

# 基于优化长短时记忆网络的深基坑变形预测方法及其工程应用

祝明<sup>1</sup>,石承龙<sup>1</sup>,吕潘<sup>1</sup>,刘现荣<sup>1</sup>,孙驰<sup>1</sup>,陈建城<sup>1</sup>,范宏运<sup>2\*</sup>

(1.中建科工集团有限公司,广东 深圳 518054; 2.山东大学齐鲁交通学院,山东 济南 250002)

**摘要:**为更精准地预测基坑开挖诱发的支护结构变形,构建一种紧邻隧道深基坑变形预测模型,采用灰狼优化算法(grey wolf optimizer, GWO)自动优化长短时记忆网络模型(long short-term memory, LSTM)中的超参数,提升了原始LSTM模型预测结果的准确性。以南京市区内某紧邻隧道的深基坑项目为工程背景,对比分析BP神经网络、原始LSTM和GWO-LSTM模型的基坑变形预测结果,3种模型的决定系数( $R^2$ )分别为0.992、0.967和0.999,说明了GWO-LSTM模型在预测深基坑变形方面的优势和准确性。最后,采用GWO-LSTM模型对 $D_{14}$ 监测点变形进行预测分析,预测结果与实测值基本一致,研究结果可为紧邻隧道深基坑安全建设提供技术支持。

**关键词:**深基坑工程;变形预测;机器学习;神经网络;优化算法

**中图分类号:**TU 46+3 **文献标志码:**A

**引用格式:**祝明,石承龙,吕潘,等.基于优化长短时记忆网络的深基坑变形预测方法及其工程应用[J].山东大学学报(工学版),2025,55(3):141-148.

ZHU Ming, SHI Chenglong, LÜ Pan, et al. Deformation prediction method and engineering application of deep foundation pit based on optimized LSTM method[J]. Journal of Shandong University (Engineering Science), 2025, 55(3):141-148.

## Deformation prediction method and engineering application of deep foundation pit based on optimized LSTM method

ZHU Ming<sup>1</sup>, SHI Chenglong<sup>1</sup>, LÜ Pan<sup>1</sup>, LIU Xianrong<sup>1</sup>, SUN Chi<sup>1</sup>, CHEN Jiancheng<sup>1</sup>, FAN Hongyun<sup>2\*</sup>

(1. China Construction Science and Industry Co., Ltd., Shenzhen 518054, Guangdong, China; 2. School of Qilu Transportation, Shandong University, Jinan 250002, Shandong, China)

**Abstract:** To more accurately predict the deformation of support structures induced by excavation of foundation pits. The research constructed a deformation prediction model for deep foundation pits adjacent to tunnels. The grey wolf optimizer (GWO) algorithm was used to automatically optimize the hyperparameters in the long-short term memory network (LSTM), which improved the accuracy of the original LSTM model's prediction results. Taking a deep excavation project adjacent to a tunnel in the urban area of Nanjing as the engineering background, a comparative analysis was conducted on the prediction results of excavation deformation using BP neural network, original LSTM and GWO-LSTM models. The  $R^2$  of the three models were 0.992, 0.967, and 0.999, respectively, indicating the advantages and accuracy of the GWO-LSTM model in predicting deep excavation deformation. Finally, the GWO-LSTM model was used to predict and analyze the deformation of  $D_{14}$  monitoring point and the predicted results were basically consistent with the measured values. The research results could provide technical support for the safe construction of deep foundation pits adjacent to tunnels.

**Keywords:** deep foundation pit; deformation prediction; machine learning; neural network; optimization algorithm

## 0 引言

近年来,随着我国城市化建设的不断发展,以地下综合体、轨道交通等为代表的地下基础设施蓬勃发展,涌现出一批深/超深基坑项目,如国家大剧院基坑支护工程等<sup>[1-2]</sup>。然而,地下空间资源日益紧缺,深基坑工程建设过程中不可避免遇到地铁隧道等构筑物,进一步加剧了深基坑工程的地面沉降和侧向变形<sup>[3-4]</sup>,导致基坑垮塌、路面塌陷和基底隆起等重大地质灾害,造成严重的财产损失和人员伤亡<sup>[5-6]</sup>。因此,对紧邻隧道的深基坑变形进行准确预测对保障工程安全建设至关重要。

目前,国内外学者针对深基坑工程的变形预测主要以物理模型驱动的方法为主,如数值模拟、模型试验等,文献[7]基于 Winkler 弹性地基梁理论,建立深基坑支护结构水平位移的数值计算方法,并与现场实测值进行对比,验证了计算结果的准确;文献[8]开展紧邻滴血枢纽的深基坑变形特性离心模型试验,揭示了基坑开挖过程中地下连续墙的变形特征,确定了紧邻地铁枢纽的深基坑建设方案;文献[9]采用有限单元法模拟紧邻地铁隧道的深基坑开挖过程,研究了深基坑变形特征,为同类项目的结构设计提供了有益参考。上述研究方法简化了深基坑工程的地质环境、地层参数等因素,但面临计算效率低、时效性差等问题,难以直接应用于深基坑变形预测分析。

