

DOI: 10.7672/sgjs2026130062

基于 CNN-LSTM-Attention 的狭窄型基坑开挖变形预测^{*}

李忠享¹, 胡科¹, 太俊¹, 徐伟¹, 孙浩然², 袁家威², 崔德山²

(1. 中国市政工程中南设计研究总院有限公司, 湖北 武汉 430010;

2. 中国地质大学(武汉)工程学院, 湖北 武汉 430078)

[摘要] 随着城市化进程的加速,地下管廊工程中狭窄型基坑的应用日益广泛。在狭窄型基坑的数值模拟计算中主要应用 HSS 模型。然而,目前的 HSS 小应变土体硬化模型在参数选取上多依赖经验值,导致数值模拟结果存在主观性偏差,缺乏更加准确且客观的模型参数。为了提高预测准确性,提出将 CNN-LSTM-Attention 模型引入基坑实例计算中,该模型结合了卷积神经网络(CNN)对空间特征的提取能力、长短期记忆网络(LSTM)对时序特征的挖掘能力以及注意力机制(Attention),能够更全面地处理基坑开挖变形问题,可以用于其 HSS 模型中参数的修正。结果表明,利用 CNN-LSTM-Attention 模型对 HSS 模型参数进行了反演修正,并得到了更为精确的修正后参数。反演修正后的模型预测值与实测值对比精度显著提高,并且将其与单一 BP 模型和单一 LSTM 模型进行了对比。该模型展现出显著优势,其平均绝对误差(MAE)、平均相对误差(MAPE)和均方根误差(RMSE)均优化于对比模型。研究结果表明,CNN-LSTM-Attention 模型在狭窄型基坑开挖变形预测中表现出色,能够更准确地反演 HSS 模型参数,相比于参数反演前其精度提高了 31.2%。同时相较于其他常用模型,CNN-LSTM-Attention 模型在预测精度和优化效果上也均实现了显著提升。

[关键词] 地下工程;综合管廊;基坑;数值模拟;CNN-LSTM-Attention 模型;参数反演;预测

[中图分类号] TU753 **[文献标识码]** A **[文章编号]** 2097-0897(2026)13-0062-11

Prediction of Deformation in Narrow Foundation Excavation Based on CNN-LSTM-Attention

LI Zhongxiang¹, HU Ke¹, TAI Jun¹, XU Wei¹, SUN Haoran², YUAN Jiawei², CUI Deshan²

(1. China South Municipal Engineering Design & Research Institute Co., Ltd., Wuhan, Hubei 430074, China;

2. School of Engineering, China University of Geosciences (Wuhan), Wuhan, Hubei 430074, China)

Abstract: With the acceleration of urbanization, narrow-type foundation excavation are increasingly applied in underground pipe gallery projects. In the numerical simulation of narrow-type foundation excavation, the HSS model is mainly used. However, the current HSS small-strain soil hardening model often relies on empirical values for parameter selection, leading to subjective deviations in numerical simulation results and a lack of more accurate and objective model parameters. To improve prediction accuracy, the CNN-LSTM-Attention model is proposed to be introduced into the calculation of foundation excavation examples. This model combines the spatial feature extraction ability of the convolutional neural network (CNN), the time series feature mining ability of the long short-term memory network (LSTM), and the attention mechanism (Attention), which can comprehensively handle the deformation problem of foundation excavation and be used to correct the parameters of the HSS model. The results show that the CNN-LSTM-Attention model was used to inversely correct the parameters of the HSS model, and more accurate corrected parameters were obtained. The comparison between the predicted values of the inversely corrected model and the measured values shows a significant improvement in accuracy. Moreover, it was compared with the single BP model and the single LSTM model. This model

^{*} 国家自然科学基金(42277171)
[作者简介] 李忠享,高级工程师,E-mail:162193953@qq.com
[通信作者] 孙浩然,硕士研究生,E-mail:shr@cug.edu.cn
[收稿日期] 2025-12-21

demonstrated significant advantages, with its mean absolute error (MAE), mean absolute percentage error (MAPE), and root mean square error (RMSE) all being optimized compared to the comparison models. In conclusion, the research results show that the CNN-LSTM-Attention model performs well in the prediction of deformation in narrow-type foundation excavation, and can more accurately inversely correct the parameters of the HSS model. Compared with before parameter inversion, its accuracy has improved by 31.2%. At the same time, compared with other commonly used models, the CNN-LSTM-Attention model has also achieved significant improvements in prediction accuracy and optimization effects.

Keywords: underground engineering; utility tunnel; foundation excavation; simulation; CNN-LSTM-Attention model; parameter inversion; prediction

0 引言

随着中国城市化进程的持续加速,城市空间开发逐步向地下延伸,地下综合管廊作为新型城市基础设施的核心组成部分,其建设规模与覆盖范围不断扩大。而地下综合管廊建设往往受城市市场地条件限制,需开挖大量宽度受限、周边环境复杂的狭窄型基坑。在此背景下,数值模拟作为预测基坑开挖过程中土体变形、支护结构受力及周边环境影响的核心技术,被广泛应用于狭窄型基坑工程的设计,成为保障工程安全的关键支撑手段。然而,现有研究与工程实践均表明,狭窄型基坑数值模拟多采用小应变土体硬化 HSS(hardening small strain)模型,该模型的各项核心参数选取多以经验值为主,存在较强的主观性,导致数值模拟结果的准确性难以保证,无法充分满足地下管廊工程变形预测的需求。因此,开展狭窄型基坑数值模拟研究,完善小应变土体本构模型在狭窄受限工况下的应用,对推动狭窄基坑数值模拟变形预测具有重要的理论与实践意义。

