

# 基于小波优化 LSTM-ARMA 模型的岩土工程非线性 时间序列预测

钱建固<sup>1,2</sup>, 吴安海<sup>1,2</sup>, 季军<sup>3</sup>, 成龙<sup>4</sup>, 徐巍<sup>1,2</sup>

(1. 同济大学土木工程学院, 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. 上海城投水务(集团)有限公司, 上海 200002; 4. 上海勘察设计研究院(集团)有限公司, 上海 200093)

**摘要:** 为了更精确地预测岩土工程应力、变形等的非线性时间序列, 提出了基于小波优化的长短时记忆神经网络-自回归滑动平均模型(LSTM-ARMA)预测模型。首先使用小波分析将监测序列分解成趋势项和噪声项, 采用LSTM网络滚动预测趋势项、ARMA模型预测噪声项, 并将趋势项预测值与噪声项预测值之和作为总的时间序列预测值。在此基础上, 以上海云岭超深基坑工程为案例进行了基坑地表沉降分析, 结果表明组合模型的预测精度要高于单一LSTM模型且更加稳定; 进一步采用弹塑性有限元对基坑开挖诱发的地表沉降进行了预测, 并与人工智能预测结果进行对比, 验证了人工智能预测模型的合理性。分析表明, 当后续工况与前置工况所诱发的变形机理突变时, 人工智能预测误差增大, 但伴随后续工况的推进, 人工智能预测误差将逐渐减小。

**关键词:** 岩土工程; 非线性时间序列预测; 小波分析; 长短时记忆神经网络(LSTM); 自回归滑动平均模型(ARMA)

中图分类号: TU433

文献标志码: A

## Prediction for Nonlinear Time Series of Geotechnical Engineering Based on Wavelet-Optimized LSTM-ARMA Model

QIAN Jiangu<sup>1,2</sup>, WU Anhai<sup>1,2</sup>, JI Jun<sup>3</sup>, CHENG Long<sup>4</sup>, XU Wei<sup>1,2</sup>

(1. 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. Shanghai Chengtou Water Group Co., Ltd., Shanghai 200002, China; 4. Shanghai Geotechnical Investigation and Design Institute Engineering Consulting (Group) Co., Ltd., Shanghai 200093, China)

**Abstract:** In order to predict the nonlinear time series of geotechnical engineering more precisely, a wavelet-

optimized LSTM-ARMA model is proposed. First, the monitoring series are decomposed into a trend term and a noise term through wavelet analysis. Then, the trend term is predicted by the long short-term memory network (LSTM), while the noise term by the autoregressive moving average model (ARMA). Finally, the sum of the predicted values of both terms is taken as the total predicted results. The performance of the method is validated through the case analysis of an ultra-deep foundation pit which also indicates that the combined model gives a more precise and stable prediction than the LSTM network. Besides, the elastic-plastic finite element method is also used to predict the ground settlement induced by foundation pit excavation, and its results are compared with those of the artificial intelligence method, verifying the rationality of the latter. The analysis shows that the prediction error of the artificial intelligent method will increase significantly when the deformation mechanisms of the previous and the subsequent working conditions change suddenly, but it will decrease gradually with the progress of the subsequent working conditions.

**Key words:** geotechnical engineering; nonlinear time series prediction; wavelet analysis; long short-term memory network (LSTM); autoregressive moving average model (ARMA)

由于岩土体材料的特殊性、实际影响因素的复杂性, 岩土工程应力、变形等的时间序列通常表现出十分明显的非线性特征<sup>[1]</sup>, 且其演化过程具有随机性、模糊性和高度复杂性的特点。

传统的分析方法如理论分析、数值模拟和经验公

收稿日期: 2020-09-19

基金项目: 国家自然科学基金资助项目(51578413); 苏州河段深层排水调蓄管道系统工程试验段监测技术验证与分析模型研究项目; 中央高校基本科研业务费专项资金资助(22120190220)