随着以云计算为代表的算力资源蓬勃发展,机器学习、深度学习等神经网络模型被广泛应用于基坑<sup>[10]</sup>、隧道<sup>[11]</sup>、边坡<sup>[12]</sup>等领域,文献[13]采用人工神经网络模型预测了深基坑支护结构的侧向位移,并采用现场实测结果验证了该模型的准确性;文献[14]优化了 BP 神经网络模型的初始权重和阈值,建立适用于深基坑地下连续墙支护结构水平位移的预测模型,并预测分析支护结构的水平位移,预测结果具有较高的准确性;文献[15]结合灰色理论和 BP 神经网络模型预测成都地铁站深基坑的周边地表沉降,预测结果可为基坑安全施工提供参考。然而,上述预测模型以 BP 神经网络、支持向量机等静态建模方法为主,难以准确预测高度非线性和时间相关性的基坑变形监测数据。

针对上述问题,文献[16]提出了长短时记忆网络模型(long short-term memory, LSTM),具有较好的记忆保留和筛选功能,在处理非线性数据和时间序列方面具有明显的优势,在基坑变形预测方面得到了

初步应用;文献[17]采用 LSTM 模型对某地铁基坑变形进行了预测分析,发现 LSTM 预测结果相比传统灰色预测模型更为准确;文献[18]提出一种基于经验模态分解的 EMD-LSTM (empirical mode decomposition-LSTM) 预测模型,并预测分析了深基坑变形,预测误差小于 0.4 m。然而,LSTM 网络模型的结构参数对预测结果影响较大,目前仅能依靠人为经验确定结构参数的数值,导致预测结果具有较强的主观性,与实际结果存在一定的偏差。

针对上述问题,本研究构建了一种紧邻隧道深基坑变形预测模型,采用灰狼算法(grey wolf optimizer, GWO)自动优化长短时记忆网络模型(LSTM)中的超参数,提升了原始 LSTM 模型预测结果的准确性。以南京市区内某紧邻隧道的深基坑项目为工程背景,对比分析 BP 神经网络、原始 LSTM 和 GWO-LSTM 模型的基坑变形预测结果,3 种模型的决定系数分别为 0.992、0.967 和 0.999,说明了 GWO-LSTM 模型在预测深基坑变形方面的优势和准确性。最后,采用 GWO-LSTM 模型对  $D_{14}$  监测点变形进行预测分析,预测结果与实测值基本一致,研究结果可为紧邻隧道深基坑安全建设提供技术支撑。

## 1 GWO-LSTM 预测模型

### 1.1 灰狼优化算法

灰狼优化算法(grey wolf optimizer, GWO)是由 Mirjalili 等通过观测灰狼的狩猎行为而提出的一种优化算法,其核心思想是模拟灰狼的社会关系和狩猎行为,通过不断调整参数,找到不同层次灰狼的最佳狩猎位置,具有参数少、泛化能力强等优势<sup>[19]</sup>。在实际应用过程中,狼群具有 4 个层次的社会关系,即第一层次为灰狼 a,负责带领狼群搜寻、追逐和压制猎物;第二层次为灰狼 b,负责协助灰狼 a 指挥狼群;第三层次为灰狼 c,服从灰狼 a 和灰狼 b 的管理,负责较低层次狼群的管理;第四个层次为灰狼 u,听从上级灰狼的指挥,其组织架构如图 1 所示<sup>[20]</sup>。




图 1 灰狼层次划分图

Fig.1 Schematic diagram of grey wolf algorithm

灰狼优化算法假设灰狼数量为  $l$ , 灰狼和猎物的距离为  $H$ , 灰狼追捕猎物的过程可以通过式(1)表示。

$$\begin{cases} H = |C \cdot X_R(k) - X_i(k)| \\ X_i(k+1) = X_R(k) - A \cdot H \end{cases} \quad (1)$$

式中,  $k$  为迭代次数,  $X_i(k)$  为迭代  $k$  次后灰狼  $i$  的位置,  $X_R(k)$  为迭代  $k$  次后猎物的位置,  $X_i(k+1)$  为灰狼再生的位置。  $A$  和  $C$  为稀疏向量, 计算公式为

$$\begin{cases} A = 2\alpha(r_1 - 1) \\ C = 2r_2 \end{cases} \quad (2)$$

式中:  $r_1$  和  $r_2$  为介于 0 和 1 的随机数;  $\alpha$  为收敛因子, 从 2 减小为 1。

在  $d$  维空间中, 灰狼 a 的位置为  $X_a(X_{a,1}, X_{a,2}, \dots, X_{a,d})$ , 灰狼 b 的位置为  $X_b(X_{b,1}, X_{b,2}, \dots, X_{b,d})$ , 灰狼 c 的位置为  $X_c(X_{c,1}, X_{c,2}, \dots, X_{c,d})$ 。在灰狼 a、b 和 c 的带领下, 狼群可以捕捉并包围猎物, 其他灰狼的位置变化可通过式(3)和式(4)计算求得<sup>[21]</sup>。

