

DOI: 10.7672/sgjs2025170062

基于长短时记忆网络的深基坑支护桩水平位移预测*

陈祺荣¹, 杨春^{2,3}, 朱东烽¹, 左志亮^{2,3}, 陈钰杭²

(1. 广东筠诚建筑科技有限公司, 广东 云浮 527400; 2. 华南理工大学土木与交通学院, 广东 广州 510641;
3. 广东省普通高校工程抗震研究中心, 广东 广州 510641)

[摘要] 随着对地下空间使用需求的增大以及地下空间结构技术发展, 在施工阶段对基坑围护结构进行安全性监测和预警愈加重要。为高效预测基坑支护桩水平位移, 基于某工程自动化监测数据, 采用多输入多输出的长短时记忆(LSTM)网络建立基坑支护桩水平位移预测模型, 并与随机森林模型和多维灰色预测模型预测结果进行对比。该模型综合考虑测点水平位移、相邻测点支撑轴力和地下水位等多模态数据, 实现对支护桩水平位移的多测点同时预测。研究表明, 考虑多因素的多输入多输出 LSTM 模型具有较高的预测精度, 能够更好地适应复杂的时间序列模式和非线性关系, 其预测结果的均方根误差比仅考虑测点水平位移的单输入单输出 LSTM 模型降低 52.5%, 比随机森林模型和多维灰色预测模型分别降低 62.3%, 59.0%。

[关键词] 基坑; 健康监测; 长短时记忆网络; 数据; 位移

[中图分类号] TU753

[文献标识码] A

[文章编号] 2097-0897(2025)17-0062-07

Prediction of Horizontal Displacement for Retaining Piles in Deep Foundation Excavation Based on LSTM Network

CHEN Qirong¹, YANG Chun^{2,3}, ZHU Dongfeng¹, ZUO Zhiliang^{2,3}, CHEN Yuhang²

(1. Guangdong Juncheng Real Estate Co., Ltd., Yunfu, Guangdong 527400, China; 2. School of Civil Engineering & Transportation, South China University of Technology, Guangzhou, Guangdong 510641, China;
3. Engineering Seismic Research Center of Guangdong, Guangzhou, Guangdong 510641, China)

Abstract: With the increasing demand for the use of underground space and development of underground space structure technology, the safety monitoring and early warning of foundation excavation retaining structure in the construction stage is becoming more and more important. To investigate an effective prediction method for the horizontal displacement of foundation excavation retaining piles, based on the automatic monitoring data for a project, a LSTM network with multi-input and multi-output data is proposed to establish the horizontal displacement prediction model of the foundation excavation retaining piles, and the prediction results were compared with those generated by the random forest model and the multi-variable grey prediction model. The model not only can consider the horizontal displacement of the measuring points, but also comprehensively can consider multi-modal data, such as the supporting axial force of adjacent measuring points and the groundwater level. The results show that, by considering the multi-factor data, the multi-input and multi-output LSTM model exhibits higher prediction accuracy and can better adapt to the complex time series patterns and nonlinear relationship, the root mean square error of the prediction results is 52.5%, less than that generated by the single-input and single-output LSTM model, considering only the horizontal displacement of measuring points, and it is 62.3% and 59.0% less than that generated by the random forest model and the multi-variable grey prediction model, respectively.

Keywords: foundation excavation; health monitoring; long short-term memory (LSTM) network; data; displacement

* 云浮市科技计划(2022010406)

[作者简介] 陈祺荣, 高级工程师, E-mail: 670587350@qq.com

[通信作者] 左志亮, 博士, 副教授, E-mail: ctzlzuo@scut.edu.cn

[收稿日期] 2025-03-11

0 引言

随着对地下空间使用需求的增大以及地下空间结构技术发展, 基坑向面积更大、更深的方向发

展,对基坑围护结构的安全性要求越来越高^[1]。围护结构被破坏前,往往在基坑侧壁不同部位出现较大的水平、竖向变形,或变形速率明显增大。因此,监测围护结构变形并进行预测尤为重要。

