文章编号：1674-2974（2026）03-0063-13 DOI：10.16339/j.cnki.hdxbzkb.2026025

基于CNN-LSTM的深基坑挡墙变形时空分布预测方法

廖少明[1,2]，唐琳鸿[1†]，杨逸枫[1]，张世阳[3]，范垚垚[3]，刘智[3]
（1. 同济大学 土木工程学院地下建筑与工程系，上海 200092；
2. 同济大学 岩土及地下工程教育部重点实验室，上海 200092；
3. 中国建筑第八工程局有限公司，上海 200120）

摘 要：为实现软土地层基坑挡墙变形的精准预测与有效控制，保障基坑安全施工，本文基于基坑挡墙变形显著的时空分布变化特征，建立基坑挡墙变形时空分布矩阵并提出融合卷积神经网络（CNN）和长短时记忆网络（LSTM）的混合预测模型CNN-LSTM，结合上海某深基坑工程，从时空维度对挡墙变形进行同步预测与对比验证. 结果表明：1）基于挡墙位移时空分布矩阵的CNN-LSTM混合预测模型与4种传统模型相比，通过时空分布特征的提取与深度学习，可对基坑水平位移的时空分布实现精准预测；2）在空间分布预测方面，通过位移空间分布特征的提取与深度学习，不仅能对挡墙变形模式进行准确识别，还能对变形曲率及最大变形位置等分布特征进行精准预测，沿深度和水平方向预测的平均绝对误差M_{AE}分别为0.532 mm和0.742 mm；3）在时间分布预测方面，通过水平位移时序特征的提取与深度学习，并考虑长短时数据依赖关系，能适应不同施工阶段挡墙位移的动态预测，施工期内预测的M_{AE}为0.841 mm，表现出良好的鲁棒性.

关键词：CNN-LSTM；时空分布特征；挡墙位移；神经网络
中图分类号：TU94 **文献标志码**：A

A CNN-LSTM-based prediction method for spatiotemporal distribution of retaining wall deflection in deep excavations

LIAO Shaoming[1,2]，TANG Linhong[1†]，YANG Yifeng[1]，ZHANG Shiyang[3]，FAN Yaoyao[3]，LIU Zhi[3]
（1. Department of Geotechnical Engineering，College of Civil Engineering，Tongji University，Shanghai 200092，China；
2. Key Laboratory of Geotechnical and Underground Engineering of the Ministry of Education，Tongji University，Shanghai 200092，China；
3. China Construction Eighth Engineering Division Co.，Ltd.，Shanghai 200120，China）

Abstract：To achieve accurate prediction and effective control of retaining wall deflection in soft soil excavations and to ensure construction safety，this study developed a spatiotemporal distribution matrix of retaining wall displacement based on its significant spatiotemporal distribution characteristics and created a hybrid CNN-LSTM prediction model that integrates convolutional neural networks（CNN）and long short term memory（LSTM）.

* **收稿日期**：2024-06-11
基金项目：国家自然科学基金资助项目（52090082），National Natural Science Foundation of China（52090082）
作者简介：廖少明（1966—），男，湖北天门人，同济大学教授，博士
† 通信联系人，E-mail：2232369@tongji.edu.cn

The research synchronously forecasted and compared the wall deflection from both temporal and spatial dimensions through a deep excavation project in Shanghai. The results show that: 1) Compared with four traditional conventional models, the CNN-LSTM hybrid prediction model, based on the spatiotemporal distribution matrix of the retaining wall displacement, demonstrates precise prediction of the spatiotemporal distribution of horizontal displacement through the extraction of spatiotemporal distribution characteristics and deep learning. 2) For spatial distribution prediction, the extraction of spatial distribution features combined with deep learning enables not only accurate identification of the deflection mode of the retaining wall but also precise prediction of distribution features such as deformation curvature and positions corresponding to maximum deflection. The predicted M_{AE} in depth and horizontal directions is 0.532 mm and 0.742 mm, respectively. 3) For time distribution prediction, the dynamic forecasting of retaining wall displacement at various construction stages is achieved through the extraction of horizontal displacement time series features and deep learning, while considering both short- and long-term data dependencies. The predicted results during the construction period demonstrate good robustness, with an M_{AE} of 0.841 mm.

Key words: CNN-LSTM; spatiotemporal distribution characteristic; retaining wall deflection; neural networks

近年来,随着我国经济高速发展,城市人口不断增加,地面空间开发日益饱和,越来越多的工程建设趋向于地下空间,如地铁、地下管线、商业综合体等.基坑作为地下空间开发的重要手段,其规模和施工难度不断增加[1],导致作为基坑工程重要支护方式的挡墙结构,在基坑开挖过程中面临诸多风险,例如位移超限、渗漏、开裂等.一旦发生事故,会对基坑主体结构和周围环境安全造成严重威胁.因此,开发一种高精度的基坑挡墙变形超前预测模型,对保证基坑及周边环境安全尤为关键.

过去的几十年里,国内外学者已经对基坑开挖诱发的挡墙变形问题开展了大量研究.Tan等[2]基于上海某26 m深的地铁车站基坑实测数据,分析了挡墙位移、地面沉降等随工况的发展规律;李航等[3]对深度为31.3 m的上海某超深基坑开挖引起的环境变形特性进行了研究分析,总结了超深基坑显著的时空分布特性;文献[4-6]通过大量挡墙位移实测数据,从统计角度探讨了地下连续墙的变形性状,确定了挡墙最大侧移与开挖深度的关系.但受特定地质水文条件限制,不同基坑的变形性状差异较大,上述基于实测数据得到的挡墙变形经验规律对开挖变形控制的指导意义相对有限.在理论解析方面,文献[7-8]通过改进可移动强度设计方法和动态调整方程理论对基坑开挖诱发的挡墙水平位移进行预测;文献[9-11]基于弹性地基梁理论,运用动态反演分析方法,实现基坑围护结构变形及稳定性的超前预测;Dan等[12]和Tong等[13]基于最小势能原理,建立了挡墙位移理论计算方法.上述理论计算方法受到假定和特定的工程地质条件限制,适用范围有限.有限元分析方法作为工程计算的有效手段,被广泛应用于基坑工程领域[14-16],文献[17-19]基于有限元法分析了开挖深度、挡墙刚度、土体参数等对挡墙变形的影响,得到挡墙侧移简化计算公式;有学者[20-21]通过Abaqus、FLAC3D等分析软件模拟不同施工状态、地质条件和支护类型的基坑,对挡墙位移与地表沉降进行计算;在此基础上Wang等[22]和Bhatkar等[23]结合现场实测数据分析了基坑开挖过程中的时空效应.数值模拟能很好地考虑周围环境对围护结构变形的影响,并能全过程模拟各施工阶段的受力和变形,但模型建立和计算耗时较长,且部分参数无法通过现场或实验直接获取.此外,数值模拟得到的基坑变形结果大多对应较长区间时间范围内或者笼统施工步骤的数据,难以预测每天的基坑变形.

随着基坑规模不断增大,传统方法在处理大规模时空分布数据和应对复杂施工工况方面仍存在局限.因此,具备大数据处理优势的机器学习和深度学习算法在岩土工程领域得到广泛应用[24-25].Yang等[26]基于门控循环单元(gated recurrent unit,GRU)算法,实现了顶管机掘进姿态的动态预测;Zhang等[27]将长短时记忆网络(long short term memory,

LSTM)模型用于预测盾构机掘进引起的地表最大沉降和纵向沉降曲线;钱建固等[28]基于小波降噪优化建立了融合LSTM和自回归滑动平均算法(auto regressive moving average,ARMA)的混合模型,对基坑开挖诱发的地表沉降进行了预测.针对基坑开挖引起的挡墙变形预测,也有学者进行了相关研究[29-34],验证了卷积神经网络(convolutional neural networks,CNN)和人工神经网络模型(artificial neural network,ANN)应用于挡墙变形预测的有效性.物理机制的融合可显著提升挡墙变形预测的可解释性[35-37],但复杂的网络结构使其实际应用过程中易受计算资源限制,从而导致动态预测性能下降.此外,现有方法在平衡监测数据与物理机制对预测模型贡献方面存在困难,易导致模型参数过度依赖物理机制,从而削弱实测数据特征的作用,进而降低模型预测结果的可靠性和泛化能力.