$$\begin{cases} H_a = |C_1 \cdot X_a(k) - X_i(k)| \\ H_b = |C_2 \cdot X_b(k) - X_i(k)| \\ H_c = |C_3 \cdot X_c(k) - X_i(k)| \end{cases} \quad (3)$$

$$\begin{cases} X_{i,a}(k+1) = X_a(k) - A_1 H_a \\ X_{i,b}(k+1) = X_b(k) - A_2 H_b \\ X_{i,c}(k+1) = X_c(k) - A_3 H_c \end{cases} \quad (4)$$

$$X_i(k+1) = \frac{X_{i,a} + X_{i,b} + X_{i,c}}{3} \quad (5)$$

式中,  $H_a$ 、 $H_b$ 、 $H_c$  分别为灰狼 a、b、c 和灰狼  $X_i(k)$  的距离,  $X_{i,a}(k+1)$ 、 $X_{i,b}(k+1)$ 、 $X_{i,c}(k+1)$  分别为灰狼  $i$  在灰狼 a、b、c 的带领下所更新的位置,  $X_i(k+1)$  为三者的矢量和。

### 1.2 长短时记忆网络

长短时记忆网络 (long short-term memory, LSTM) 是一种克服传统循环神经网络梯度消失难题的深度学习神经网络, 采用存储单元取代传统的隐藏单元, 并包含多个存储块, 每个存储块包括 3 个门: 输入门、遗忘门和输出门以及至少一个存储单元<sup>[16,22]</sup>。在计算过程中, LSTM 网络将 3 个门的输入信息添加/删除至存储单元中, 并基于 3 个门的状态提升或限制存储单元, 从而确定在训练过程中保持或遗忘的信息<sup>[23-24]</sup>, LSTM 架构图如图 2 所示。

对于 LSTM 网络的 3 个门, 输入门单元用于收集新信息, 输出门单元用于计算传播到网络的信息, 遗忘门单元用于决定单元的最终状态是否可以

被遗忘。3 个门和单元可以通过式(6)进行计算求解。

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ o_t = \sigma(W_o \odot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \cdot \tanh(c_t) \end{cases} \quad (6)$$

式中:  $f_t$ 、 $i_t$ 、 $o_t$  分别为遗忘门、输入门和输出门,  $\tilde{c}_t$  为潜在单元状态,  $c_t$  和  $h_t$  分别为时间  $t$  条件下的单元状态和单元输出信息,  $W_f$ 、 $W_i$ 、 $W_c$ 、 $W_o$ 、 $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$  分别为权重矩阵和相应的偏向量,  $x_t$  为时间  $t$  条件下的输入量,  $\sigma$  为 sigmoid 函数<sup>[25-26]</sup>。

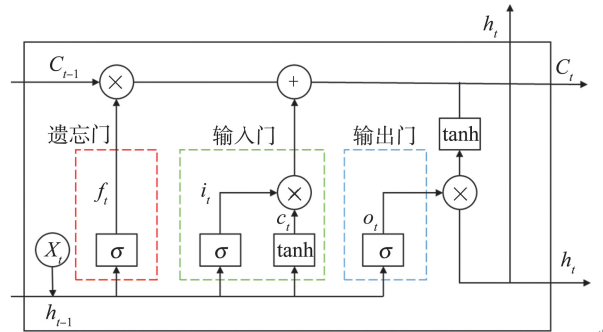


图2 LSTM 网络架构图

Fig.2 Network architecture diagram of LSTM

### 1.3 GWO-LSTM 预测模型

LSTM 网络在实际应用过程中, 其预测结果受网络超参数影响较大, 如初始学习率、隐藏层单元数目等, 目前针对超参数取值主要通过经验法确定, 存在主观性强、准确率差等问题。对此, 本研究构建了基于 GWO 和 LSTM 的预测模型, 采用 GWO 算法对 LSTM 网络模型中 3 个隐藏层神经元数量、损失率和 batch\_size 5 个超参数进行优化, 以此确定 LSTM 网络模型中的最优超参数取值组合, 进而提升预测模型的准确率, 主要步骤如下。

(1) 首先确认 LSTM 网络中超参数的取值范围, 并初始化灰狼种群, 确认灰狼个体的位置向量。

(2) 对于每个 LSTM 模型, 通过 GWO 算法搜索隐藏层神经元数量、Epoch 数目和学习率的最优参数, 并以均方根误差 (RMSE) 为指标控制优化迭代过程 (总迭代次数 tmax)。