在基坑工程围护结构中,支护桩是重要的受力结构,实时监测桩体水平位移可及时了解其安全状态。自动化监测技术包括全站仪监测、北斗卫星定位监测、光纤传感监测、无人机安全监测等^[2],具有及时性、连续性、准确性、延展性等特点,提升测量精度与频率,实时监测数据,便于判断当前状况,对施工安全有重要意义。

预测桩体水平位移能够帮助施工人员预计桩体变化,从而提前准备预案。预测基坑变形的方法包括常规理论计算法、有限元模型数值模拟法和机器学习法。深度学习能够提取数据中更抽象的特征,对数据进行更本质的刻画^[3]。已有研究表明,依靠神经网络等智能模型,能够挖掘基坑变形数据变化的内在规律,定量研究导致基坑变形的各因素,从而建立合适的变形预测模型,反映基坑真实的变形情况,定量预测其变形趋势。王亮^[4]将神经网络用于地铁隧道变形预测,使用遗传算法优化 BP 神经网络,对以时间为自变量的 Logistic 模型进行参数优化求解,构建时间域的沉降预测模型,在地铁隧道变形预测中具有较高的精度和稳定性。薛艳杰^[5]将 GA 算法嵌入 PSO 算法进行参数优化,建立基于灰色最小二乘法支持向量机的时序变形预测模型,预测土岩复合地层中的地铁深基坑位移,进而验证变形预测模型的有效性、可行性。陈焕等^[6]采用灰色预测模型预测 2 道钢支撑架设的轴力短期数据,其结果具有较好的吻合性,并在此基础上使用置信区间估计法建立安全预警模型。王凯等^[7]通过时间序列模型(ARMA)较好拟合监测数据,并基于 ARMA 模型多重防线对地铁深基坑变形进行监测预警。虽然神经网络模型在变形预测中应用成功,但传统神经网络模型存在一定局限性,如 BP 神经网络模型和支持向量机无法充分利用历史数据^[8],对高度非线性和时间相关性的数据适用性较差。基坑监测数据具有较强的非线性特征和时间序列规律,长短时记忆(LSTM)神经网络对非线性数据和时序序列具有优势,故使用该模型进行预测。夏天等^[1]利用 LSTM 的自学习和时序数据处理能力,建立深基坑变形安全风险预警模型,以预测基坑支护结构、周边道路、地下管线等结构体的变形,拟合速度较快、精度较高。张生杰等^[9]利用 LSTM 算法预测地下连续墙的水平变形,比 BP 预测

模型和灰色预测模型预测结果准确性更高。王永军^[10]研究深基坑开挖时,预测地表沉降的方法,赵华菁^[11]对深基坑地下连续墙变形进行动态预测,均对 LSTM 和 BP 神经网络进行对比,结果表明 LSTM 具有更高的预测精度。当使用 LSTM 预测基坑变形时,大多只将某测点的历史数据作为特征进行时序预测,属于单输入单输出的 LSTM 模型,考虑因素较单一。然而,基坑支护桩结构的水平位移受多种参数影响,如支撑刚度、地下水位等,因此有必要挖掘各类相关监测数据的关联性。

为高效预测基坑支护桩结构水平位移,以某基坑支护工程为例,利用自动化监测技术获取位移数据,如通过阵列式位移计获取支护桩水平位移、地下水位及支撑轴力等数据,通过 MATLAB 软件建立考虑多因素输入和多结果输出的长短时记忆(LSTM)网络模型,预测基坑支护桩水平位移,且与随机森林模型和灰色模型预测结果进行对比。