第一作者: 钱建固(1972—), 男, 教授、博士生导师, 工学博士, 主要研究方向为岩土力学与本构理论、岩土基础工程和交通岩土工程. E-mail: qianjiangu@tongji.edu.cn



论文  
拓展  
介绍

式法等等<sup>[2-4]</sup>虽然具备预测的能力,但由于理论计算方法的不成熟,往往只适用于特定工况,在实际工程应用时通常存在比较大的误差,预测精度难以满足要求。

伴随着大数据科学与人工智能技术的发展,智能预测已逐渐成为岩土工程领域的发展趋势。常用的智能分析方法有:灰色预测、时间序列分析、优化算法和BP(反向传播)神经网络等<sup>[5-6]</sup>。但是这些算法都存在一些局限性。监测数据为动态数据,其随时间的推移不断更新变换,同时由于影响因素的复杂多变,还往往具有高度非线性和非平稳性的特征。而灰色预测和时间序列分析均不具备滚动预测的能力,无法以当前的预测结果为基础继续进行下一步的预测。优化算法如遗传算法、蚁群算法等则存在局部极值的问题,容易陷入局部最优从而无法找到全局最优的预测结果。BP神经网络是一种多层前馈神经网络,层与层之间通过导数连乘来传递和更新信息,当导数很小或者很大时,BP神经网络便容易出现梯度消失和梯度爆炸的问题而造成结果的不收敛。为了更好地分析时间序列,Hochreite和Schmidhuber<sup>[7]</sup>于1997年提出了长短时记忆神经网络(long short-term memory neural network, LSTM)。同BP神经网络相比,它不仅解决了梯度消失和梯度爆炸的问题,同时还对高度非线性的数据有着极强的映射能力,能够对岩土工程应力、变形等的时间序列做出高精度的预测。

当前智能方法在岩土工程领域中的应用大致可以分为两类。一类为基于模型的反演方法,在基本土体模型的基础上,通过对少部分数据的学习,修正基本土体模型参数,从而得到较为准确的预测结果<sup>[8]</sup>。该类方法已经较为成熟,在预测土体变形、强度等方面都得到了较为广泛的运用<sup>[9]</sup>。另一类为基于大数据的智能算法,该类方法不考虑土力学原理,直接通过相关工程数据的学习,找出不同对象间的隐藏规律,进而做出准确预测<sup>[10]</sup>。该类方法对数据的要求更高,但是技术却尚未成熟,因此在实际工程中的应用并不普及。如何改进第二类方法,使其预测结果能更好地指导生产实践便是本文的主要研究目的。

另一方面,实际工程由于受到施工、自然天气等各种随机因素的干扰,采集到的监测数据往往包含了各种噪声。噪声即高频误差,它的存在将会影响LSTM神经网络对数据的学习,最终造成预测结果的不准确。为了充分考虑噪声的影响,本文提出了基于小波优化(Wavelet Optimized)的长短时记忆神经网络-自回归

滑动平均(LSTM-ARMA)预测模型。先通过小波变换提取原始监测时间序列的噪声,得到噪声项,扣除噪声项后剩余的部分即为趋势项。其中,趋势项真实反映了实际工程中应力、变形等的演化趋势,而噪声项则体现了各种随机因素的综合干扰。长短时记忆神经网络(long short-term memory network, LSTM)擅长学习阶梯性与趋势性的时间序列,自回归滑动平均模型(autoregressive moving average, ARMA)模型擅长模拟平稳时间序列(均值、方差恒定)。因此,本文分别使用LSTM神经网络和ARMA模型学习并预测趋势项和噪声项。最终将趋势项预测值和噪声项预测值之和作为总的时间序列预测值。

小波分析、LSTM神经网络与ARMA模型的结合使用在岩土工程预测分析领域比较鲜见,为了检验该组合模型的有效性与可行性,本文将其运用于上海云岭超深基坑工程的地表沉降预测中。工程实例表明,该预测方法相对误差小、预测精度稳定,具有较好的工程实用性。