(3) 根据式(6)对灰狼个体信息进行更新、迭代, 以此确定 LSTM 模型的最优超参数组合。

GWO-LSTM 模型的计算流程图如图 3 所示。

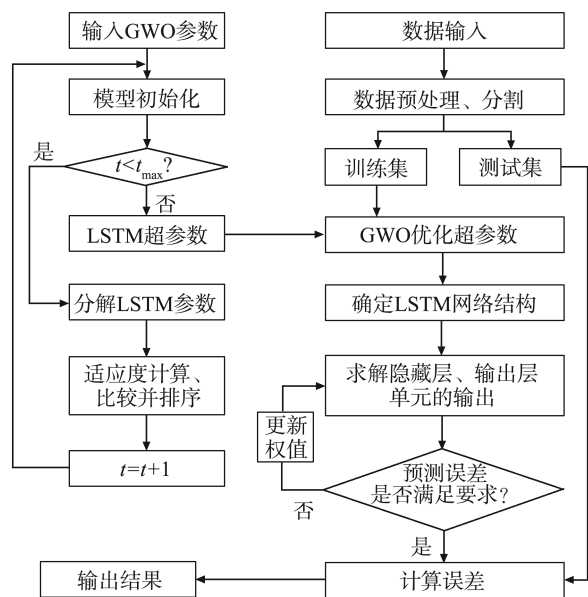


图 3 GWO-LSTM 预测模型  
Fig.3 GWO-LSTM prediction model

## 2 工程实例分析

### 2.1 工程概况

本研究依托工程为南京市区内某深基坑工程,该工程位于南京市雨花台区数字大道北侧,基坑开挖面积约 21 000 m<sup>2</sup>、总周长 630 m、挖深约 6~8 m,局部集水坑挖深约 11.15 m,为深基坑工程。基坑开挖深度范围内地层条件复杂,包括 8 个土层,土体压缩性强、稳定性差,基坑施工过程中极易诱发崩塌、滑坡等地质灾害,基坑位置及地层示意图如图 4 所示。

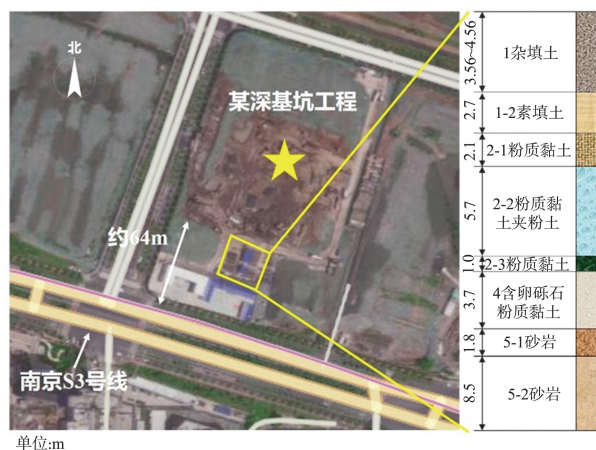


图 4 深基坑位置及地层示意图  
Fig.4 Schematic diagram of deep foundation pit

此外,该深基坑工程南侧紧邻南京轨道交通 S3 号线,地下室外墙距离轨道交通控制保护线(地铁 50 m 保护线)最近距离约 13.67 m,基坑建设过程中

不仅受到地铁振动等外部干扰,还需要考虑基坑施工对既有隧道的影响。对此,基坑建设过程中在基坑周围布设了 30 个位移监测点,主要用于监测坡顶竖向和水平位移等信息,如图 5 所示。




图 5 基坑监测方案  
Fig.5 Monitoring plan of foundation pit

### 2.2 预测模型参数设置与优化

本研究以基坑南侧紧邻南京 S3 号线区域为研究对象,分别采用 GWO-LSTM、LSTM 和 BP 神经网络预测分析了 D<sub>14</sub> 监测点处坡顶竖向位移的演化过程,主要包括以下步骤。

#### (1) 数据集构建

本研究选取了 D<sub>13</sub> 和 D<sub>14</sub> 监测点在 2022 年 9 月 8 日至 2023 年 1 月 19 日之间的坡顶竖向位移数据,总共 130 期,如图 6 所示。其中,在实际预测过程中,选取 80% 的数据为模型训练集(104 组),20% 的数据为模型测试集(26 组)。此外,D<sub>13</sub> 监测数据用于分析模型的可靠度,D<sub>14</sub> 监测数据用于验证模型的实用性。




图 6 现场监测数据  
Fig.6 Monitoring data in-site

#### (2) 模型参数设置

为增加模型预测结果的可信度,本研究采用原始 LSTM 和 BP 神经网络模型与 GWO-LSTM 模型进行横向对比。其中,GWO-LSTM 算法中优化的超参数包括 3 个隐藏层神经元数量、损失率和 batch\_size,对应的取值范围如表 1 所示。原始 LSTM 模型中设置 4 层网络,对应神经元数目分别为 50、

200、200和300。BP神经网络模型中隐藏层数为2,对应单元数分别为32和16。此外,3种模型的输入单元数、输出单元数和训练次数均保持一致,分别为1、1、200,输入参数为1~104 d的变形值,输出参数为105~130 d的变形值。