1 预测模型

LSTM(long short-term memory)神经网络是常用的门控循环神经网络,是循环神经网络(recurrent neural network, RNN)的一种,相比其他神经网络模型,RNN 结合输入和输出,更符合人脑思维模式。在反向传播算法过程中,如果网络层数过多,当梯度反向传播时进行连乘,会使网络权重更新不稳定,导致梯度消失或梯度爆炸。因此,RNN 对于长期记忆处理效果不佳。LSTM 解决 RNN 的部分缺点,具有独特的记忆细胞结构,通过更新记忆状态维持对信息的长期跟踪,改善梯度爆炸和梯度消失的问题^[12]。LSTM 网络中的每个记忆细胞均受输入门、遗忘门和输出门的门控机制调控,这些门控机制实质是一系列的加权函数,负责调控信息流动,从而实现对重要信息的长期保持和对无关信息的遗忘。LSTM 单元工作过程包括遗忘操作、输入操作、细胞状态更新和输出操作,其结构如图 1 所示^[12],图中 x_t 表示第 t 个时间步的输入; h_t 表示第 t 个时间步的隐藏状态,作为本时间步的输出传到下层; c_t 表示第 t 个时间步的细胞状态,保证传递到下一时间步保持信息准确; σ 表示激活函数 sigmoid; \tanh 表示双曲正切激活函数,用于门控机制。遗忘门通过 sigmoid 函数计算每个记忆细胞单元的遗忘率,决定上一时间步状态中信息的遗忘量。输入门结合 sigmoid 和 \tanh 函数,评估更新需求,并融合上次输出与本次输入,生成新的候选记忆细胞状态和对应存储率。基于遗忘率和输入门确定候选记忆状态及对应存储率更新记忆细胞状态。输出门使

用 sigmoid 函数确定输出率,影响网络输出,其中通过更新得到的记忆细胞状态经过 \tanh 函数进行非线性变换后,乘以输出率得到最终输出。深基坑结构从开始施工到变形,具有明显的非线性特点,监测噪声较多。与 ARIMA 时间序列模型相比,LSTM 能够更好地处理非线性数据,适用于桩身水平位移预测中。




图1 LSTM网络结构

Fig.1 LSTM network structure

深基坑围护结构的支护桩水平位移影响因素众多,不同因素间错综复杂,属于灰色系统,适合使用灰色模型进行预测。灰色系统理论所需因素少、模型简单,适用于因素空间难以穷尽、运行机制尚不明确、又缺乏确定关系的信息系统。灰色模型一般用 $GM(x, n)$ 表示, x 表示微分方程阶数, n 表示变量数。常用模型 $GM(1, 1)$ 预测模型是灰色预测核心,但其响应函数近似于指数规律,考虑因素少,与支护桩的变形规律有较大差异,而多维灰色预测模型 $GM(1, n)$ 适用于预测桩身水平位移。

随机森林算法既可用于分类也可用于回归预测,其基本思想是首先对样本数据进行自助抽样,得到多个训练集,然后为每个训练集建立分类模型,最后组合每个分类模型预测结果共同投票决定最优解^[13]。随机森林算法能够分析各因素的重要性,通过大量决策树避免过拟合,因为其对特征子集选择随机,所以可以处理高维度数据,不需进行特征选择,具有实现简单、预测精度高、泛化能力强等优点。

2 工程概况

新兴县妇幼保健院扩建项目基坑支护工程位于广东省云浮市新兴县,总用地面积约 15 265m²。场内共 6 个单体建筑,总建筑面积约 42 213m²,其中地下室总面积约 8 968m²。本基坑深 5.05~5.95m,局部最大挖深(坑中坑) 6.45m。基坑面积约 9 765m²,周长 418m。

基坑北侧有妇幼保健院大楼和游乐场,距离支

护内边线最短距离约 6.7m。基坑南侧红线紧贴多栋居民楼,距支护内边线最短距离约 5m。基坑西南侧红线紧贴多栋居民楼,距支护内边线最短距离约 4m。根据 DBJ/T 15—20—2016《建筑基坑工程技术规程》可知,基坑北侧、南侧、西南侧环境等级为一级。其余方向,即基坑东北侧、东南侧、西侧环境等级为二级。地下混合稳定水位埋深为 1.10~2.10m,相应标高为 26.230~27.360m,其稳定水位随地形及季节性气候影响而波动,一般年变化幅度为 1.00~3.00m。

