]. 隧 道建设(中英文), 2022, 42(1): 113-120. (ZHANG Shengjie, TAN Yong. Deformation prediction of foundation pit based on long short-term memory algorithm[J]. Tunnel Construction, 2022, 42(1): 113-120. (in Chinese))
- [9] 徐长节,李欣雨. 基于人工神经网络的深基坑支护结构侧移预测 [J/OL]. 上海交通大学学报, 1-20[2024-09-11]. https://doi.org/10.16183/j.cnki.jsjtu.2023.109. (XU Changjie, LI Xinyu. Lateral Deformation Prediction of Deep Foundation Retaining Structures Based on Artificial Neural Network[J/OL]. Journal of Shanghai Jiao Tong University, 1-20[2024-09-11]. https://doi.org/10.16183/j.cnki.jsjtu.2023. 109. (in Chinese))
- [10] 方 庆,陈 胜,刘雪珠,等.基于变分模态分解的 CNN-LSTM 模型在基坑变形预测中的应用[J/OL].力学与 实践,1-8[2024-09-11].http://kns.cnki.net/kcms/detail/11. 2064.o3.20240314.2043.002.html. (FANG Qin, CHEN Sheng, LIU Xuezhu, et al. Application of the variational mode decomposition-based CNN-LSTM model in predicting excavation deformation[J]. Mechanics in Engineering, 1-8[2024-09-11].http://kns.cnki.net/kcms/detail/11. 2064.o3. 20240314.2043.002.html. (in Chinese))
- [11] 满 轲, 武立文, 刘晓丽, 等. 基于 CNN-LSTM 模型的 TBM 隧道掘进参数及岩爆等级预测[J/OL]. 煤炭科学技术, 1-19[2024-09-11]. http://kns.cnki.net/kcms/detail/11.2402.TD. 20231026.1344.003.html. (MAN Ke, WU Liwen, LIU Xiaoli, et al. The prediction of TBM tunnel boring parameters and rockburst grade based on CNN-LSTM model[J/OL]. Coal Science and Technology, 1-19[2024-09-11]. http://kns.cnki. net/ kcms/ detail/11.2402.TD.20231026.1344.003.html. (in

Chinese))

- [12] 王 锋. 基于 SSA-LSTM 模型的软岩隧道变形特征智能预测及应用研究[J]. 现代隧道技术, 2024, 61(1): 56-66.
  (WANG Feng. Study on intelligent prediction of the deformation characteristics of soft rock tunnel based on SSA-LSTM model and its application[J]. Modern Tunnelling Technology, 2024, 61(1): 56-66. (in Chinese))
- [13] 洪宇超, 钱建固, 叶源新, 等. 基于时空关联特征的

(上接第230页)

- [8] FLEMING W G K. The improvement of pile performance by base grouting[J]. Civil Engineering, 1993, 97(2): 88-93.
- [9] THIYYAKKANDI S, MCVAY M, BLOOMQUIST D, et al. Measured and predicted response of a new jetted and grouted precast pile with membranes in cohesionless soils[J]. Journal of Geotechnical and Geoenvironmental Engineering, 2013, 139(8): 1334-1345.
- [10] JOER H A, RANDOLPH M F, GUNASENA U. Experimental modeling of the shaft capacity of grouted driven piles[J]. Geotechnical Testing Journal, 1998, 21(3): 159-168.
- [11] MULLINS G, WINTERS D, STEVEN D. Predicting end bearing capacity of post-grouted drilled shaft in cohesioniess soils[J]. Journal of Geotechnical and Geoenvironmental Engineering, 2006, 132(4): 478-487.
- [12] 王卫东,李永辉,吴江斌.上海中心大厦大直径超长灌注 桩现场试验研究[J]. 岩土工程学报,2011,33(12):
  1817-1826. (WANG Weidong, LI Yonghui, WU Jiangbin.

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): 108-111. (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): 108-111. (in Chinese))

(编校: 胡海霞)

Field loading tests on large-diameter and super-long bored piles of Shanghai Center Tower[J]. Chinese Journal of Geotechnical Engineering, 2011, **33**(12): 1817-1826. (in Chinese))

- [13] 戴国亮,万志辉,龚维明,等.基于沉降控制的组合后压 浆灌注桩承载力计算研究[J]. 岩土工程学报,2018,40(12): 2172-2181. (DAI Guoliang, WAN Zhihui, GONG Weiming, et al. Calculation of bearing capacity for combined post-grouting bored piles based on settlement control[J]. Chinese Journal of Geotechnical Engineering, 2018, 40(12): 2172-2181. (in Chinese))
- [14] 万志辉, 戴国亮, 龚维明, 等. 超厚粉细砂地层组合压浆 桩压浆效果试验[J]. 中国公路学报, 2018, 31(3): 59-67.
  (WAN Zhihui, DAI Guoliang, GONG Weiming, et al. Experiment on grouting effects of combined grouting piles under extra-thick fine silty sand layer[J]. China Journal of Highway and Transport, 2018, 31(3): 59-67. (in Chinese))

(编校:黄贤沙)