表1 GWO-LSTM算法参数

Table 1 Parameters in GWO-LSTM

神经元数	学习率	训练数	灰狼数	迭代数
1~300	0.000 2~0.990 0	2~256	30	60

(3) 模型评估指标

为量化预测结果和实测结果的差异性,本研究采用平均绝对误差(mean absolute error, MAE)、均方根差(root mean square error, RMSE)和决定系数( $R^2$ )作为预测结果的评估指标,其计算公式如式(7)~(9)所示。

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - Y'_i|, \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y'_i)^2}, \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - Y'_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2}, \quad (9)$$

式中,  $N$  为测试集数据数目,  $Y_i$  为模型预测值,  $Y'_i$  为现场实测值,  $\bar{Y}$  为现场实测数据平均值。

2.3 预测结果对比分析

采用BP神经网络、原始LSTM和GWO-LSTM模型的预测结果如图7所示。

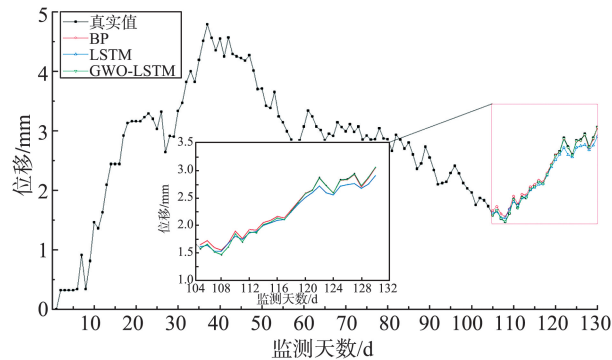



图7 3种模型预测结果

Fig.7 Prediction results of three models

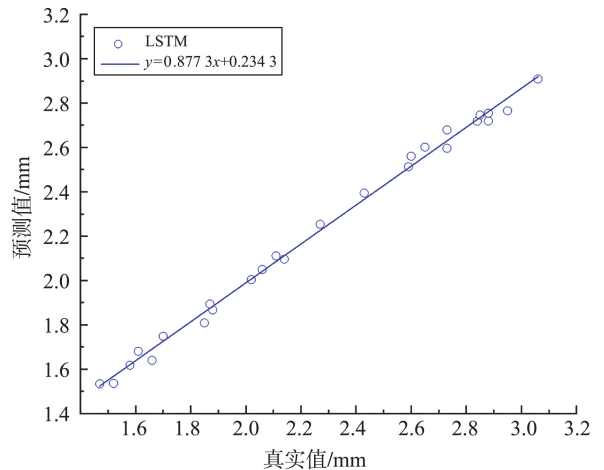
由图7可以看出,3种模型的预测结果与现场监测的实测值基本一致,特别是随着预测期数的增加,预测结果与实测值的拟合度逐步递增,两者仍存在一定的误差。

为进一步说明3种预测模型与实测值的差异性,本研究绘制了3种模型预测值与实测值的关系

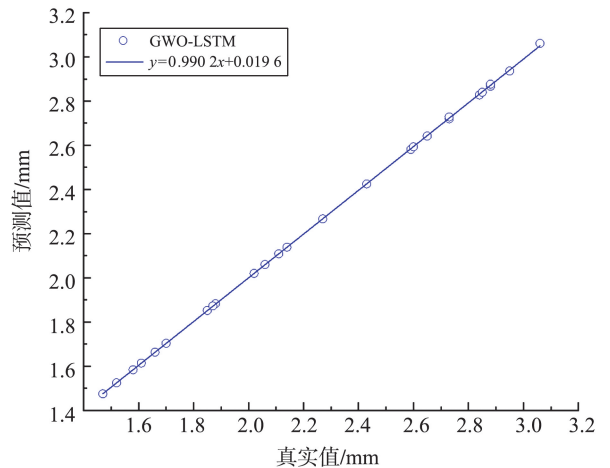
曲线,如图8所示。



(a) BP神经网络模型预测结果



(b) LSTM模型预测结果



(c) GWO-LSTM模型预测结果

图8 不同模型预测结果对比图

Fig.8 Comparison of different prediction models

由图8可以看出,BP神经网络、原始LSTM和GWO-LSTM模型预测结果的拟合曲线分别为  $y = 0.930 6x + 0.180 5$ 、 $y = 0.877 3x + 0.234 2$  和  $y = 0.990 2x + 0.019 6$ ,斜线的斜率均不为1,与实际均存在一定的差异性(斜率越接近1表示预测结果更加准确)。整体而言,3种模型预测结果的准确度为:

GWO-LSTM>BP>LSTM。通过分析可知,LSTM 模型对训练集数据数目要求更高,更适用于对时序、序列数据的处理和分析,预测结果相比 BP 神经网络模型较差。然而,通过引入 GWO 算法对 LSTM 模型中的超参数进行优化,提升了 LSTM 模型在处理小样本数据的能力,GWO-LSTM 模型预测结果较 BP 神经网络模型更好。