根据设计图纸、规范要求,以及基坑工程常见问题,确定如下监测项目:①在基坑支护内埋设阵列式位移计,共设置 12 个监测点,即 X1~X12(见图 2),监测精度为 $\pm 1.6\text{mm}@32\text{m}$,以判断支护桩的倾斜情况;②在混凝土支撑内埋设钢筋计,共设 16 个监测点(ZL1~ZL16),监测精度 $\leq 0.5\%$,用于判断支撑轴力变化情况;③在基坑周边埋设水位计,共设 9 个监测点(W1~W9),监测精度为 10mm,实施 24h 自动在线监测,一般情况下每 1h 采集 1 次数据,紧急情况下调整为 5min 采集 1 次,并将所有数据做报警分析,如有不正常数据应立即发送报警通知。




图2 测点布置

Fig.2 Layout of monitoring points

3 LSTM 预测过程

3.1 数据选取

从该基坑工程的支护结构测斜数据中提取水平位移值,采用 LSTM 模型预测水平位移。考虑到一定范围内支护桩间的变形具有关联性,故选择目

标监测点和相邻监测点的前 1 期数据作为特征输入数据,将目标监测点的下期数据作为输出数据,通过多监测点数据综合预测支护桩水平位移。以场地中的关键监测点为例,介绍水平位移预测方法。

1) 基坑北侧现有妇幼保健院大楼和游乐场距支护内边线最短距离约 6.7m。其中,基坑北侧 X2 监测点靠近原妇幼保健院大楼,且位于北侧红线中间部分,此处变形可能对原有结构和管线产生较大影响,故选取支护结构测斜点 X2 为目标监测点。

2) X1 位于基坑北侧,靠近原妇幼保健院大楼,与 X2 监测值有一定关联。水位监测点 W1 位于测点 X1, X2 间,靠近 X1,地下水位对桩的水平位移有一定影响,与 X2 的监测值有一定关联。ZL5, ZL6 位于 X2 附近,由于支撑轴力与支护桩水平位移相关,因此也选为辅助监测点。故选择 X1, W1, ZL5, ZL6 为辅助测点。

3) 支护结构测斜点 X1, X2, 在桩身不同深处各 12 个数据点,即 X1-1~X1-12 和 X2-1~X2-12。将各数据点的 x, y 坐标、 x, y 位移速率作为预测数据。将 W1 的探头水深、水面高程和水位变化速率作为预测数据,将 ZL5, ZL6 的累计轴力变化值作为预测数据。

3.2 数据处理及网络训练

从 2022 年 10 月 7 日 00:00 到 2023 年 2 月 14 日 00:00, 监测系统每小时输出 1 次监测数据,共 3 000 多期数据。由于各监测点的数据输出时间不完全同步,为保证每次输入数据集的数据间隔一致,对每个数据点的监测数据-时间集进行 3 次样条插样,每次插样间隔 12h,共 254 期预测数据,将前 214 期数据设定为训练集,将后 40 期数据设定为预测集。将训练集用作网络训练、预测集用于评判网络训练效果。然后,对数据进行归一化,将数据映

射到 0~1 内,为输至网络做准备。

通过 MATLAB 软件进行网络搭建,模型架构包括输入层、LSTM 层、ReLU 激活层、Dropout 层、全连接层、回归输出层。其中 LSTM 层由 128 个隐藏单元组成,在网络中引入 Dropout 正则化技术,Dropout 概率为 0.2。训练过程中,训练设置包括批大小 128 和最大迭代次数 1 200。使用 Adam 优化算法,将初始学习率设定为 0.001,学习率下降因子为 0.1,并在训练完成总周期的 80% 后动态调整学习率。整个预测流程如图 3 所示。

3.3 训练结果

由于同时预测 X2 的 12 个数据点结果较多,因此首先对其预测结果进行模糊聚类分析,筛选吻合程度不同的 2 个结果进行展示。以各数据点相关系数作为相似系数,建立模糊相似矩阵,并进一步构造模糊等价矩阵,再以 0.95 相似度作为界限,将测斜点 X2 的 12 个数据点分成 2 类。分类结果显示, {X2-1~X2-10, X2-12} 为一类, {X2-11} 为一类,将第 1 类的 X2-1 的预测结果进行展示。