已有文献验证了将深度学习算法应用于挡墙变形预测的有效性,但挡墙变形具有显著的时空分布特征[38-40],目前大多数预测模型没有考虑挡墙变形的时空分布特征,导致模型动态预测精度和稳定性较低,在准确预测挡墙变形模式和特征上仍有改进空间.针对此问题,本文首先构建挡墙变形时空分布矩阵,描述基坑开挖诱发的挡墙变形时空分布特征;在此基础上,采用CNN提取空间分布特征,LSTM处理时间序列特征,建立了一种基于CNN-LSTM混合模型的挡墙变形时空分布预测法.通过充分利用监测数据所包含的复杂时空分布关系,从数据时空分布特征角度间接考虑岩土物理力学性质、支护形式等因素对挡墙变形的影响,克服既有方法的局限性,实现挡墙变形与风险的超前动态预测,为基坑工程的施工安全管理提供有力支持.

1　时空分布特征与模型

1.1　挡墙变形时空分布特征

挡墙变形呈现两个显著的时空分布特征:1)深度方向上,挡墙变形随深度与时间发生变化;2)基坑平面上,挡墙变形随测点位置与时间发生变化.由单个测点监测数据可从时间和空间维度构建二维时空分布矩阵,如图1所示.在空间维度上,单个测点沿深度方向间隔 x m布置数据采集点,总计 N 个;在时间维度上,测点每日自动采集数据,共采集 D 天.数据采集点间距和采样频率受工程规模、基坑等级等因素影响可适当加密,每日数据叠加形成维度 $N\times D$ 的时空分布矩阵 $\boldsymbol{\Delta}$,如式(1)所示.由 $\boldsymbol{\Delta}$ 可识别挡墙各测点位移不同深度和时间的时空变化趋势.

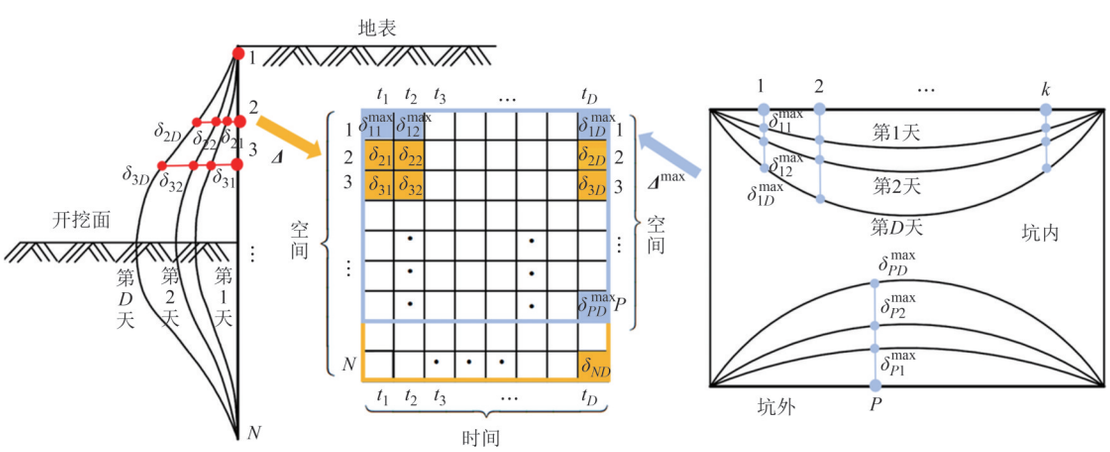

图1　挡墙水平位移时空分布矩阵

Fig.1　Spatiotemporal matrix of excavation-induced horizontal displacement of retaining wall

基坑开挖过程中,各测点挡墙水平位移相互影响,最大水平位移主要发生在开挖面附近[41],因此在不同测点间可构建一个二维时空矩阵,空间维度上为各测点沿深度方向的最大水平位移,共 P 个测点,时间维度与时空矩阵 $\boldsymbol{\Delta}$ 一致,共采集 D 天,每日数据叠加形成维度为 $P\times D$ 的时空分布矩阵 $\boldsymbol{\Delta}^{\max}$,如式(2)所示.由 $\boldsymbol{\Delta}^{\max}$ 可预测基坑挡墙的整体水平位移时空变化趋势.

$$\boldsymbol{\Delta}^{k}=\begin{bmatrix}\delta_{11}^{k} & \delta_{12}^{k} & \cdots & \delta_{1D}^{k}\\ \delta_{21}^{k} & \delta_{22}^{k} & \cdots & \delta_{2D}^{k}\\ \vdots & \vdots & \delta_{ij}^{k} & \vdots\\ \delta_{N1}^{k} & \delta_{N2}^{k} & \cdots & \delta_{ND}^{k}\end{bmatrix} \tag{1}$$

式中:δ_{ij}^{k} 代表位于第 k 个测点第 i 个深度位置,第 j 天

的水平位移.

$$\boldsymbol{\Delta}^{\max}=\begin{bmatrix}\delta_{11}^{\max} & \delta_{12}^{\max} & \cdots & \delta_{1D}^{\max}\\ \delta_{21}^{\max} & \delta_{22}^{\max} & \cdots & \delta_{2D}^{\max}\\ \vdots & \vdots & \delta_{kj}^{\max} & \vdots\\ \delta_{P1}^{\max} & \delta_{P2}^{\max} & \cdots & \delta_{PD}^{\max}\end{bmatrix} \tag{2}$$

式中:$\delta_{kj}^{\max}$代表位于第k个测点,第j天的最大水平位移.

1.2 CNN-LSTM混合预测模型

CNN-LSTM模型最早由Donahue等[42]提出,结合了CNN和LSTM的优点,可充分考虑数据的时空特征关系,特别适用于处理具有复杂时空关系的数据集.因此,考虑挡墙变形具有的显著时空特征,本文采用CNN-LSTM模型框架,通过CNN层提取时空分布矩阵中的空间特征,并由LSTM层处理CNN层输出的特征,与前列数据整合进行时序建模,最后通过全连接层整合复杂时空特征预测值并输出,模型结构如图2所示.

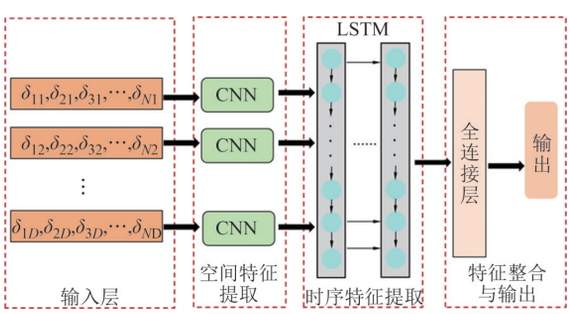

图2 CNN-LSTM模型结构

Fig.2 CNN-LSTM model structure

2 CNN-LSTM模型建立

CNN-LSTM模型用于挡墙变形预测包括数据准备、模型训练和模型验证3个关键步骤.首先,将预处理后的数据转换为时空矩阵$\boldsymbol{\Delta}$和$\boldsymbol{\Delta}^{\max}$.然后,将标记的训练集输入模型进行训练,当达到设定的迭代次数或误差满足要求时,终止训练.最后,通过已训练模型对未标记数据进行预测,并与实测数据进行比较,得到模型评价指标.

2.1 数据前处理

施工过程中受多种因素影响,监测效果存在不确定性,导致监测数据无法直接用于模型训练.因此,为保证预测精度,需在模型训练前对原始数据进行前处理,主要包括空值处理和异常值剔除.考虑到基坑开挖过程中,挡墙变形逐渐增大,相邻两天同一测点、同一深度位置处的数据间波动较小,故本文采用均值填充法,以相邻两天同测点和同深度位置处的位移均值替代缺失值,从而保持数据的连续性.此外,由于监测数据受传感器故障影响,不可避免地存在异常值.为保证预测精度与监测数据中时空分布特征的完整性,以卡方分布的0.95分位数为阈值,通过式(3)所示的马氏距离[43]检测并剔除异常值,剔除后产生的缺失值按空值处理方法进行填充.

$$D_{(M)}(\boldsymbol{x})=\sqrt{(\boldsymbol{x}-\boldsymbol{\mu})^{\mathrm{T}}\boldsymbol{S}^{-1}(\boldsymbol{x}-\boldsymbol{\mu})} \tag{3}$$

式中:$\boldsymbol{x}=(x_1,x_2,\cdots,x_P)^{\mathrm{T}}$;$\boldsymbol{\mu}=(\mu_1,\mu_2,\cdots,\mu_P)^{\mathrm{T}}$,为$\boldsymbol{x}$的均值;$\boldsymbol{S}$为协方差矩阵.