在基坑工程数值模拟方面,HSS 模型因能精准刻画土体小应变阶段的刚度特性,已成为复杂地质条件下基坑变形分析的主流本构模型之一,在国内外工程实践中得到广泛应用^[1]。管飞^[2]采用 HSS 本构模型对软土地层中的基坑进行了数值分析,模拟了土的双曲线型应力应变关系、压硬性、剪胀性、加卸载条件下土体刚度的差异,数值计算结果和实测值较为符合。邵羽等^[3]研究表明修正剑桥模型由于未能考虑土体小应变特性,导致基坑变形模拟结果相对 HSS 模型偏大,建议在进行敏感环境下的基坑开挖数值模拟时,优先采用能考虑土体小应变特性的 HSS 本构模型。吴瑞拓等^[4]使用 HSS 模型和合适的模型参数有效地模拟了基坑开挖过程中的变形性状,实测结果与有限元分析结果相吻合。董鑫等^[5]通过开展系列三轴试验、标准固结试验及共振柱试验,获得了土体的 HSS 模型相关参数,通

过对比模拟结果与监测数值,验证了试验获得模型参数方法的适用性及参数的可靠性。陆军等^[6]基于一系列室内试验和经验方程,标定了软土层的 HSS 模型参数。将该参数应用于实际基坑工程的三维仿真模拟,模拟结果显示通过室内试验获得的参数在侧向变形上更接近实测值,验证了模型参数标定方式的合理性和优越性。当前 HSS 模型应用存在的核心问题集中于参数确定的准确性与效率,传统室内试验取样扰动会导致参数失真,而复杂地质条件下参数的空间变异性难以精准表征^[7]。

随着数据驱动研究范式的兴起,CNN, LSTM, Attention 等机器学习模型因具备强大的非线性拟合与时序特征挖掘能力,在基坑变形预测领域得到快速推广,成为传统数值模拟方法的重要补充。CNN 模型凭借出色的空间特征提取能力,被用于挖掘基坑变形与多源环境参数的空间关联,显著优于传统方法^[8-9]。LSTM 模型在时序变形预测中应用最为广泛,相较于 BP 神经网络等静态建模方法,LSTM 在处理高度非线性时序监测数据时适应性更强,但受限于数据量与模型构建细节,其预测精度与可靠性仍需提升^[10-11]。Attention 机制的引入则解决了传统模型对关键时序节点捕捉不足的问题,提升了模型在监测数据缺失情况下的鲁棒性^[12-13]。当前这些模型存在的主要问题包括:仅依赖历史变形数据进行自回归预测,未能充分融合基坑空间效应等多源工程数据;模型泛化能力受地质条件和支护结构限制,部分模型存在可解释性不足的问题。

CNN-LSTM-Attention 混合模型与 HSS 本构模型的协同发展,为狭窄基坑变形预测提供了“数据驱动-机理分析”融合的新路径,二者在优势互补中展现出广阔的应用前景^[14]。CNN-LSTM-Attention 混合模型集成了 CNN 的空间特征提取、LSTM 的时序依赖建模与 Attention 的关键信息聚焦能力,有效弥补了单一模型的性能短板^[15]。HSS 本构模型则凭借扎实的力学机理基础,能够为变形预测提供物理

约束,避免数据驱动模型的过拟合问题,尤其在复杂地质条件下狭窄基坑变形趋势预判中具有不可替代的优势^[16]。未来二者的融合应用将成为核心发展方向:一方面,可利用 CNN-LSTM-Attention 模型的预测结果反演优化 HSS 模型参数,提升数值模拟的准确性;另一方面,HSS 模型的机理分析结果可作为先验知识指导混合模型的特征选择与结构设计,增强模型的可解释性与泛化能力。这种融合模式能够充分发挥数据驱动的高效精准优势与机理模型的可靠稳健特性,有望解决狭窄管廊基坑的变形预测难题,为基坑工程的智能监测与安全预警提供核心技术支撑。

本文将 CNN-LSTM-Attention 模型引入狭窄型基坑的实例计算中,对 HSS 模型参数进行反演优化,利用优化后参数进行基坑变形数值计算,最后将计算结果与实际监测数据进行比对,验证优化效果。该模型充分利用多源异构信息,增强对复杂地质条件下狭窄基坑开挖引起周围土体变形的理解,为未来类似工程项目提供更加科学合理的设计依据和技术支撑。

1 工程概况

1.1 项目概况

拟建知音侧路道路工程全长 581.37m,起点位于琴台大道与佳兆业壹号小区附近,终点位于汉江堤路。拟建道路规划红线宽度为 20m,道路分类为城市支路,路面设计标高为 23.000~25.990m,路面北高南低。本工程按照城市主干路进行设计,全长 6 000m,红线宽 50~75m,埋设管道直径为 800~1 500mm,埋深深度不超过 7m。两侧采用钢板桩支护,距离地面 0.5m 处采用钢支撑进行支护,如图 1 所示。本基坑长度远大于基坑宽度,且开挖深度大于开挖宽度,为狭窄型基坑,且该项目开挖工程施工周期较长,施工风险较大,具备典型性与代表性,因此本文选用此工程案例进行验证。同时因为是狭窄型基坑,因此在后续数值模拟中可以采用单元体模型来进行数值模拟,土体参数采用的是该工程 KC3 钻孔的勘测数据。