X2-1 数据点水平位移的实际值、预测值对比如图 4 所示。X2-1 的 x, y 向水平位移均呈明显的非线性关系,且均在一定范围内波动,随着监测期数增加无明显递增或递减趋势。预测结果与监测数据曲线的变化趋势吻合良好,其中 x 向水平位移均方根误差为 0.61、均方误差为 0.38、平均绝对误差为 0.48、预测残差绝对值最大值为 1.45mm。 y 向水平位移均方根误差为 0.39、均方误差为 0.15、平均绝对误差为 0.32、预测残差绝对值最大值为 0.74mm。

X2-11 数据点水平位移的实际值、预测值对比如图 5 所示。 x, y 向的水平位移在一定范围内波动,波动幅度较 X2-1 小,但随着监测期数增加呈递

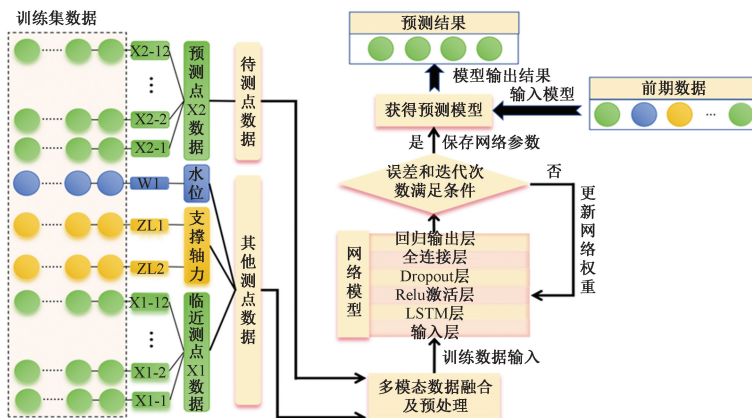


图 3 预测流程

Fig. 3 Prediction process




图 4 X2-1 水平位移结果对比

Fig. 4 Comparison of X2-1 horizontal displacement results

增趋势。预测结果与监测数据曲线变化趋势吻合良好,其中 X2-11 的 x 向水平位移均方根误差为 0.045、均方误差为 0.002 1、平均绝对误差为 0.034、预测残差绝对值最大值为 0.11mm。 y 向水平位移均方根误差为 0.062、均方误差为 0.003 8、平均绝对误差为 0.052、预测残差绝对值最大值为 0.13mm。

支护结构测斜点 X2 的 12 个数据点最后 40 期的实际位移和预测位移如图 6 所示,其中 12 个数据点从上到下按照实际顺序排布,且相邻点间隔 1m。12 个数据点向 x, y 正向移动,运动方向基本一致,数值不大,说明桩身无较大倾斜,移动过程中各数据点的数值稍有波动。上部数据点位移大、下部数据点位移小,与一般支护桩倾斜变形规律相符。预测水平位移与实际位移发展方向基本一致,总体误差不大。

4 与其他模型的对比

为进一步验证 LSTM 模型在深基坑支护桩水平位移预测中的效果,分析结合支撑轴力和地下水位数据作为多源输入特征的作用,选取 LSTM 模型预测精度相对较低的 X2-1 点 x 向位移,分别使用单输入单输出的 LSTM 模型,以及多维灰色预测模型 $GM(1, n)$ 和随机森林模型进行预测,并与多输入多输出的 LSTM 模型预测结果进行对比。




图 5 X2-11 水平位移结果对比

Fig. 5 Comparison of X2-11 horizontal displacement results




图 6 立体位移结果对比

Fig. 6 Comparison of stereo displacement results

4.1 单输入单输出的 LSTM 模型

在 MATLAB 软件中建立单输入单输出的 LSTM 模型进行预测,该模型批大小设置为 32,其他超参数设置与多输入多输出 LSTM 模型一致。采用与多输入多输出 LSTM 模型相同的数据集,但仅将前 1 期 X2-1 的 x 坐标作为特征输入,本期坐标作为特征输出,将前 214 期训练集、后 40 期预测值进行网络训练与预测。将模型预测值减去实际值得到残差,以均方根误差作为评价指标,与多输入多输出 LSTM 模型预测结果进行对比。残差变化如图 7 所示。箱体为上下 4 分位数包含范围,用于衡量数据集中程度。多输入多输出 LSTM 预测的残差值箱体高度更小,更加集中在 0 附近,误差更小。箱线图虚线根据 4 分位距 (IQR) 计算,长度值为 $1.5IQR$,用于衡量异常值,虚线