为量化 3 种模型预测结果与实测结果的误差,本研究绘制了 3 种模型预测结果的误差曲线,如图 9 所示。




图 9 3 种算法误差对比

Fig.9 Error between three algorithms

由图 9 可以看出,3 种模型预测结果的最大误差值约为 6.2%,最小误差值接近于 0。其中,BP 神经网络模型的误差值随着预测期数的增加而不断减小至稳定值,最后趋于 0.5%;LSTM 模型的误差演化过程整体处于振荡过程,平均误差值约为 3%左右;GWO-LSTM 模型的误差演化过程较为稳定,基本小于 0.5%。结合表 2 可以看出,3 种模型预测结果的决定系数分别为 0.992、0.967 和 0.999,相比于原始 LSTM 模型,GWO-LSTM 模型预测结果的准确度提升了约 3.31%,说明了 GWO 优化算法对提升 LSTM 模型预测结果可靠度的重要性。

表 2 3 种模型的性能指标

Table 2 Performance indicators of three models

预测模型	MAE/mm	RMSE/mm	R <sup>2</sup>
BP	0.034	0.055	0.992
LSTM	0.064	0.105	0.967
GWO-LSTM	0.005	0.008	0.999

通过上述分析可以看出,GWO-LSTM 模型预测结果与实测值基本一致,其预测结果较 BP 神经网络模型和原始 LSTM 模型更好,更加适用于紧邻隧道深基坑变形预测分析,预测结果可为基坑结构设计和安全建设提供技术保障。

### 3 预测模型应用验证

为说明 GWO-LSTM 模型的实用性,本研究选取紧邻隧道的基坑监测点 D<sub>14</sub>(与隧道安全险距离为 13.67 m)监测数据进行了验证分析,预测值和实测值的变化曲线如图 10 所示。

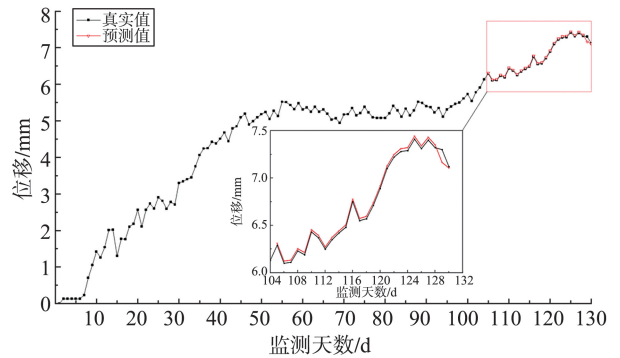


图 10 D<sub>14</sub>监测数据实测值和预测值

Fig.10 Monitoring values and prediction values at D<sub>14</sub>

由图 10 可以看出,GWO-LSTM 模型预测值与实测值基本一致,两者重合度较高。其中,128、129 和 130 期数据的预测值和实测值存在较大的差距,最大误差值约为 0.13 mm。

GWO-LSTM 模型预测结果如图 11 所示,由图 11 可以看出,GWO-LSTM 模型预测结果的拟合曲线为  $y=0.9867x+0.1096$ ,与实测值基本一致。通过计算可知,预测结果的平均绝对误差(MAE)、均方根差(RMSE)和决定系数(R<sup>2</sup>)分别为 0.030、0.047 和 0.993,均满足现场实际应用需求。由此可知,GWO-LSTM 模型具有极佳的稳定性,能够对紧邻隧道深基坑任意位置监测点的变形数据进行准确预测,为基坑结构设计与安全施工提供技术保障。

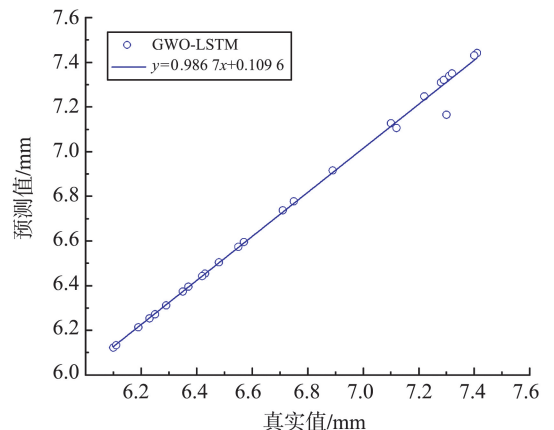


图 11 GWO-LSTM 预测结果

Fig.11 Prediction results of GWO-LSTM

## 4 结论

本研究针对紧邻隧道深基坑变形的精准预测难题,提出了一种融合 GWO 算法和 LSTM 算法的紧邻隧道深基坑变形预测模型,并成功应用于南京市区内某紧邻隧道的深基坑项目,验证了本研究所构建的 GWO-LSTM 模型的稳定性和可靠性,得到以下 3 个结论。

(1)本研究构建了基于 GWO-LSTM 的紧邻隧道深基坑变形预测模型,通过融合 GWO 算法,自动优化 LSTM 模型中的超参数,明确最优超参数组合值,进一步提升了 LSTM 模型预测结果的准确度。