1.2 工程地质条件

根据勘察数据,场地地层垂向分布可依据沉积年代与成因类型划分为 5 个工程地质单元:①素填土与湖沼相淤泥沉积物构成表层覆盖层;②冲积成因的黏性土夹淤泥质土形成第 2 沉积单元;③作为岩性过渡带,第 3 单元呈现黏性土与砂土互层特征;④第 4 单元由冲积相砂质沉积层主导;⑤底层为晚更新世冲洪积复合地层,包含致密老黏性土与胶结




图 1 基坑支护剖面

Fig. 1 Profile of foundation excavation support

砂层。经过详细的地质勘测,开挖后侧壁主要地层从上到下依次为:①杂填土,②黏土,③淤泥质粉质黏土,④粉质黏土、粉土、粉砂互层,⑤粉砂,⑥黏质中粗夹砾卵石,如图 2 所示。




图 2 典型地层剖面

Fig. 2 Profile of typical strata

1.3 土体参数选取

为确定基坑(槽)支护设计岩土参数,本次勘察主要进行了原状土样室内快剪试验及现场岩土的原位测试。根据该工程 KC3 钻孔的勘测数据试验及测试结果,结合湖北省地方标准 DB42/T 159—2012《基坑工程技术规程》,经综合分析确定岩土参数如表 1 所示。

1.4 监测方案

鉴于该工程具有开挖周期长、施工风险高的显著特点,建立科学系统的全过程实时监测与动态调控机制具有关键性作用。通过构建多维度、多参数的智能化监测体系,可有效突破传统施工管理中的信息滞后与被动应对困境,实现风险隐患的精准识别与超前防控。本工程创新采用基于 BIM 技术集成化的监测平台,重点针对钢板桩支护结构的力学响应开展全生命周期数据采集与分析,其中桩后土体深层水平位移监测作为核心监测项目,通过预埋高精度测斜管实施连续自动化测量。

在具体实施层面,监测系统采用分布式光纤传

表 1 狭窄型基坑岩土设计参数

Table 1 Geotechnical design parameters of narrow foundation excavation

土层	重度/(kN·m ⁻³)	土工试验		规范标准		压缩模量 E _s /MPa	渗透系数/ (cm·s ⁻¹)
		黏聚力 c/kPa	内摩擦角 φ/(°)	黏聚力 c/kPa	内摩擦角 φ/(°)		
① ₁ 杂填土	(18.5)	—	—	8	18	2.0	2.0×10 ⁻³
① ₂ 素填土	(18.0)	—	—	10	8	2.0	8.0×10 ⁻⁴
① ₃ 淤泥	(17.0)	—	—	9	4	2.2	2.0×10 ⁻⁵
② ₁ 黏土	18.6	16	8	21	12	3.0	5.0×10 ⁻⁶
② ₂ 淤泥质粉质黏土	17.6	9	5	14	6	2.5	3.0×10 ⁻⁶
② ₃ 粉质黏土夹粉土	17.8	8	6	16	14	5.5	2.5×10 ⁻⁵
③粉质黏土、粉土、粉砂互层	18.4	10	7	11	19	9.0	—
④ ₁ 粉砂	(20.0)	—	—	0	31	14.0	2.5×10 ⁻²
④ ₂ 粉砂	(20.0)	—	—	0	35	23.0	—
④ _a 粉砂夹粉土、粉质黏土	17.8	10	7	11	20	13.0	—
⑤ ₁ 粉质黏土	19.2	25	10	31	15	9.3	1.5×10 ⁻⁶
⑤ ₂ 粉质黏土夹粉砂、砾卵石	19.3	20	10	21	20	10.0	2.5×10 ⁻²
⑤ ₃ 黏质中粗夹砾卵石	18.8	24	35	25	30	22.5	2.5×10 ⁻²

注:()中为经验值

感技术与电子测斜仪相结合的方案,沿基坑周边布置多组监测断面,每个断面设置 3 个不同深度的测斜管(深度穿透潜在滑动面以下 2m)。通过每小时自动采集土体位移数据,结合有限元数值模拟进行实时比对分析,当位移速率超过预警阈值(本工程设定为 3mm/d)时,系统自动触发三级预警机制:一级预警启动数据复核与人工验证,二级预警触发施工参数调整(如调整开挖步序或增加临时支撑),三级预警则立即启动应急预案并组织专家会诊。这种分级响应体系既保证了风险防控的及时性,又避免了过度反应造成的资源浪费。

具体测斜管布置如图 3 所示,本文选择 ZDX3 监测点数据进行后续模拟与训练,主要是因为基坑中部的土体和支护结构受力较为均匀,能够更好地代表整个基坑的整体稳定性状况。

2 CNN-LSTM-Attention 模型

2.1 CNN-LSTM-Attention 模型简介

人工神经网络作为机器学习的重要分支体系,在岩土工程数字化转型过程中已被成功应用于液塑限智能评估、桩基承载力演算、岩土材料本构建模等领域。该算法具有解析多维数据间复杂非线性关联的优势特征,在保持较高输入容错性的同时,兼具时空特征提取能力。其既能有效识别时间序列的演变规律,又可精准解析空间分布的耦合关系,这种双重优势使其在狭长型基坑变形趋势预测等工程场景中展现出显著适用价值。

本节将针对人工神经网络算法,介绍其原理及其在本文中的应用。以下将简要介绍目前岩土工程中最常用的长短期记忆神经网络和卷积神经网络,以及本文使用的基于注意力神经机制的卷积长短期神经网络。