外为异常值。可见,多输入多输出 LSTM 模型异常值更少,预测更加稳定。考虑多因素的多输入多输出 LSTM 预测精度更高,其均方根误差(0.61)比只考虑单因素的单输入单输出 LSTM 预测结果均方根误差(0.93)降低 52.5%,说明在深基坑支护桩水平位移预测中,将与目标监测点相邻的测点数据也作为输入数据,可提高预测精度。

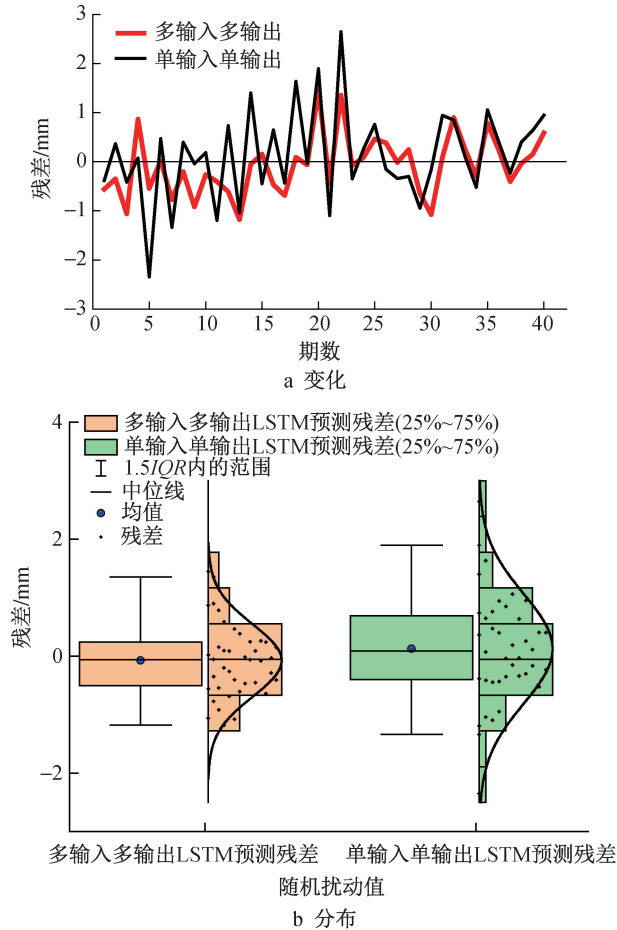


图 7 LSTM 模型预测残差对比

Fig. 7 Comparison of the predicted residuals for LSTM models

4.2 多维灰色预测模型和随机森林模型

在 MATLAB 中建立多维灰色预测模型 $GM(1, n)$ 和随机森林模型后进行预测,并与多输入多输出的 LSTM 模型预测结果进行对比,以评估预测任务中的性能差异。其中随机森林模型决策树数量为 1 000,以保证预测精度,每棵树的最小叶子节点数量为 10,以控制树的复杂度并防止过拟合。将 2 个模型得到的预测值分别减去实际值得到残差,以均方根误差作为评价指标,与多输入多输出 LSTM 模型的预测结果进行对比,如图 8 所示。3 个模型的预测结果残差随监测期数增加没有持续增加的趋势,说明 3 个模型预测结果变化趋势与实际监测结

果变化趋势相似。多输入多输出 LSTM 预测模型的残差值更加集中在 0 附近,箱线图箱体更扁,误差更小。相比随机森林的预测残差,均值更加接近于 0,预测精度更高。与 $GM(1, n)$ 和随机森林模型相比,多输入多输出的 LSTM 预测结果与实际值的误差(均方根误差为 0.61)在 3 种预测模型中表现最优越。 $GM(1, n)$ 与随机森林模型的均方根误差分别为 0.99, 0.97, 2 个模型误差相近。多输入多输出的 LSTM 模型预测精度更高,其均方根误差比 $GM(1, n)$ 和随机森林模型预测结果分别降低 62.3%, 59.0%。