(2)以南京市区内某紧邻隧道的深基坑项目为工程背景,基于紧邻隧道的  $D_{13}$  监测点现场实测数据,对比了 BP 神经网络、原始 LSTM 和 GWO-LSTM 模型的预测结果,3 种模型预测结果与实测结果的决定系数分别为 0.992、0.967 和 0.999,说明了 GWO-LSTM 模型在预测深基坑变形方面的优势和准确性。

(3)采用 GWO-LSTM 模型对该项目紧邻隧道的  $D_{14}$  监测点变形数据进行了预测分析,预测结果的平均绝对误差(MAE)、均方根差(RMSE)和决定系数( $R^2$ )分别为 0.030、0.047 和 0.993,均满足现场实际应用需求,说明了本研究所构建的 GWO-LSTM 模型的稳定性和可靠性。

### 参考文献:

- [1] 喻军, 龚晓南, 李元海. 基于海量数据的深基坑本体变形特征研究[J]. 岩土工程学报, 2014, 36(增刊2): 319-324.  
YU Jun, GONG Xiaonan, LI Yuanhai. Study on deformation characteristics of deep foundation pit based on massive data [J]. Chinese Journal of Geotechnical Engineering, 2014, 36(Suppl.2): 319-324.
- [2] 李连祥, 韩志霄, 张潇潇, 等. 基于岩体稳定的土岩双元基坑破坏模式[J]. 山东大学学报(工学版), 2024, 54(3): 70-80.  
LI Lianxiang, HAN Zhixiao, ZHANG Xiaoxiao, et al. Failure mode of soil-rock dual foundation pit based on rock mass stability [J]. Journal of Shandong University (Engineering Science), 2024, 54(3): 70-80.
- [3] 李连祥, 张强, 石锦江, 等. 基坑开挖邻近隧道水平形变位移规律[J]. 山东大学学报(工学版), 2021, 51(1): 46-52.  
LI Lianxiang, ZHANG Qiang, SHI Jinjiang, et al. Law of horizontal deformation displacement of tunnels due to adjacent excavation [J]. Journal of Shandong University (Engineering Science), 2021, 51(1): 46-52.
- [4] 张陈蓉, 俞剑, 黄茂松. 基坑开挖对邻近地下管线影响的变形控制标准[J]. 岩土力学, 2012, 33(7): 2027-2034.  
ZHANG Chenrong, YU Jian, HUANG Maosong. Deformation controlling criterion of effect on underground pipelines due to foundation pit excavation [J]. Rock and Soil Mechanics, 2012, 33(7): 2027-2034.
- [5] 朱晓天. 渗流作用下粉质黏土地层超深基坑危害数值模拟分析[J]. 隧道与地下工程灾害防治, 2022, 4(2): 98-106.  
ZHU Xiaotian. Numerical simulation analysis of ultra-deep foundation pit in silty clay formation under seepage [J]. Hazard Control in Tunnelling and Underground Engineering, 2022, 4(2): 98-106.
- [6] 杨雨冰, 周彪, 谢雄耀. 邻近基坑施工作业下盾构隧道横向变形及开裂特性研究[J]. 岩石力学与工程学报, 2016, 35(增刊2): 4082-4093.  
YANG Yubing, ZHOU Biao, XIE Xiongyao. Study on lateral deformation and cracking characteristics of shield tunnel under adjacent foundation pit construction [J]. Chinese Journal of Rock Mechanics and Engineering, 2016, 35(Suppl.2): 4082-4093.
- [7] 李涛, 杨依伟, 周予启, 等. 深基坑内支撑拆除时支护结构水平位移计算方法[J]. 岩石力学与工程学报, 2022, 41(增刊1): 3021-3032.  
LI Tao, YANG Yiwei, ZHOU Yuqi, et al. Calculation method of horizontal displacement of supporting structure during demolition of internal support in deep foundation pit [J]. Chinese Journal of Rock Mechanics and Engineering, 2022, 41(Suppl.1): 3021-3032.
- [8] 梁发云, 褚峰, 宋著, 等. 紧邻地铁枢纽深基坑变形特性离心模型试验研究[J]. 岩土力学, 2012, 33(3): 657-664.  
LIANG Fayun, CHU Feng, SONG Zhu, et al. Centrifugal model test research on deformation behaviors of deep foundation pit adjacent to metro stations [J]. Rock and Soil Mechanics, 2012, 33(3): 657-664.
- [9] YE S H, ZHAO Z F, WANG D. Deformation analysis and safety assessment of existing metro tunnels affected by excavation of a foundation pit [J]. Underground Space, 2021, 6(4): 421-431.
- [10] 孙钧, 温海洋. 人工智能科学在软土地下工程施工变形预测与控制中的应用实践: 理论基础、方法实施、精细化智能管理(示例)[J]. 隧道建设(中英文), 2020, 40(1): 1-8.  
SUN Jun, WEN Haiyang. Application of artificial intelligence science to construction deformation prediction and control of underground engineering in soft soil: cases study on theoretical foundation, method application and fine intelligent technical management [J]. Tunnel Construction, 2020, 40(1): 1-8.