目前在岩土领域中长短期记忆神经网络(long short term memory network, LSTM)主要针对其时间特征进行捕捉(见图 4),可以自行对时间信息选择学习与遗忘,但 LSTM 对于空间信息的捕捉较少。

而卷积神经网络(convolutional neural network, CNN)则被广泛运用于各类高纬度特征的相互关系(见图 5),在卷积神经网络架构中,特征提取的核心机制依赖于卷积核的运算过程。卷积核本质上是 1 个权重矩阵,通过与输入数据执行特定的矩阵变换,实现空间特征的抽取。具体而言,输入矩阵被系统性地分割为多个与卷积核维度匹配的数据块,每个数据块与卷积核进行点积计算,所得结果经有




图 3 监测点布置

Fig. 3 Layout of monitoring points




图 4 LSTM 结构

Fig. 4 LSTM structure

序排列形成新的特征图。在池化处理阶段,网络采用区域极值采样策略,与卷积运算的滑动窗口机制不同,池化操作的采样窗口互不重叠。这种下采样方式能够有效剔除冗余特征,保留关键信息,从而提升模型的泛化能力,避免过拟合现象的发生,但对于其时间信息的捕捉不足。所以虽然 LSTM 和 CNN 算法在岩土工程领域已展现出显著的应用价值,但单独使用 LSTM 或 CNN 模型仅能分别处理时序特征或空间特征。然而,在狭窄型基坑开挖过程中需要对时间与空间效应进行双重考虑,故本文采用 CNN 神经网络与 LSTM 神经网络结合并且加入 Attention 机制,从而使模型能够集中注意力在输入序列中的重要部分,提高了模型的性能。通过计算输入序列的加权平均值,给予重要部分更高的权重。因此 CNN-LSTM-Attention 神经网络可以更好地从时空效应角度并集中注意力于输入序列中更重要的部分,更好地提高模型性能,更好地开展对于狭窄型基坑开挖中引起土体变形的分析研究。

基于注意力机制的 CNN 神经网络与 LSTM 神经网络结合的 CNN-LSTM-Attention 神经网络结构如图 6 所示。

2.2 CNN-LSTM-Attention 算法的应用

本文将采用 CNN-LSTM-Attention 算法指导有限




图 5 卷积及池化结构

Fig. 5 Convolution and pooling structure

元的位移反分析,以及采用 CNN-LSTM-Attention 对比其他岩土工程中常用的神经网络模型在实际工程中的优势这两个角度,对 CNN-LSTM-Attention 在基坑开挖导致地层变形预测中的应用以及性能开展分析。

CNN-LSTM-Attention 混合模型整合了卷积神经网络的空间特征识别优势与长短期记忆网络的时序规律解析能力。以及结合注意力机制能够自动关注输入数据中最重要的部分,提高模型对关键信息的捕捉能力。在 CNN-LSTM-Attention 模型里,注意力层以 LSTM 层的输出为输入来计算各时间步的注意力权重。一方面,从数据处理与算法视角看,他能筛选干扰信号,避免实际测量值中的异常参数干扰拟合结果,还可凭借卷积池化操作削减输入 LSTM 层的数据规模,进而缩减运算耗时、提高运算效率;另一方面,立足时空预测分析维度,该模型既能萃取出关键的空间信息,又能构建起时间上的关联性。从注意力机制方面,引入 Attention 部分能够更准确地选择重要的时间步和空间位置,从而提高分类的准确性,可以应用于狭窄型基坑开挖动态预测分析的研究中,具体如图 7 所示。

1) 位移反分析

本研究采用 CNN-LSTM-Attention 混合神经网络技术进行位移反演分析。基于该基坑工程的地质勘察数据和施工图纸,利用有限元分析软件构建了




图 6 CNN-LSTM-Attention 神经网络结构

Fig. 6 CNN-LSTM-Attention neural network




图7 CNN-LSTM-Attention 映射
Fig. 7 CNN-LSTM-Attention mapping

ZDX3 监测点处的基坑开挖数值模型。通过对比数值模拟结果与实际监测的支护结构变形数据,筛选出代表性土层,并运用 CNN-LSTM-Attention 智能算法对小应变硬化模型的关键参数进行反演优化,为工程后续研究奠定可靠的数据基础。

2) CNN-LSTM-Attention 模型的精度优势
结合 CNN 模型和单一时序神经并加入注意力神经机制的 CNN-LSTM-Attention 网络与单一时序神经 LSTM 模型、BP 遗传算法模型。基于基坑开挖引起钢板桩水平位移实测数据,对比 CNN-LSTM-Attention 网络、LSTM 模型和 BP 遗传算法模型的预测精度,并将混合 CNN-LSTM-Attention 网络、LSTM 模型和 BP 遗传算法模型,为基坑开挖引起钢板桩水平位移预测提供参考。

3 基于 CNN-LSTM-Attention 的狭窄型基坑开挖对支护结构位移反分析

3.1 小应变土体硬化模型

有限元数值模拟的预测效果与本构模型紧密相关,选对本构模型及其参数,能大幅提高预测准确性。当下常用土体本构模型的参数多源于土体大应变加载试验,然而诸多工程实测与研究显示,施工时基坑周边多数区域土体处于小应变状态,仅