2.2 数据集划分

基于时空矩阵$\boldsymbol{\Delta}$和$\boldsymbol{\Delta}^{\max}$,按输入时间步$m$与输出时间步1构建时间滑动窗口,逐步将数据集划分为输入$\boldsymbol{x}_{Nm}$与输出$\boldsymbol{y}_{N1}$用于模型训练,如图3(a)所示.在此基础上,未来n天的挡墙位移预测流程如图3(b)所示,将当前预测输出$\boldsymbol{y}_{N1}$与原输入$\boldsymbol{x}_{Nm}$叠加形成输入$\boldsymbol{x}_{Nm+1}$,并按输入时间步m与输出时间步1向前滑动,实现输入和输出实时更新;通过循环n次,得到未来n天的挡墙位移预测值.

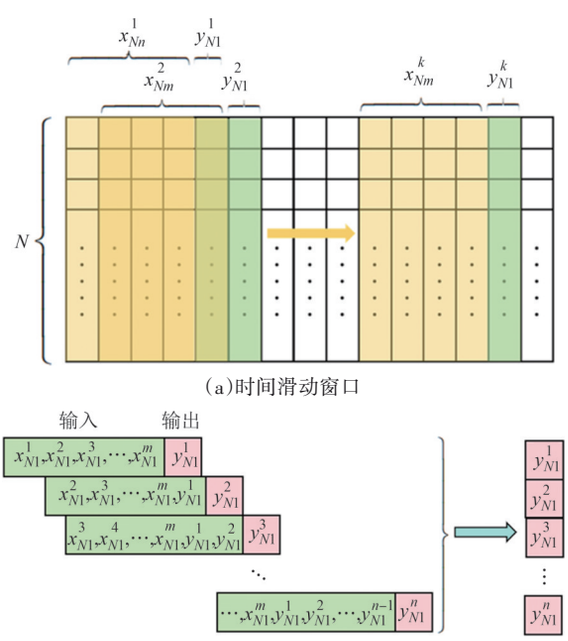

(a)时间滑动窗口

(b)未来n天的挡墙位移预测

图3 动态预测模型

Fig.3 Dynamic prediction model

2.3 模型参数与评价指标

超参数寻优是建立深度学习模型的必要步骤,其取值会对模型训练和预测效果产生较大影响,故本文采用网格搜索算法[44]对CNN-LSTM模型进行超参数优化.该方法通过将模型超参数的可行范围离

散为网格并遍历所有参数组合,依据模型评价指标筛选最优参数组合用于模型构建.网格搜索对象和调优范围如表1所示,最终确定的最优超参数组合与模型参数设置如表2所示,其中损失函数采用平均绝对误差(mean absolute error, MAE)M_{AE},评价指标选用均方误差(mean square error, MSE)M_{SE}、平均绝对百分比误差(mean absolute percentage error, MAPE)M_{APE}.输入步长m为7 d,预测天数为5 d.

表1　超参数网格搜索调优范围

Tab.1　Hyperparameter tuning ranges for the grid search algorithm

超参数	调优范围
学习率	0.01, 0.001, 0.000 1
卷积滤波器	8, 16, 32, 64, 128
LSTM单元	8, 16, 32, 64, 128

表2　CNN-LSTM模型参数

Tab.2　Parameters for the CNN-LSTM model

参数	CNN			LSTM	学习率	批次	训练
	卷积层	池化层	滤波器	神经元		大小	步数
取值	1	1	16	128	0.001	32	2 000

2.4　预测模型

考虑到开挖引起的挡墙变形具有两个显著的时空分布特征,分别构建两类预测模型.1)两步预测模型:基于时空分布矩阵$\boldsymbol{\Delta}$预测未来n天各测点处挡墙位移,得到单个测点处挡墙的变形模式.然后,提取各测点预测结果的最大值,得到未来n天的挡墙整体最大位移,分别如图4中a_1和a_2所示.2)单步预测模型:利用时空分布矩阵$\boldsymbol{\Delta}^{max}$,直接预测未来$n$天的挡墙整体最大位移,如图4中$b_1$所示.

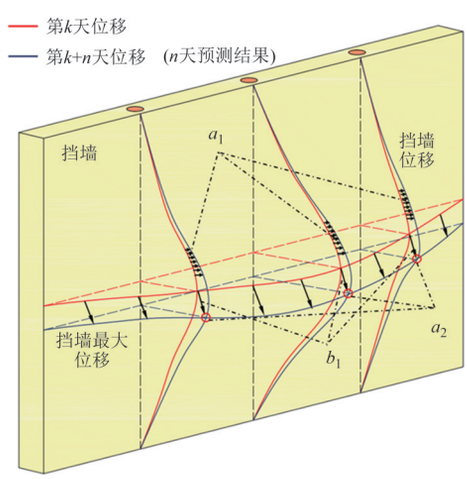

图4　挡墙变形时空分布预测步骤

Fig.4　Steps for spatiotemporal prediction of retaining wall deflection

3　案例分析

3.1　工程概况

本文以上海某软土深基坑为背景,该基坑北邻地铁12号线区间隧道,面积约62 200 m^2,分A、B、C、D、E五个区依次施工.考虑到基坑开挖面积大、邻近地铁,且地下条件复杂多变,挡墙在基坑开挖期间长期面临安全风险,为保证基坑稳定及周围建(构)筑物的安全,共布置14个挡墙位移测点(P1~P14),监测频率为每天1次,基坑平面图和测点布置如图5(a)所示,基坑典型剖面如图5(b)所示.采集整理A、B区基坑开挖期间14个测点的数据,覆盖挡墙变形快速发展和稳定发展阶段,并基于时空分布矩阵$\boldsymbol{\Delta}$和$\boldsymbol{\Delta}^{max}$,构建挡墙水平位移数据集,如表3所示.各测点挡墙最大变形随施工工况变化的发展趋势如图6所示.基坑5个分区的支护方案、地层条件以及周边环境等存在差异,将构建的CNN-LSTM模型应用于此基坑,可充分验证模型的稳定性和鲁棒性.

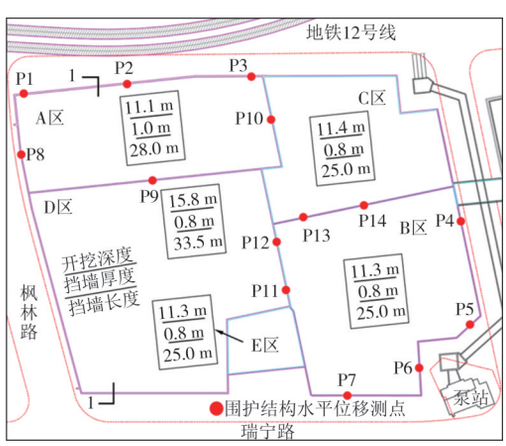

(a)基坑平面布置图

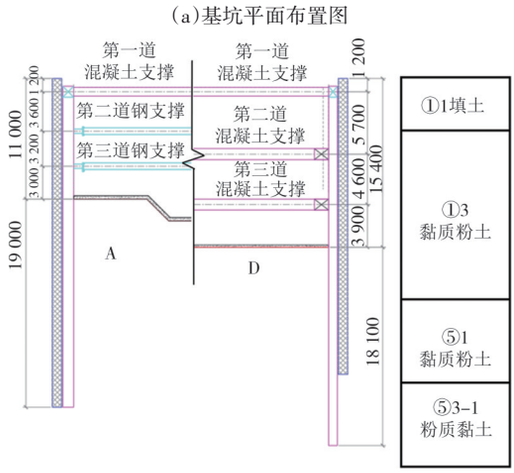

(b)1-1剖面图(单位:mm)

图5　基坑平面和典型剖面图

Fig.5　Site plan and typical sectional of excavations

表3 挡墙位移监测数据的统计特征

Tab.3 Statistical characteristics of the dataset for retaining wall displacement

测点	维度($N\times D$)	最大值/mm	最小值/mm	均值/mm	标准差/mm
P1	53×67	12.17	0.00	6.11	3.35
P2	51×59	14.86	−1.11	7.23	4.51
P3	53×60	12.78	−0.30	6.31	3.36
P4	47×116	57.81	0.33	28.78	17.56
P5	47×89	76.71	2.00	42.48	22.46
P6	47×111	37.81	0.11	17.24	9.73
P7	59×112	93.94	1.00	51.88	26.15
P8	55×68	16.27	−6.95	5.32	5.11
P9	43×69	44.45	−9.98	13.30	14.44
P10	47×72	75.07	−3.60	26.03	23.16
P11	65×122	61.35	−6.68	30.63	17.73
P12	51×122	72.97	−10.76	34.54	21.60
P13	49×123	98.83	−6.94	48.15	30.44
P14	39×120	94.97	11.00	47.43	31.5