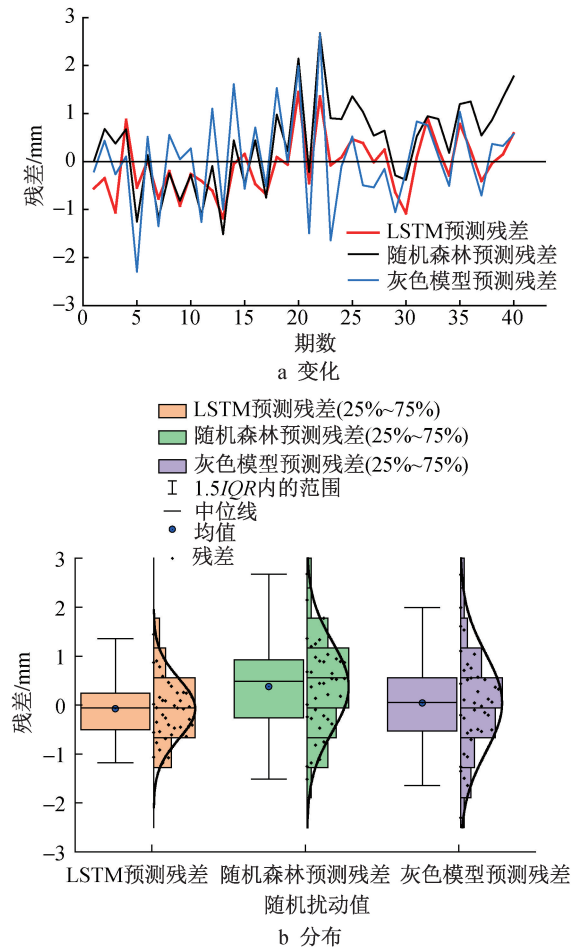


图 8 LSTM 模型与其他模型残差对比

Fig. 8 Residuals comparison between the LSTM model and other models

对比结果表明,在深基坑支护桩水平位移预测中,多输入多输出 LSTM 模型的准确性和可靠性高于 $GM(1, n)$ 和随机森林模型。且与 $GM(1, n)$ 相比,多输入多输出 LSTM 模型能够同时对支护桩阵列式位移计测斜点不同深处的 12 个数据点进行预测,可据此预测桩的变形和倾斜,预测效率更高。

相比 $GM(1, n)$ 模型, LSTM 模型可更好地适应复杂的时间序列模式和非线性关系,因此在深基坑

支护桩水平位移预测中具有更高的预测精度。LSTM 模型能够有效处理长期依赖关系,对于具有较长时间跨度的数据或复杂动态模式的数据,其表现往往优于传统 GM(1, n) 模型。相比随机森林模型,LSTM 模型在处理时间序列数据时可更好地捕捉时间相关性和序列模式,特别是在需要考虑先前输入对后续输出影响时,使 LSTM 模型在深基坑支护桩水平位移预测中表现更优。

5 结语

1) 影响围护结构支护桩水平位移的因素多,位移变化呈非线性关系,深度越浅监测数据波动越大,应采用考虑多因素、可高效处理非线性数据的模型进行预测。多输入多输出 LSTM 模型能够同时对支护桩阵列式位移计测斜点不同深度的多数据点进行预测,并据此预测桩的变形和倾斜,预测效率及精度高。

2) 与仅考虑测点水平位移变化的单输入单输出 LSTM 模型相比,同时考虑测点水平位移、相邻目标测点的支撑轴力和地下水位测点数据的多输入多输出 LSTM 模型具有更高的预测精度,均方根误差降低 52.5%。

3) 相比灰色模型和随机森林模型,多输入多输出 LSTM 模型可更好地适应复杂的时间序列模式和非线性关系,更好捕捉时间相关性和序列中的模式,对具有较长时间跨度的数据或复杂动态模式的深基坑支护桩水平位移预测表现更优越,均方根误差分别降低 62.3%,59.0%。