少数区域有明显塑性变形,并且基坑开挖对土体主要是卸载过程。由此可见,兼顾土体小应变和卸载特性的模型,理论上更契合基坑开挖数值分析。小应变硬化土模型(即 HSS 模型)由 Benz 在硬化土模型(HS 模型)基础上改进而成,涵盖 11 个 HS 参数与 2 个小应变参数,综合考量了土体小应变区刚度随应变的非线性变化,既能体现软黏土硬化特性,区分加载、卸载,又让刚度取决于应力历史与路径,用于基坑开挖工程优势显著。

除了 HS 模型所需参数外,HSS 模型还需要确定的小应变特性参数为参考初始剪切模量 G_0^{ref} 和阈值剪应变 $\gamma_{0.7}$,两者均需由室内共振柱试验确定。在缺少试验数据的情况下,可以用经验公式(1)和(2)进行估算:

$$G_0^{\text{ref}} = 33 \frac{(2.97 - e)^2}{1 + e} \quad (1)$$

$$\gamma_{0.7} = \frac{1}{9G_0} [2c'(1 + \cos 2\varphi') - \sigma'_1(1 + K_0) \sin 2\varphi'] \quad (2)$$

式中: e 为孔隙比; c' 为有效黏聚力; φ' 为内摩擦角; σ'_1 为最大主应力; K_0 为静止土压力系数; $9G_0$ 为构成莫尔-库仑形式的偏应力水平。

3.2 数值模拟过程与结果

因为是狭窄型基坑,通常长宽比在 10 以上,因此可以采用单元体模型来进行坑底隆起的数值模拟。数值模拟时,单元体模拟基坑宽度为 3.5m,模拟周围土层宽度为 52~55m,模拟深度为 25m,减小了边界效应对模拟结果的影响。土体模型采用小应变硬化土模型。钢板桩采用板单元进行模拟,钢管支撑采用梁单元进行模拟,均采用线弹性模型。网格采用非均匀划分的方式,距离一定范围以内加密网格,加密范围根据基坑开挖深度确定。土体采用 10 结点四面体单元,钢板桩采用板单元的 6 结点板单元,钢管支撑采用梁的 3 结点线单元。通过界面单元考虑土体和支护结构之间的接触,结构间接触除钢管支撑与钢板间支撑为铰接外其余均设置为刚接。除模型顶面代表地面外,其余侧面均采用水平和垂直方向约束。因为基坑较浅,所以不考虑地下水的影响,将水头固定在地下 20m 处。分阶段施工时,首先激活拉森钢板桩,然后开挖基坑,开挖至支撑设计标高时激活钢管支撑,然后开挖至设计坑底高度,最后进行安全性计算。具体步骤如下。

- 1)第 1 步:建立几何模型并定义土体材料参数,将水头定义在地下 20m 处,如表 2 所示。
- 2)第 2 步:建立结构模型并定义结构材料参数。
- 3)第 3 步:将基坑底部土体和支护结构周围土体局部加密,划分网格。
- 4)第 4 步:设置塑性开挖计算步骤和安全性计算步骤,开始计算。
- 模拟结果如图 8 所示,钢板桩边缘最大变形为

40.12mm,中部最大变形为 41.25mm,最大变形都集中在地表以下 5.5m 左右,且在不同深度下,钢板桩在边缘和中部的变形量接近,说明支护结构刚度大、支撑间距小的情况下变形差异小。




图 8 钢板桩变形
Fig. 8 Deformation of steel sheet pile

选取基坑变形量和受力较大的单元体中部作截面分析,如图 9 所示。基坑横向变形最大值为 40.53mm,位于基坑底部。基坑坑底发生隆起变形,变形最大值为 60.21mm,位于基坑底部中点;基坑两侧发生地表沉降,沉降最大值为 10.25mm,位于基坑侧壁 1~5m 的范围内。由此可以看出基坑土体位移变形主要由两部分组成:①地表至地表以下 1.75 倍开挖深度的基坑外侧土体向坑内滑动变形,②基坑底部土体因为坑壁外侧土体的挤压作用而向上隆起变形。由于钢板桩嵌入土体深度很深,导致两部分变形土体无法在桩底部联结贯通,且桩底土体承载能力较好,不受基坑开挖的影响而产生隆起变形,使得土体变形区域仅集中在基坑底面与坑底上下 7m 内的基坑侧壁。

表 2 HSS 模型土层参数

Table 2 Soil layer parameters of HSS model

参数	土层					
	杂填土	② ₁ 黏土	② ₂ 淤泥质粉质黏土	③粉质黏土、粉土、粉砂互层	④ ₁ 粉砂	⑤ ₃ 黏质中粗夹砾卵石
Z/m	1.1	2.6	3.7	5.8	8.8	14.8
γ/(kN·m ⁻³)	18.5	18.2	18.2	18.6	18.8	18.8
γ _{sat} /(kN·m ⁻³)	19	18.7	18.7	19.1	19.3	19.1
E ₅₀ ^{ref} /kPa	4 000	6 000	5 000	18 000	28 000	45 000
E _{oed} ^{ref} /kPa	4 000	6 000	5 000	18 000	28 000	45 000
E _{ur} ^{ref} /kPa	12 000	18 000	15 000	54 000	84 000	135 000
G ₀ ^{ref} /kPa	7 933	8 737	7 240	70 940	75 940	80 215
γ _{0.7}	7.51×10 ⁻⁴	1.07×10 ⁻³	1.80×10 ⁻⁴	4.20×10 ⁻⁴	1.00×10 ⁻³	1.2×10 ⁻³
c/kPa	10	12	5	7	10	24
φ/(°)	18	10	15	33	31	35
ψ/(°)	0	0	0	3	1	2