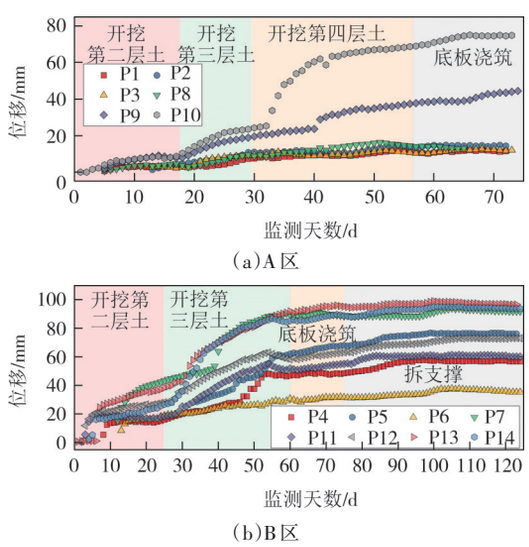

图6 挡墙最大变形

Fig.6 Maximum deflection of retaining wall

3.2 预测结果

为避免模型训练和预测存在时空关联,取各测点最后5期监测数据为测试集,其余监测数据为训练集,以输入步长为7 d的时间滑动窗口对数据集进行划分,作为模型输入.随监测期数增加,将异常检测后的监测数据加入数据集并按设定输入步长划分数据,以此循环,实现不同施工阶段挡墙变形的动态预测.训练过程M_{AE}损失变化曲线如图7所示,M_{AE}在模型前50次迭代中快速下降,当迭代次数达到200次时逐渐趋于稳定,训练效果较好,此外,为避免过拟合,在Early Stopping机制下,模型在M_{AE}损失不再下降时停止迭代,保证了模型在测试集上的预测精度.

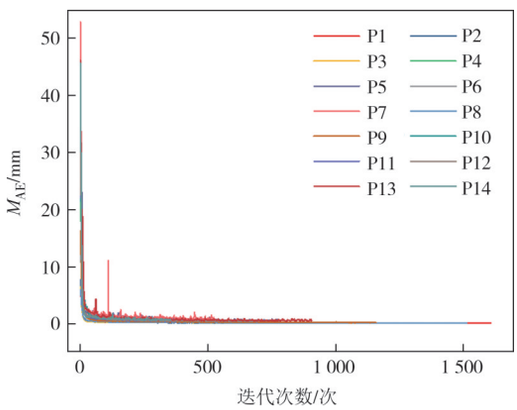

图7 M_{AE}损失变化曲线

Fig.7 Curve of M_{AE} loss variation

3.2.1 挡墙变形时空分布预测结果

由表4可知,CNN-LSTM模型在训练集与测试集上均表现出良好的性能,其M_{AE}值分别仅为0.763 mm和0.532 mm,表明模型在已标记数据和未知数据上均能取得精度较高的预测结果.此外,由图8(a)可知,随预测天数增加,模型预测误差逐渐增大.其主要原因是,挡墙变形多日动态预测基于挡墙变形单日预测结果,导致模型输入在动态更新过程中误差不断积累.但在5 d内测试集的平均预测误差相对较小,最大M_{AE}仅为0.532 mm,且预测结果均沿最佳预测线分布[图8(b)],表明通过挡墙变形时空分布特征的提取,能有效控制模型在多日动态预测中的误差累积,使模型在未来5 d内保持较高的预测精度,适用于挡墙位移时空分布多日动态预测.挡墙各测点的水平位移预测偏差分布如图9所示.整体来看,各测点预测偏差较小,其中最大偏差分别出现在P7和P10测点,分别为−2.47 mm和2.77 mm,偏差百分比仅为2.68%和3.71%,表明预测模型在具备不同时空特征的数据集上表现出良好的鲁棒性.

表4 CNN-LSTM模型评价指标

Tab.4 Evaluation metrics of CNN-LSTM model

数据集类型	M_{AE}/mm	M_{SE}/mm^2	M_{APE}/%
训练集	0.763	6.553	8.925
预测集	0.532	0.518	5.276

基坑开挖诱发的挡墙变形受工况影响较大,不同施工阶段的变形发展规律存在差异.为验证模型在前期及中长期施工过程中的动态预测性能,由上述模型对14个测点监测期内的水平位移进行预测,

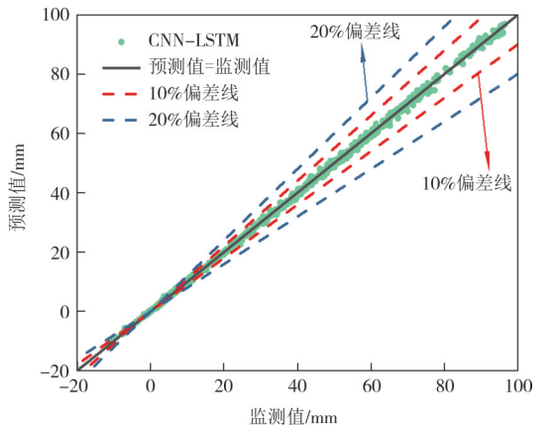

(a)CNN-LSTM模型预测值与监测值散点分布

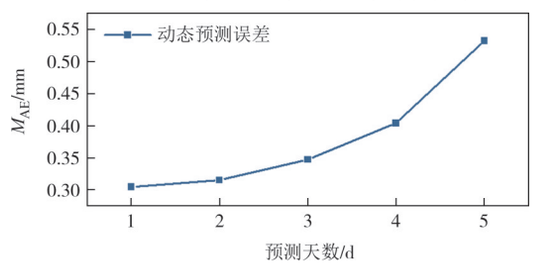

(b)挡墙变形动态预测误差

图 8　挡墙变形时空分布预测结果

Fig.8　Spatiotemporal distribution prediction results of retaining wall deflection

各测点预测效果相近,因此以测点P4为例,得到如图10所示的空间分布预测结果. 由图10可知,模型

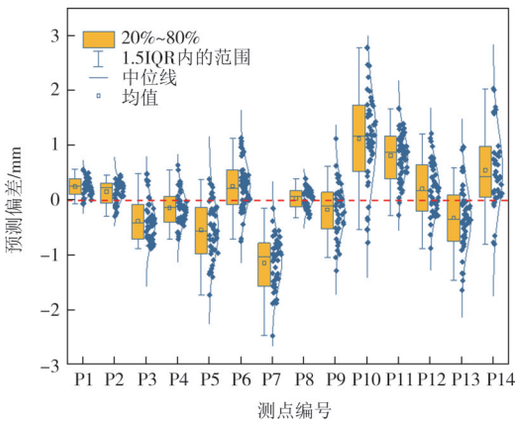

图 9　不同测点预测偏差分布

Fig.9　Distribution of prediction errors for different points

在挡墙位移空间分布预测中能准确捕捉挡墙“鼓腹型”变形模式,沿深度方向的预测误差M_{AE}、M_{SE}和M_{APE}分别为0.642 mm、0.549 mm^{2}和1.901%. 此外,变形曲率反映了挡墙的挠曲程度,竖向过大的曲率可能导致挡墙开裂和渗漏安全隐患,故准确预测曲率分布特征是挡墙变形预测的重要部分. 与实测曲率相比,CNN-LSTM模型的挡墙位移预测结果的曲率峰值偏大,但整体分布高度一致,且曲率最大值集中分布于挡墙最大变形深度位置附近,可准确捕捉曲率峰值位置,验证了模型在挡墙位移空间分布预测上的准确性.