- [11] 汤志立, 徐千军. 基于9种机器学习算法的岩爆预测研究[J]. 岩石力学与工程学报, 2020, 39(4): 773-781.  
TANG Zhili, XU Qianjun. Rockburst prediction based on nine machine learning algorithms[J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(4): 773-781.
- [12] 刘开云, 乔春生, 滕文彦. 边坡位移非线性时间序列采用支持向量机算法的智能建模与预测研究[J]. 岩土工程学报, 2004, 26(1): 57-61.  
LIU Kaiyun, QIAO Chunsheng, TENG Wenyan. Research on non-linear time sequence intelligent model construction and prediction of slope displacement by using support vector machine algorithm [J]. Chinese Journal of Geotechnical Engineering, 2004, 26(1): 57-61.
- [13] 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 Changjie, LI Xinyu. Lateral deformation prediction of deep foundation retaining structures based on artificial neural network [J]. Journal of Shanghai Jiaotong University, 2024, 58(11): 1735-1744.
- [14] 李彦杰, 薛亚东, 岳磊, 等. 基于遗传算法-BP神经网络的深基坑变形预测[J]. 地下空间与工程学报, 2015, 11(增刊2): 741-749.  
LI Yanjie, XUE Yadong, YUE Lei, et al. Deformation prediction of deep foundation pit based on genetic algorithm-BP neural network [J]. Chinese Journal of Underground Space and Engineering, 2015, 11(Suppl. 2): 741-749.
- [15] LÜ Y, LIU T T, MA J, et al. Retraction Note: study on settlement prediction model of deep foundation pit in sand and pebble strata based on grey theory and BP neural network [J]. Arabian Journal of Geosciences, 2022, 15(8): 742.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [17] 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.
- [18] SHAN J Z, ZHANG X, LIU Y W, et al. Deformation prediction of large-scale civil structures using spatiotemporal clustering and empirical mode decomposition-based long short-term memory network [J]. Automation in Construction, 2024, 158: 105222.
- [19] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [20] 孙铁军, 李杰, 张豹, 等. 基于 GWO-SVR 模型的基坑边坡变形预测及敏感性分析[J]. 公路, 2022, 67(4): 390-395.  
SUN Tiejun, LI Jie, ZHANG Bao, et al. Deformation prediction and sensitivity analysis of foundation pit slope based on GWO-SVR model [J]. Highway, 2022, 67(4): 390-395.
- [21] 阮永芬, 余东晓, 吴龙, 等. DE-GWO 算法优化 SVM 反演软土力学参数[J]. 岩土工程学报, 2021, 43(增刊1): 166-170.  
RUAN Yongfen, YU Dongxiao, WU Long, et al. Optimization of SVM inversion of soft soil mechanical parameters by DE-GWO algorithm [J]. Chinese Journal of Geotechnical Engineering, 2021, 43(Suppl. 1): 166-170.
- [22] 邱道宏, 傅康, 薛翊国, 等. 深埋隧道 TBM 掘进参数 LSTM 时序预测模型及应用研究[J]. 中南大学学报(自然科学版), 2021, 52(8): 2646-2660.  
QIU Daohong, FU Kang, XUE Yiguo, et al. LSTM time-series prediction model for TBM tunneling parameters of deep-buried tunnels and application research [J]. Journal of Central South University (Science and Technology), 2021, 52(8): 2646-2660.
- [23] ZHANG W G, TANG L B, LI H R, et al. Probabilistic stability analysis of Bazimen landslide with monitored rainfall data and water level fluctuations in Three Gorges Reservoir, China [J]. Frontiers of Structural and Civil Engineering, 2020, 14(5): 1247-1261.
- [24] TANG L B, MA Y B, WANG L, et al. Application of long short-term memory neural network and prophet algorithm in slope displacement prediction [J]. International Journal of Geoenvironment Case Histories, 2021, 6(4): 48-66.
- [25] 苏恩杰, 叶飞, 何乔, 等. 基于卷积神经网络-长短期记忆的施工期盾构管片上浮过程预测模型[J]. 同济大学学报(自然科学版), 2023, 51(9): 1352-1361.  
SU Enjie, YE Fei, HE Qiao, et al. Prediction model of shield segment floating process during construction based on convolutional neural networks and long short-term memory [J]. Journal of Tongji University (Natural Science), 2023, 51(9): 1352-1361.
- [26] 李洛宾, 龚晓南, 甘晓露, 等. 基于循环神经网络的盾构隧道引发地面最大沉降预测[J]. 土木工程学报, 2020, 53(增刊1): 13-19.  
LI Luobin, GONG Xiaonan, GAN Xiaolu, et al. Prediction of maximum ground settlement caused by shield tunnel based on cyclic neural network [J]. China Civil Engineering Journal, 2020, 53(Suppl.1): 13-19.