注:Z 为土层厚度;γ 和 γ_{sat} 分别为天然重度和饱和重度;E₅₀^{ref} 为参考三轴排水剪切割线模量,对应 50%强度时的刚度;E_{oed}^{ref} 为参考侧限压缩模量,控制竖向压缩变形;E_{ur}^{ref} 参考卸载再加载模量,通常取 3E₅₀^{ref},反映基坑开挖卸荷时的回弹刚度;G₀^{ref} 为参考小应变初始剪切模量,表征土体在极小应变下的最大刚度;γ_{0.7} 为剪切模量衰减至 0.7 倍 G₀^{ref} 时的阈值应变,二者共同控制小应变刚度非线性行为;c 为有效黏聚力;φ 为有效内摩擦角;ψ 为剪胀角




图 9 基坑土体位移云图

Fig. 9 Cloud map of soil displacement in foundation excavation

3.3 基于 CNN-LSTM-Attention 算法的有限元位移反分析

针对复杂基坑工程参数识别问题,传统反分析方法通常需通过多轮参数调整与实测数据对比实现迭代优化,尤其在受限空间基坑开挖工况下面临较高计算成本。基于深度学习的 CNN-LSTM-Attention 混合模型凭借计算机性能的持续进步,可有效提升大样本数据的处理精度与效率。从岩土力学特性分析,土体模量参数主导变形响应特征,强度参数(黏聚力 c 、内摩擦角 φ) 主要控制稳定性表现。值得注意的是,工程实践中数值模拟所需的弹性模量 E 常基于实验室压缩模量 E_s 进行估算,根据工程经验通常取压缩模量的 3~5 倍估值。此外,受试验过程不可避免的离散性及开挖扰动效应影响,强度参数的实测值也存在不确定性。研究表明,相较于强度参数,模量参数对位移场的控制作用更为显著,因此选取 HSS 本构模型中的关键模量参数($E_{50}^{\text{ref}}, E_{\text{oed}}^{\text{ref}}, E_{\text{ur}}^{\text{ref}}, G_0^{\text{ref}}$) 作为反演对象更具工程合理性。本研究以支护结构水平位移为优化目标,结合有限元正演模拟与现场监测数据,重点分析位移偏差显著区域及最大变形区周边的土层响应特性。为避免参数间的耦合效应,反演策略采用统一系数对各参考模量进行整体修正。数据处理方面,选取钢板桩自由段监测点的位移时序数据作为模型输入,对应土层的参数修正因子作为输出,构建融合 CNN 特征提取、LSTM 时序分析及注意力机制加权处理的智能反演模型。该预测系统通过深度学习算法实现了小应变条件下土体参数的动态识别,为复杂工况的数值模拟参数确定提供了新的技术路径。首先对预测结果进行正演,本文主要利用开挖过程中钢板桩位移的数值模拟计算结果,正演结果

与实测结果如图 10 所示。




图 10 正演结果对比

Fig. 10 Comparison of forward modeling results

由图 10 可知,实际运用 HSS 模型进行数值模拟得到的钢板桩水平位移与实际监测数据误差依旧较大,这主要是由于 HSS 模型受几个主要参数的影响较大,并且其参数取值受人为主观因素的影响又较大,进而导致其模拟结果与实际监测值误差较大,因此对于其参数的修正至关重要。

正演预测值与实际预测值进行对比得知,误差较大的土层以及钢板桩的最大位移处均在第 3 层③粉质黏土、粉土、粉砂互层与第 4 层④₁ 粉砂之间,钢板桩的最大位移值作为本次正反演对比的主要评判标准,因此将最大位移所在的 2 层土层作为此次模拟训练的目标土层,经过上述分析,考虑对此 2 层土体小应变土体的上述 4 种模量分别乘以 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0, 1.1, 1.2, 1.3, 1.4 系数,完成 12×12 组有限元 3D 模型钢板桩水平位移交叉模拟。

将以上交叉模拟计算结果输入 CNN-LSTM-Attention 反演分析模型。将模拟结果作为训练集进行训练。最后通过实测值结果进行反演,得到③粉质黏土、粉土、粉砂互层与④₁ 粉砂的修正系数分别为 0.694 与 1.14,修正后参数如表 3 所示。

表 3 基于 CNN-LSTM-Attention 模型修正后参数
Table 3 The parameters after correction based on the CNN-LSTM-Attention model

参数	土层	
	③粉质黏土、粉土、粉砂互层	④ ₁ 粉砂
Z/m	5.8	8.8
$\gamma /(\text{kN} \cdot \text{m}^{-3})$	18.6	18.8
$\gamma_{\text{sat}} /(\text{kN} \cdot \text{m}^{-3})$	19.1	19.3
$E_{50}^{\text{ref}} / \text{MPa}$	12.495	31.92
$E_{\text{oed}}^{\text{ref}} / \text{MPa}$	12.492	31.92
$E_{\text{ur}}^{\text{ref}} / \text{MPa}$	37.476	95.76
$G_0^{\text{ref}} / \text{kPa}$	49 232	86 571
$\gamma_{0.7}$	4.20×10^{-4}	1.00×10^{-3}
c / kPa	0	0
$\varphi / (^{\circ})$	33	31
$\psi / (^{\circ})$	3	1

代入模型,得到训练中正反演以及训练后正反演与实测值对比结果如图 11 所示。




图 11 正反演与实测值对比结果

Fig. 11 Results of comparison between forward and inversion and measured values

由图 11 可知,经过 CNN-LSTM-Attention 反演模型的训练与修正,反演效果良好,在 0~7m 深度内,有限元模型一定程度低估了钢板桩的水平位移,而经过 CNN-LSTM-Attention 反演模型的训练与修正后,其反演的预测值与实测值的对比精度得到了极大的提高。