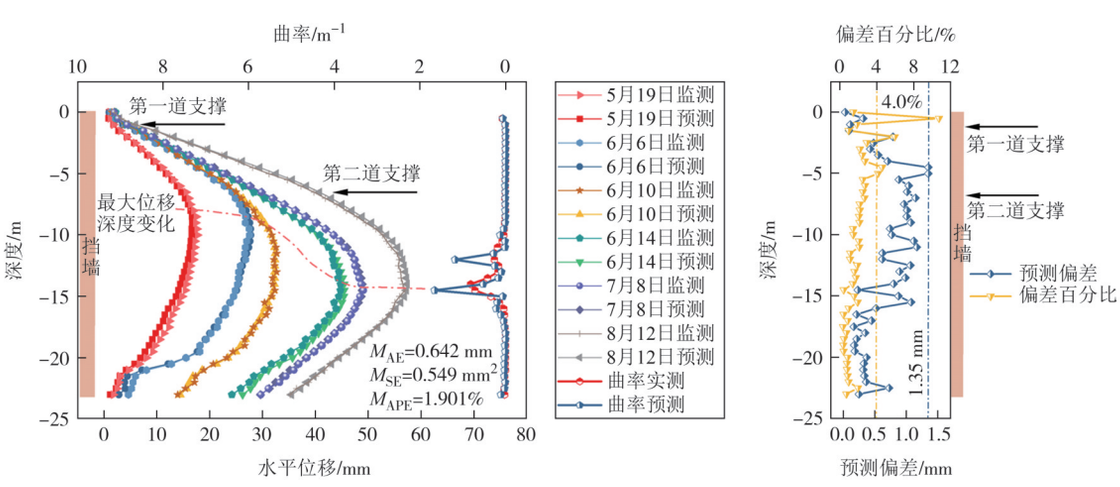

(a)空间分布预测结果　　(b)变形预测偏差

图 10　两步模型空间分布预测结果

Fig.10　Spatial distribution prediction of the double-step model

基坑开挖诱发的挡墙变形是动态变化过程,在土方开挖初期,由于基坑开挖深度较小,挡墙变形整体较小;随着基坑持续开挖,挡墙变形快速发展;当基坑开挖完毕,挡墙变形逐渐趋于稳定. 由图11可知,模型通过动态更新数据集,提取不同阶段的复杂时空分布特征,在时间分布预测上,M_{AE}、M_{SE}和M_{APE}分别为0.841 mm、1.146 mm^{2}和2.376%,表现出较高的精度与鲁棒性,最大偏差发生在第二道支撑拆除阶段,为2.926 mm,偏差百分比为5.347%. 表明模型在挡墙变形快速发展和稳定阶段的动态预测中均保

持较高的精度.此外,最大位移深度预测结果与实测深度变化总体保持一致,最大偏差为±1 m,进一步验证了模型在空间分布预测方面的优势.

由图10和图11可知,通过CNN-LSTM混合预测模型提取挡墙水平位移竖向空间分布特征,可在空间分布上,准确识别挡墙剖面变形模式、挡墙最大变形对应深度与曲率分布特征;在时间分布上,将挡墙多日变形特征转换为时间序列,可获取挡墙水平位移长期依赖关系.然而,模型在施工前期和工况转换阶段预测精度相对较低,主要归因于该阶段缺乏足够的时空分布特征数据.通过提高监测频率,可使模型在短时间内快速学习施工初期和工况转换阶段的挡墙变形发展规律,进而从时空两个维度对基坑开挖诱发的挡墙水平位移进行准确预测,为工程施工和安全管理提供参考.

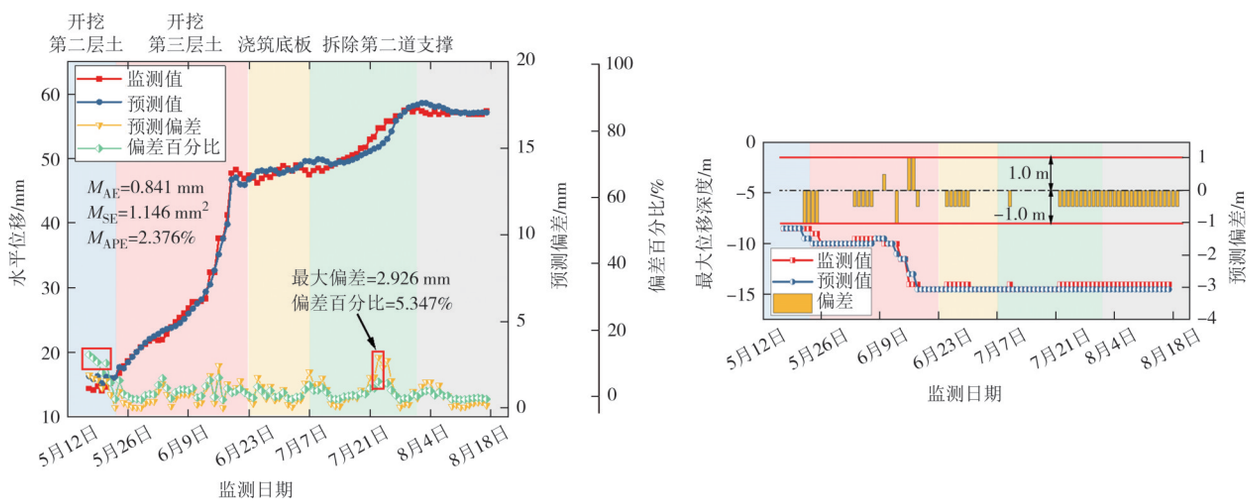

(a)时间分布预测结果 (b)最大变形位置

图11 两步模型时间分布预测结果

Fig.11 Temporal distribution prediction of the double-step model

3.2.2 挡墙最大变形预测

挡墙最大变形主要发生在基坑开挖面附近,采用单步预测模型可实现挡墙最大位移的整体预测,以快速识别挡墙位移超限风险.受基坑尺寸和分区等多种因素影响,不同测点间的挡墙水平位移在空间上呈现出不同程度的关联特征.因此,在预测前需验证各测点间的关联特征,以此保证模型的预测精度.通过式(4)所示的皮尔逊相关系数[45]计算得14个测点间的相关系数R分布,如图12所示.

$$R^{a,b}=\frac{\sum_{i=1}^{t}\left(x_i^a-\bar{x}^a\right)\left(x_i^b-\bar{x}^b\right)}{\sqrt{\sum_{i=1}^{t}\left(x_i^a-\bar{x}^a\right)^2\sum_{i=1}^{t}\left(x_i^b-\bar{x}^b\right)^2}} \tag{4}$$

式中:x_i^a,x_i^b分别为第a、b个测点监测数据$\boldsymbol{x}^a$,$\boldsymbol{x}^b$的第i个值;$\bar{x}^a$,$\bar{x}^b$分别为$\boldsymbol{x}^a$,$\boldsymbol{x}^b$的均值;t为样本数量.一般认为$0.8<R\leqslant 1.0$为强相关;$0.5<R\leqslant 0.8$为中等强度相关;$0\leqslant R\leqslant 0.5$为弱相关或不相关.

由图12可以观察到,除P8和P2测点间的皮尔逊相关系数仅为0.38,表现出较弱的相关性外,其余测点间的挡墙变形均呈中强和强相关性,表明挡墙变形在空间上的显著关联特征.因此,可采用单步模型预测挡墙最大变形.

基于时空分布矩阵$\boldsymbol{\Delta}^{\max}$,对未来第5天的挡墙最大变形进行预测,得到预测误差M_{AE}、M_{SE}和M_{APE}如表5所示.其中训练集和测试集M_{AE}分别为1.451 mm和0.742 mm,预测效果较好.

由图13可知,两种模型的挡墙最大位移预测偏差均较小.其中,单步模型对挡墙最大位移的预测偏差集中在-1.19~1.36 mm范围内,两步模型的最大位移预测偏差分布在-1.35~2.52 mm范围内,整体略大于单步模型,验证了单步预测模型应用于挡墙最大水平位移整体预测的可靠性与有效性.从训练效率角度出发,由两步模型预测各测点位移并提取最大值,需对14点数据集进行预测,训练时长约为$14\times T$(T为单次训练的平均时长).而基于时空分布矩阵$\boldsymbol{\Delta}^{\max}$的单步预测模型只需获取各测点每日最大位移,进行一次预测,训练时长为$1\times T$.因此,单步模型可在保证预测精度的前提下显著降低训练时长,提高训练效率,适用于快速预测并识别基坑开挖过程中的挡墙变形相关风险.