参考文献:

- [1] 夏天,成诚,庞奇志.基于长短时记忆网络的深基坑变形安全风险预警[J].地球科学,2023,48(10):3925-3931.
XIA T, CHENG C, PANG Q Z. Safety risk warning of deep foundation excavation deformation based on LSTM [J]. Earth science, 2023, 48(10): 3925-3931.
- [2] 王磊.自动化监测技术在深基坑监测中的应用[J].工程技术研究,2022,7(24):190-192.
WANG L. Application of automatic monitoring technology in deep foundation excavation monitoring [J]. Engineering and technological research, 2022, 7(24): 190-192.
- [3] 孙志远,鲁成祥,史忠植,等.深度学习研究与进展[J].计算机科学,2016,43(2):1-8.
SUN Z Y, LU C X, SHI Z Z, et al. Research and progress on deep learning[J]. Computer science, 2016, 43(2): 1-8.
- [4] 王亮.遗传算法优化神经网络在地铁隧道变形中的应用[J].智能城市,2023,9(1):5-7.
WANG L. Application of neural network optimized by genetic algorithm in subway tunnel deformation [J]. Intelligent city, 2023, 9(1): 5-7.
- [5] 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(S2):77-85.
XUE Y J. Time series prediction of deep foundation excavation deformation in soil-rock composite stratum based on machine learning algorithm [J]. Modern tunnelling technology, 2022, 59(S2): 77-85.
- [6] 陈焕,张可,蒋一波,等.地铁车站深基坑钢支撑体系轴力预测及安全预警模型研究[J].防灾减灾工程学报,2023,43(3):576-587.
CHEN H, ZHANG K, JIANG Y B, et al. Research on axial force prediction and safety warning model of steel bracing system in deep foundation excavation for subway station [J]. Journal of disaster prevention and mitigation engineering, 2023, 43(3): 576-587.
- [7] 王凯,胡怡婧,徐青.基于时间序列 ARMA 模式识别的基坑监测预警优化研究[J].工业安全与环保,2018,44(7):29-32.
WANG K, HU Y J, XU Q. Research on supervision of monitoring and warning of foundation excavation based on time series ARMA model identification [J]. Industrial safety and environmental protection, 2018, 44(7): 29-32.
- [8] XU S L, NIU R Q. Displacement prediction of Baijiabao landslide based on empirical mode decomposition and long short-term memory neural network in Three Gorges area, China [J]. Computers & geosciences, 2018, 111: 87.
- [9] 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 S J, TAN Y. Deformation prediction of foundation excavation based on long short-term memory algorithm [J]. Tunnel construction, 2022, 42(1): 113-120.
- [10] 王永军.基于 LSTM 的深基坑开挖地表沉降预测研究[J].山西建筑,2021,47(14):74-75,140.
WANG Y J. Study on prediction model of ground subsidence in deep foundation excavation based on LSTM [J]. Shanxi architecture, 2021, 47(14): 74-75, 140.
- [11] 赵华菁,张名扬,刘维,等.基于神经网络算法的深基坑地下连续墙变形动态预测[J].地下空间与工程学报,2021,17(S1):321-327.
ZHAO H J, ZHANG M Y, LIU W, et al. Dynamic prediction of diaphragm wall deflection caused by deep excavation using neural network algorithm. [J]. Chinese journal of underground space and engineering, 2021, 17(S1): 321-327.
- [12] 程秋实.深圳市某深基坑施工变形监测与预测研究[D].长春:吉林大学,2022.
CHENG Q S. Research on monitoring and prediction of a deep foundation excavation construction deformation in Shenzhen [D]. Changchun: Jilin University, 2022.
- [13] 张延庆.深圳宏电大厦基坑工程开挖变形规律及预测研究[D].长春:吉林大学,2022.
ZHANG Y Q. Study on excavation deformation law and prediction of Hongdian Building foundation excavation engineering of Shenzhen [D]. Changchun: Jilin University, 2022.