4 基于 BP, LSTM, CNN-LSTM-Attention 3 种模型反演预测参数精度分析

4.1 不同模型预测结果对比分析

以 144 组模拟钢板桩水平位移数据为基础,与当前岩土工程中运用较广泛的 BP 模型以及 LSTM 模型分别进行对比,将 CNN-LSTM-Attention 模型与这两种目前最为常用的模型使用同样的数据集进行训练预测,并分别对第 3 层③粉质黏土、粉土、粉砂互层与第 4 层④粉砂进行反演分析与前文思路相同,3 种模型预测结果如图 12 所示。




图 12 钢板桩水平位移预测值对比

Fig. 12 Comparison of predicted horizontal displacement of steel plate pile

由图 12 可知,3 种模型反演出的参数代入模型得到的预测结果均能得到钢板桩水平位移的变化趋势,但对于单一的神经网络 LSTM 以及基于遗传算法的 BP 神经网络,反演出的参数所进行模拟得到的钢板桩水平位移值均与实测值差距较大,明显偏离实测值,这可能是由于钢板桩在水平位移的过程中存在一个较为复杂的非线性关系,LSTM 模型与 BP 神经网络虽然具备处理非线性问题的能力,但在训练集数据不够庞大时这两种模型仍可能无法准确地捕捉到复杂的非线性关系,因此对于混合神经网络模型 CNN-LSTM-Attention 其效果以及预测精度均好于单一的神经网络模型,这可能是由于 CNN-LSTM-Attention 首先通过 CNN 层提取序列的空间特征,接着通过 LSTM 层捕捉时间依赖性,最后通过 Attention 层增强对序列中重要时间步的关注。多层次特征捕捉该模型综合了 CNN 的空间特征提取能力、LSTM 的时间依赖建模能力以及 Attention 的全局相关性捕捉能力,能够更准确地处理复杂的序列数据。

4.2 不同模型预测精度及优化效果分析

为更加准确检验模型的预测精度,通过平均误

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,具体计算公式分别为:

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

(3)

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

(4)

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

(5)

式中: N 为样本个数; $\hat{y}_i$ 为输出预测值; y_i 为真实值。3 种预测模型的性能评估结果如图 13 所示,包括平均绝对误差(MAE)、平均相对误差(MAPE)和均方根误差(RMSE)的对比分析。从图 13 可以看出,3 种模型的 MAE 值均低于 0.1,表明其预测偏差较小;RMSE 值均在 0.1 附近,说明模型具有较高的拟合精度。就 MAPE 而言,CNN-LSTM-Attention 模型表现最优,其次是 BP 模型,LSTM 模型相对较差,这验证了 CNN-LSTM-Attention 模型在预测准确性方面的优势。




图 13 竖向水平位移预测精度对比

Fig. 13 Comparison of prediction accuracy of vertical horizontal displacement

表 4 进一步对比了单一时序神经网络模型与混合时序神经网络模型的预测性能。数据分析表明,引入注意力机制的卷积-长短期记忆神经网络(CNN-LSTM-Attention)相较于 LSTM 和 BP 模型具有显著的优化效果。具体而言,CNN-LSTM-Attention 模型的 MAE,MAPE 和 RMSE 分别比 LSTM 模型降低了 51.1%,55.4%和 13.3%,相较于 BP 模型则分别减少了 35.8%,52.9%和 7.5%。这一结果充分证明了混合模型在提升预测精度方面的有效性。

5 结语

本文以知音路沟槽基坑为分析案例,基于 CNN-LSTM-Attention 人工神经网络算法,结合有限元数值模拟对基于数值模拟进行的钢板桩水位移模拟,

表 4 预测模型评价指标
Table 4 Evaluation index of prediction model

评判指标	CNN-LSTM-Attention	LSTM	优化效果/%	BP	优化效果/%
MAE	0.061 2	0.125 3	51. 1	0.095	35. 8
MAPE	0.497 0	1.115 6	55. 4	1.056	52. 9
RMSE	0.109 9	0.126 8	13. 3	0.118	7. 5

最后结合实测监测数据,利用 CNN-LSTM-Attention 算法进行参数反演修正并展示了 CNN-LSTM-Attention 算法在基坑参数反演中相较于 BP 模型和单一 LSTM 模型的精度优势。主要研究成果如下。

1)本文分析了结合 CNN-LSTM-Attention 神经网络与小应变土体硬化模型的有限元位移反分析预测方法在基坑钢板桩水平位移预测中的表现,利用 CNN-LSTM-Attention 算法对小应变土体硬化模型的模量参数进行反演分析,并且根据钢板桩最大位移所位于的土层从而选择③粉质黏土、粉土、粉砂互层与④粉砂,结果表明通过 CNN-LSTM-Attention 模型训练后得到 2 层土分别的修正系数分别为 0.694,1.14。

2)本文采用 CNNb-LSTM-Attention 算法反演小应变土体硬化模型模量参数 $E_{50}^{ref}, E_{oed}^{ref}, E_{ur}^{ref}, G_0^{ref}$,乘以修正系数后的有限元模型能够较为准确的反应钢板桩水平位移模式。通过 CNN-LSTM-Attention 算法修正过后的有限元模型相较于未修正的模型其对比实测数据优化效果提高了 31.2%。

3)并且通过几种岩土工程中常用模型对比,与 BP 模型和 LSTM 模型相比,CNN-LSTM-Attention 模型展现出显著的优化效果。在平均绝对误差(MAE)、平均相对误差(MAPE)和均方根误差(RMSE)方面,CNN-LSTM-Attention 模型相较于 LSTM 模型分别减少了 51.1%,55.4%和 13.3%,相较于 BP 模型则分别降低了 35.8%,52.9%和 7.5%。

参考文献:

[1] CAO M M, ZHANG Z, DU Z B, et al. Experimental study of hardening small strain model parameters for strata typical of Zhengzhou and their application in foundation pit engineering [J]. Buildings, 2023, 13(11) : 2784.