通过单步预测模型对P1~P14测点监测期内最

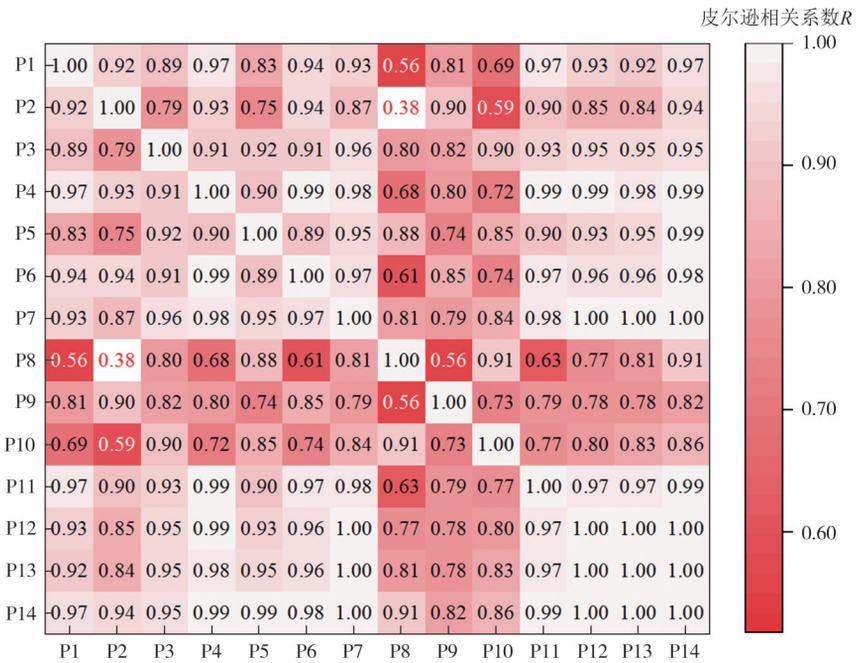

图 12　测点空间相关性热力图

Fig.12　Heat map of spatial correlation of measuring point

表 5　单步模型评价指标

Tab.5　Evaluation metrics of the single-step model

数据集类型	M_{AE}/mm	M_{SE}/mm^2	M_{APE}/%
训练集	1.451	21.916	5.194
预测集	0.742	0.989	2.150

大水平位移进行预测,预测误差M_{APE}分布在0.88%~4.87%范围内.以A区基坑P1、P2和P3测点所在挡墙为例,得到如图14所示的挡墙变形时空分布预测曲线.在预测精度方面,3个测点处M_{APE}分别为4.31%、4.87%和4.24%,误差均处于较低水平;在时空分布规律上,挡墙位移呈现“中部大,角部小”的“鼓腹型”变化趋势,且变形随基坑开挖整体增大,时空分布特征显著.表明单步预测模型可在空间维度准确提取挡墙位移时空分布矩阵$\boldsymbol{\Delta}^{max}$中各监测点间的空间关联特征,并从时间维度获取挡墙最大位移的长期依赖关系,实现挡墙最大位移的高精度超前预测.

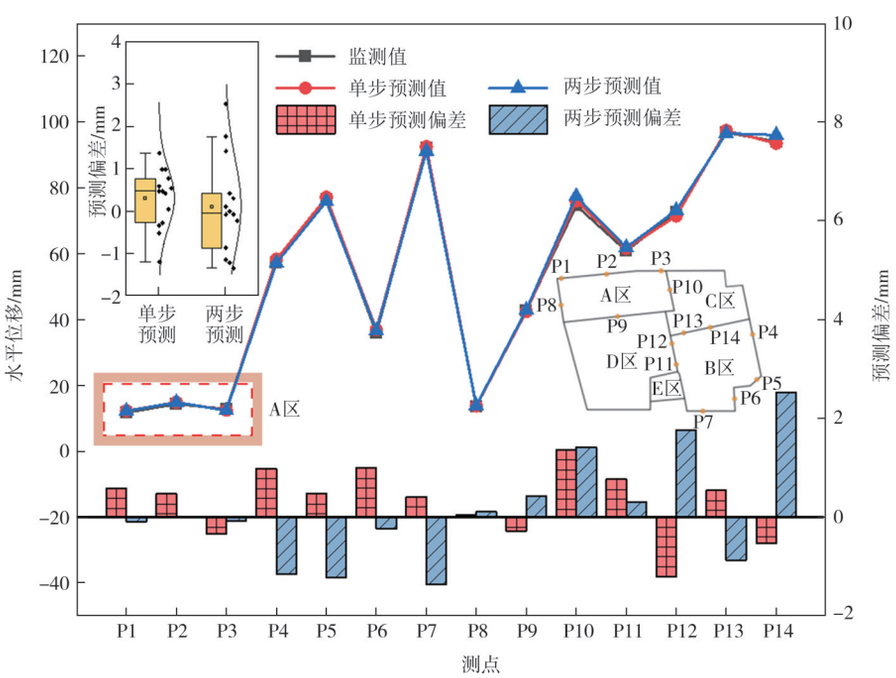

图 13　挡墙最大位移预测结果对比

Fig.13　Comparison of predicted maximum of retaining wall displacement

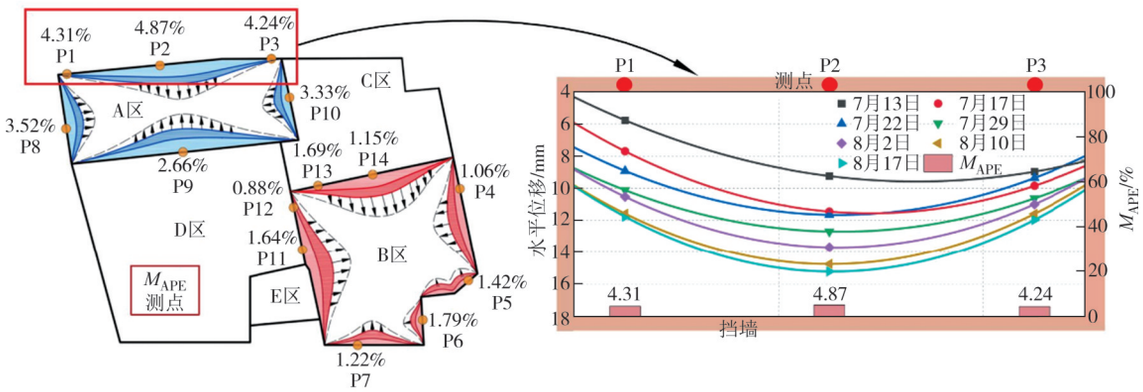

图 14 单步模型时空分布预测结果

Fig.14 Spatiotemporal distribution prediction of the single-step model

4 模型对比验证

为验证CNN-LSTM模型在挡墙变形时空分布预测方面的效果及优势,将CNN-LSTM与4种常用预测模型进行比较,包括CNN、LSTM、ANN和卷积长短时记忆网络(convolutional-long short term memory,Conv-LSTM)模型.5种模型的训练与预测误差如表6所示.

表6 5种模型预测评价指标

Tab.6 Evaluation metrics for five models

模型	训练集			测试集		
	M_{AE}/mm	M_{SE}/mm^2	M_{APE}/%	M_{AE}/mm	M_{SE}/mm^2	M_{APE}/%
CNN-LSTM	**0.763**	**6.553**	**8.925**	**0.532**	**0.518**	**5.276**
CNN	0.861	10.970	16.861	0.824	1.418	7.874
LSTM	7.731	188.260	157.292	6.206	65.395	31.938
ANN	0.904	11.301	23.442	0.611	0.637	9.434
Conv-LSTM	2.156	65.498	26.890	2.364	67.850	11.617

由表6可知,在5种模型中,CNN-LSTM模型的M_{AE}、M_{SE}和M_{APE}均最小.其中,该模型在测试集上的M_{AE}相较于其余4种模型(CNN、LSTM、ANN和Conv-LSTM)分别降低35%、91%、13%和77%.根据图15与图16的数据分布可知,同时提取时空特征的CNN-LSTM模型的预测结果沿最佳预测线呈线性分布,精度高,泛化能力强,且模型在各测点的训练集和测试集上的M_{AE}均保持稳定,表现出较高的鲁棒性.CNN模型仅考虑数据的空间特征,未考虑时序特征与长期依赖关系,其分布也具有较高的线性特征,但与CNN-LSTM相比,预测值与监测值的偏差相对较大,精度更低.LSTM模型仅提取数据的时序特征进行训练,未对挡墙位移空间分布特征进行提取,其预测结果分布在10%偏差线和35%偏差线之间,模型稳定性和精度较低.ANN模型的预测结果分布在最佳预测线和10%偏差线之间,模型稳定性较好,但无法捕捉数据长期依赖关系,与CNN-LSTM相比,预测精度相对较低.Conv-LSTM模型通过卷积操作提取空间特征,而未进行池化操作,导致在挡墙位移的复杂时空分布预测中,模型鲁棒性和稳定性不足,其部分测点预测结果沿最佳预测线分布,P5测点预测结果整体超出20%偏差线.

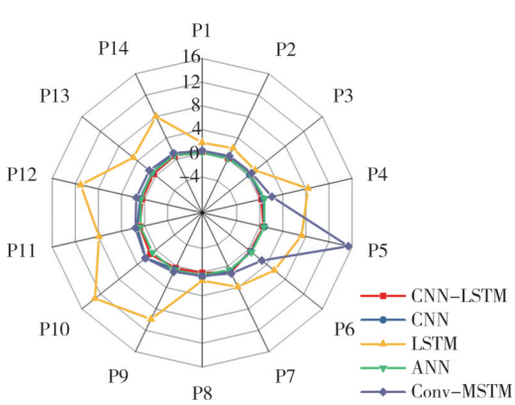

图 15 5种模型M_{AE}雷达对比图

Fig.15 The radar chart of the M_{AE} for the five models

上述结果表明,提取挡墙水平位移时空分布特征对挡墙位移的精准预测至关重要.基于时空分布矩阵的CNN-LSTM混合预测模型突破了传统预测方法的局限,在挡墙水平位移预测中具有双重优势,不仅能有效提取数据的空间分布特征,还具有强大的时间序列处理能力,使模型能够更全面地学习数据的时空分布特征.因此,其在不同测点间能保持稳定且高精度的预测性能,更适用于基坑开挖诱发的挡墙变形预测.

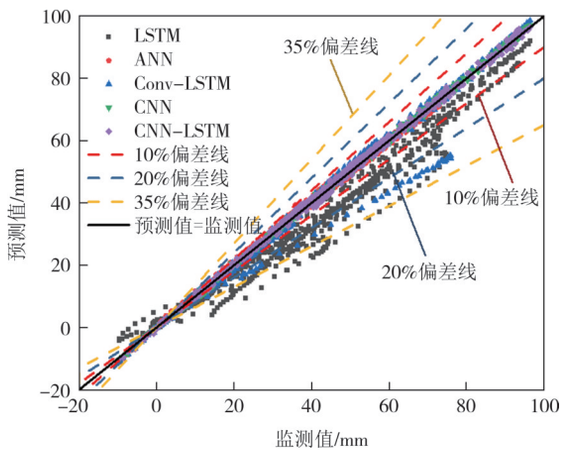

图 16　5种模型预测结果对比

Fig.16　Comparison of prediction results for five models

5　结 论

本文通过构建基坑挡墙水平位移时空分布矩阵$\boldsymbol{\Delta}$和$\boldsymbol{\Delta}^{\max}$,并建立CNN-LSTM混合预测模型,结合上海某深大基坑工程,从时空两个维度对挡墙变形进行同步预测与对比验证,得到主要结论如下:

1)基于时空分布矩阵$\boldsymbol{\Delta}$和$\boldsymbol{\Delta}^{\max}$,CNN-LSTM混合模型通过时空分布特征的提取与深度学习,能有效控制模型输入在动态更新过程中的误差累积,实现挡墙位移时空分布的多日动态精准预测.

2)空间分布预测上,模型准确预测了挡墙水平位移的"鼓腹型"变化模式,及平面"中部大,角部小"的空间分布模式.此外,准确预测了挡墙变形曲率分布与最大位移对应深度变化,最大变形曲率集中分布在最大变形处.M_{AE}、M_{SE}和M_{APE}沿深度和水平方向预测结果分别为0.532 mm和0.742 mm、0.518 mm^{2}和0.989 mm^{2}以及5.276%和2.150%.

3)时间分布预测上,模型通过提取不同施工阶段挡墙位移的复杂时空分布特征,动态预测了施工期内的挡墙位移,预测误差M_{AE}、M_{SE}和M_{APE}分别为0.841 mm、1.146 mm^{2}和2.376%,表现出较高的预测精度和鲁棒性.

4)在挡墙最大变形预测方面,两步模型和单步模型预测精度相近,预测偏差集中分布在±2 mm范围内,但单步模型训练耗时更短,能更快地评估挡墙变形相关风险.

5)提取时空分布特征对确保挡墙位移预测的精度和鲁棒性至关重要.相较于CNN、LSTM、ANN和Conv-LSTM模型,同时提取挡墙水平位移时空分布特征的CNN-LSTM模型在测试集上的M_{AE}分别降低35%、91%、13%和77%,更适用于复杂时空特征序列的预测.

本文所建立的CNN-LSTM混合神经网络在基坑位移预测方面表现出较高的精度与鲁棒性,随工况变化取得了良好动态预测效果,降低了对工程和周围环境的相关风险,进一步为位移场景映射或工况推演奠定基础.然而,本模型未考虑支撑轴力、开挖深度等工况参数,出现工况突变时,模型无法快速调整网络结构参数,导致预测精度下降.因此,模型更适用于工况变化均匀或采用自动化监测手段的基坑工程,未来的研究将考虑如何结合基坑开挖工况参数以应对更复杂的基坑工程情境.

参考文献

[1] LIAO S M, FAN Y Y, SHI Z H, et al. Optimization study on the reconstruction and expansion of an underground rail transit center in Shanghai soft ground[J]. Tunnelling and Underground Space Technology, 2013, 38: 435-446.

[2] TAN Y, LI M W. Measured performance of a 26 m deep top-down excavation in downtown Shanghai [J]. Canadian Geotechnical Journal, 2011, 48(5): 704-719.

[3] 李航,李泽文,廖少明,等. 上海超深基坑环境变形时空分布特性实测分析[J]. 岩土工程学报,2023,45(8):1595-1604.
LI H, LI Z W, LIAO S M, et al. Field measurement of time-space distribution behaviors of environmental settlement of an ultra-deep excavation in Shanghai soft ground[J]. Chinese Journal of Geotechnical Engineering, 2023, 45(8): 1595-1604. (in Chinese)

[4] 徐中华,王建华,王卫东. 上海地区深基坑工程中地下连续墙的变形性状[J]. 土木工程学报,2008,41(8):81-86.
XU Z H, WANG J H, WANG W D. Deformation behavior of diaphragm walls in deep excavations in Shanghai[J]. China Civil Engineering Journal, 2008, 41(8): 81-86. (in Chinese)

[5] 廖少明,魏仕锋, 谭勇, 等. 苏州地区大尺度深基坑变形性状实测分析[J]. 岩土工程学报,2015,37(3):458-469.
LIAO S M, WEI S F, TAN Y, et al. Field performance of large-scale deep excavations in Suzhou [J]. Chinese Journal of Geotechnical Engineering, 2015, 37(3): 458-469. (in Chinese)

[6] YANG T, LIU S L, WANG X Y, et al. Analysis of the deformation law of deep and large foundation pits in soft soil areas [J]. Frontiers in Earth Science, 2022, 10: 828354.

[7] LEI G, GONG X N. Analysis of lateral displacement law of deep foundation pit support in soft soil based on improved MSD method [J]. Advances in Civil Engineering, 2021, 2021: 5550214.

[8] DONG Y, LUAN Y Z, WANG F, et al. Monitoring and prediction of horizontal displacement of underground enclosure piles in subway foundation pits[J]. ACS Omega, 2023, 8(26): 23389-23400.

[9] 冯俊福, 俞建霖, 杨学林, 等. 考虑动态因素的深基坑开挖反演分析及预测[J]. 岩土力学, 2005, 26(3): 455-460.
FENG J F, YU J L, YANG X L, et al. Back analysis and prediction of deep pit foundation excavation considering dynamic factors[J]. Rock and Soil Mechanics, 2005, 26(3): 455-460. (in Chinese)

[10] 杨林德, 钟才根, 曾进伦. 基坑支护位移和安全性监测的动态预报[J]. 土木工程学报, 1999, 32(2): 9-13.
YANG L D, ZHONG C G, ZENG J L. Dynamic prediction for displacement and safety of foundation pit [J]. China Civil Engineering Journal, 1999, 32(2): 9-13. (in Chinese)

[11] 杨林德, 仇圣华, 杨志锡. 基坑围护位移量及其稳定性预测[J]. 岩土力学, 2001, 22(3): 267-270.
YANG L D, QIU S H, YANG Z X. Prediction on displacement and stability of frame bracing structure of foundation pit [J]. Rock and Soil Mechanics, 2001, 22(3): 267-270. (in Chinese)

[12] DAN K, SAHU R B. Estimation of ground movement and wall deflection in braced excavation by minimum potential energy approach [J]. International Journal of Geomechanics, 2018, 18(7): 04018068.