[2] 管飞. 基于 HSS 本构模型的软土超大型深基坑 3D 数值分析 [J]. 岩土工程学报, 2010, 32(S1) : 177-180.

GUAN F. 3D numerical analysis for a ultra-large deep excavation in soft clay based on HSS constitutive model[J]. Chinese journal of geotechnical engineering, 2010, 32(S1) : 177-180.

[3] 邵羽,江杰,陈俊羽,等. 基于 HSS 模型与 MCC 模型的深基坑降水开挖变形分析[J]. 水利学报, 2015, 46(S1) : 231-235.

SHAO Y, JIANG J, CHEN J Y, et al. Deformation of deep

- foundation pits due to excavation and dewatering based on HSS model and Modified Cam-Clay model[J]. Journal of hydraulic engineering, 2015, 46(S1): 231-235.
- [4] 吴瑞拓, 顾晓强, 高广运, 等. 基于 HSS 模型的上海地铁深基坑开挖变形分析[J]. 建筑科学与工程学报, 2021, 38(6): 64-70.
- WU R T, GU X Q, GAO G Y, et al. Analysis of deep excavation deformation of Shanghai metro station using HSS model[J]. Journal of architecture and civil engineering, 2021, 38(6): 64-70.
- [5] 董鑫, 周峰, 王旭东, 等. 基坑数值分析中 HSS 模型参数试验及应用[J]. 科学技术与工程, 2023, 23(18): 7878-7885.
- DONG X, ZHOU F, WANG X D, et al. Experimental and application of HSS model parameters in foundation pit numerical analysis[J]. Science technology and engineering, 2023, 23(18): 7878-7885.
- [6] 陈军, 孙枫, 庄兴岳, 等. 基于 HSS 模型的台州软土地区基坑开挖位移分析[J]. 岩土工程学报, 2025, 47(S1): 212-217.
- CHEN J, SUN F, ZHUANG X Y, et al. Displacements of an excavation in soft soil area of Taizhou based on HSS model[J]. Chinese journal of geotechnical engineering, 2025, 47(S1): 212-217.
- [7] FU Y B, HE S Y, ZHANG S Z, et al. Parameter analysis on hardening soil model of soft soil for foundation pits based on shear rates in Shenzhen Bay, China[J]. Advances in materials science and engineering, 2020(1): 7810918.
- [8] 周意, 王章琼, 邹原耕, 等. 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[J]. 城市轨道交通研究, 2025, 28(6): 32-36, 53.
- ZHOU Y, WANG Z Q, ZOU Y G, et al. Metro foundation pit deformation prediction method based on CNN-GRU neural network under incomplete data condition[J]. Urban mass transit, 2025, 28(6): 32-36, 53.
- [9] WEI X, CHENG S T, CHEN R, et al. ANN deformation prediction model for deep foundation pit with considering the influence of rainfall[J]. Scientific reports, 2023, 13: 22664.
- [10] 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(S2): 108-111.
- HONG Y C, QIAN J G, YE Y X, 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): 108-111.
- [11] LI H L, ZHAO Z Z, DU X. Research and application of deformation prediction model for deep foundation pit based on LSTM[J]. Wireless communications and mobile computing, 2022, 2022(1): 9407999.
- [12] 张明聚, 秦胜旺, 李鹏飞, 等. 基于融合注意力机制 BP 神经网络的深基坑变形预测方法[J]. 北京交通大学学报, 2025, 49(2): 95-104.
- ZHANG M J, QIN S W, LI P F, et al. Deep excavation deformation prediction method based on BP Neural Network with integrated attention mechanism[J]. Journal of Beijing Jiaotong University, 2025, 49(2): 95-104.
- [13] CHEN W H, YUAN S, HE L, et al. A spatiotemporal correlation and attention-based model for pipeline deformation prediction in foundation pit engineering[J]. Scientific reports, 2024, 14: 26387.
- [14] 孟飞, 郑卓然, 黄文聪, 等. 基于 CNN-BiLSTM-Attention 的深基坑变形预测方法[J]. 地下空间与工程学报, 2025, 21(S1): 87-94.
- MENG F, ZHENG Z R, HUANG W C, et al. Prediction method of pit deformation based on CNN-BiLSTM-attention[J]. Chinese journal of underground space and engineering, 2025, 21(S1): 87-94.
- [15] YIN S B, CHANG C L, ZHANG M W, et al. Beyond static fingerprints to dynamic evolution: a CNN-LSTM-attention model for identifying coal mine water inrush sources in northern China[J]. Processes, 2025, 13(12): 3906.
- [16] ZHAO J, LI W J, PENG Y L. Analysis on intelligent deformation prediction of deep foundation pits with internal support based on optical fiber monitoring and the HSS model[J]. Frontiers in materials, 2023, 10: 1231303.