[13] TONG L H, GUO W L, XU C J, et al. Simplified theoretical prediction for lateral deformation of a diaphragm wall using the general third-order plate theory [J]. International Journal of Geomechanics, 2023, 23(11): 04023188.

[14] DO T N, OU C Y, CHEN R P. A study of failure mechanisms of deep excavations in soft clay using the finite element method[J]. Computers and Geotechnics, 2016, 73: 153-163.

[15] HASHASH Y M A, WHITTLE A J. Ground movement prediction for deep excavations in soft clay [J]. Journal of Geotechnical Engineering, 1996, 122(6): 474-486.

[16] ZHANG W G, GOH A T C, XUAN F. A simple prediction model for wall deflection caused by braced excavation in clays [J]. Computers and Geotechnics, 2015, 63: 67-72.

[17] 谭跃虎, 吉同筠. 软土深挖基坑中挡墙侧向变形分析与计算[J]. 岩土工程学报, 1995, 17(4): 71-76.
TAN Y H, JI T J. Analysis and calculation of lateral wall deflection of braced excavation in soft-clay[J]. Chinese Journal of Geotechnical Engineering, 1995, 17(4): 71-76. (in Chinese)

[18] 金晓飞, 梁书亭, 朱筱俊, 等. 软土地区深基坑连续墙最大变形简易计算方法[J]. 岩土力学, 2015, 36(增刊2): 583-587.
JIN X F, LIANG S T, ZHU X J, et al. Simplified method for calculating maximum deformation of diaphragm walls caused by braced excavation in soft clays[J]. Rock and Soil Mechanics, 2015, 36(Sup.2): 583-587. (in Chinese)

[19] 刘国彬, 沈建明, 侯学渊. 深基坑支护结构的可靠度分析[J]. 同济大学学报(自然科学版), 1998, 26(3): 260-264.
LIU G B, SHEN J M, HOU X Y. Reliability analysis of braced structures of deep-excavation [J]. Journal of Tongji University (Natural Science), 1998, 26(3): 260-264. (in Chinese)

[20] 刘勇, 冯志, 黄国超, 等. 北京地铁工程深基坑围护结构变形研究[J]. 地下空间与工程学报, 2009, 5(2): 329-335.
LIU Y, FENG Z, HUANG G C, et al. The study in predicting the deformation of supporting structure for deep foundation pit [J]. Chinese Journal of Underground Space and Engineering, 2009, 5(2): 329-335. (in Chinese)

[21] 张运良, 聂子云, 李凤翔, 等. 数值分析在基坑变形预测中的应用[J]. 岩土工程学报, 2012, 34(增刊1): 113-119.
ZHANG Y L, NIE Z Y, LI F X, et al. Deformation prediction of excavations based on numerical analysis [J]. Chinese Journal of Geotechnical Engineering, 2012, 34(Sup.1): 113-119. (in Chinese)

[22] WANG D Y, WU K P, WANG J, et al. Deformation monitoring and simulation analysis of deep foundation excavation construction for subway station [J]. IOP Conference Series: Earth and Environmental Science, 2020, 580(1): 012027.

[23] BHATKAR T, BARMAN D, MANDAL A, et al. Prediction of behaviour of a deep excavation in soft soil: a case study [J]. International Journal of Geotechnical Engineering, 2017, 11(1): 10-19.

[24] XIAO H H, CAO Z Y, CAO R L, et al. Prediction of shield machine posture using the GRU algorithm with adaptive boosting: a case study of Chengdu Subway project [J]. Transportation Geotechnics, 2022, 37: 100837.

[25] BAI D X, LU G Y, ZHU Z Q, et al. Using time series analysis and dual-stage attention-based recurrent neural network to predict landslide displacement[J]. Environmental Earth Sciences, 2022, 81(21): 509.

[26] YANG Y F, LIAO S M, LIU M B. 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.

[27] ZHANG P, WU H N, CHEN R P, et al. A critical evaluation of machine learning and deep learning in shield-ground interaction prediction[J]. Tunnelling and Underground Space Technology, 2020, 106: 103593.

[28] 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): 1107-1115.
QIAN J G, WU A H, JI J, et al. Prediction for nonlinear time series of geotechnical engineering based on wavelet-optimized LSTM-ARMA model[J]. Journal of Tongji University (Natural Science), 2021, 49(8): 1107-1115. (in Chinese)

[29] WU C Z, HONG L, WANG L, et al. Prediction of wall deflection induced by braced excavation in spatially variable soils *via* convolutional neural network [J]. Gondwana Research, 2023,

123:184-197.

[30] YONG W X, ZHANG W G, NGUYEN H, et al. Analysis and prediction of diaphragm wall deflection induced by deep braced excavations using finite element method and artificial neural network optimized by metaheuristic algorithms [J]. Reliability Engineering & System Safety, 2022, 221: 108335.

[31] TRAN D, NGUYEN H, WANG Y R, et al. Analysis of artificial intelligence approaches to predict the wall deflection induced by deep excavation[J]. Open Geosciences, 2023, 15: 20220503.

[32] 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]. 上海交通大学学报, 2024, 58(11): 1735-1744.
XU C J, LI X Y. Lateral deformation prediction of deep foundation retaining structures based on artificial neural network [J]. Journal of Shanghai Jiao Tong University, 2024, 58(11): 1735-1744.(in Chinese)

[33] ZHAO H J, LIU W, SHI P X, et al. Spatiotemporal deep learning approach on estimation of diaphragm wall deformation induced by excavation[J]. Acta Geotechnica, 2021, 16(11): 3631-3645.

[34] KUNG G T C, HSIAO E C L, SCHUSTER M, et al. A neural network approach to estimating deflection of diaphragm walls caused by excavation in clays[J]. Computers and Geotechnics, 2007, 34(5): 385-396.

[35] YANG Y F, LIAO S M, TANG L H. Physics-guided architecture of neural networks for predicting wall deflection induced by braced excavations [C]//Information Technology in Geo-Engineering. Cham: Springer, 2025: 295-304.

[36] YANG Y F, LIAO S M, TEOH B K, et al. A physics-constrained neural network for predicting excavation-induced ground surface settlement in clay [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2025, 17(5): 2665-2681.

[37] LIU Y B, LIAO S M, YANG Y W, et al. Data-driven and physics-informed neural network for predicting tunnelling-induced ground deformation with sparse data of field measurement [J]. Tunnelling and Underground Space Technology, 2024, 152: 105951.

[38] 刘建航, 刘国彬, 范益群. 软土基坑工程中时空效应理论与实践(上)[J]. 地下工程与隧道, 1999(3): 7-12.
LIU J H, LIU G B, FAN Y Q. The theory and its practice by using the rule of time-space effect in soft soil excavation (part1) [J]. Undergrourd Engineering and Tunnels, 1999 (3): 7-12. (in Chinese)

[39] 李俊才, 张倬元, 罗国煜. 深基坑支护结构的时空效应研究[J]. 岩土力学, 2003, 24(5): 812-816.
LI J C, ZHANG Z Y, LUO G Y. Study on effects of time-space of retaining structures of the deep-foundation pit excavation [J]. Rock and Soil Mechanics, 2003, 24(5): 812-816. (in Chinese)

[40] FINNO R J, BLACKBURN J T, ROBOSKI J F. Three-dimensional effects for supported excavations in clay [J]. Journal of Geotechnical and Geoenvironmental Engineering, 2007, 133(1): 30-36.

[41] 李琳, 杨敏, 熊巨华. 软土地区深基坑变形特性分析[J]. 土木工程学报, 2007, 40(4): 66-72.
LI L, YANG M, XIONG J H. Analysis of the deformation characteristics of deep excavations in soft clay [J]. China Civil Engineering Journal, 2007, 40(4): 66-72. (in Chinese)

[42] DONAHUE J, HENDRICKS L A, GUADARRAMA S, et al. Long-term recurrent convolutional networks for visual recognition and description [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 7-12, 2015, Boston, MA, USA. IEEE, 2015: 2625-2634.

[43] MAHALANOBIS P C. On the generalized distance in statistics [J]. Sankhyā: The Indian Journal of Statistics, 2018, 80: S1-S7.

[44] LI J H, LI P X, GUO D, et al. Advanced prediction of tunnel boring machine performance based on big data [J]. Geoscience Frontiers, 2021, 12(1): 331-338.

[45] LEE RODGERS J, NICEWANDER W A. Thirteen ways to look at the correlation coefficient[J]. The American Statistician, 1988, 42(1): 59-66.