## 1 预测模型

基于小波优化的LSTM-ARMA时序预测模型可按照以下几个步骤进行:

(1)对监测得到的非线性时间序列进行处理,剔除异常数据并且通过线性插值等方式将监测时间序列变成等距时间序列。

(2)选取适当的小波基函数和分解层数,对时间序列进行小波降噪,将其分解成趋势项和噪声项。

常用的小波基函数有db小波基(如db5、db6等)、haar小波基和sym小波基等。通过小波变换,可将原始时间序列 $f(t)$ 分解成各个子信号的叠加:

$$f(t) = c_{j,k} \sum_k \varphi_{j,k} + d_{j,k} \sum_k \psi_{j,k} \quad (1)$$

其中: $\varphi_{j,k}$ 为近似信号; $\psi_{j,k}$ 为细节信号; $c_{j,k}$ 与 $d_{j,k}$ 为相应的系数。近似信号与细节信号分别描述原始时间序列的低频与高频部分,但仅为相对概念,并不代表频率的绝对大小。原始信号经小波多层次分解后,每一层级上均可获得一个低频子信号与一个高频子信号<sup>[11]</sup>。

接着设置合理的阈值 $T$ ,若某一时刻的子信号值低于该阈值,则认为其是由噪声产生,将其置为零从而实现去噪。常用的阈值计算方法<sup>[11]</sup>如式(2)所示:

$$T = \sigma \sqrt{2 \ln n} \quad (2)$$

其中: $n$ 为信号的采样长度; $\sigma$ 为噪声信号的方差,可根据鲁棒中值定理<sup>[11]</sup>进行计算。

最终可将原始时间序列  $f(t)$  分解成趋势项  $\text{trend}(t)$  与噪声项  $\text{noise}(t)$  之和:

$$f(t) = \text{trend}(t) + \text{noise}(t) \quad (3)$$

(3) 趋势项采用 LSTM 神经网络进行滚动预测。

LSTM 神经网络的结构为链式结构,由一个个重复单元串联而成。重复单元的内部构造如图 1 所示。前已述及,BP 神经网络由于结构问题,容易出现梯度消失或者梯度爆炸,从而导致结果的不收敛。而 LSTM 神经网络特色性地加入了细胞状态  $C_t$  用于记录长期信息、隐藏状态  $h_t$  用于记录短期信息,同时设置了“门”的结构(遗忘门、输入门和输出门)用于时刻更新和丢弃信息,这使得 LSTM 神经网络在时间序列预测上表现优异,同时还避免了梯度消失和梯度爆炸的问题。

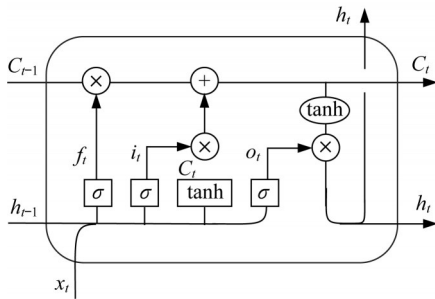


图 1 LSTM 重复单元示意图

Fig. 1 Architecture of LSTM neural network

滚动预测趋势项前,需要先构造样本用于训练 LSTM 神经网络。样本构造方式如表 1 所示,其中  $u$  代表监测变形序列中的趋势项。

表 1 LSTM 神经网络的输入与输出

Tab. 1 Input and output of LSTM neural network

网络输入	期望输入
$u_{(1)}, u_{(2)}, u_{(3)}, \dots, u_{(m)}$	$u_{(m+1)}$
$u_{(2)}, u_{(3)}, u_{(4)}, \dots, u_{(m+1)}$	$u_{(m+2)}$
...	...
$u_{(k)}, u_{(k+1)}, u_{(k+2)}, \dots, u_{(k+m-1)}$	$u_{(k+m)}$

$m$  的取值从 3 到 10 不等<sup>[12]</sup>,并且可以随着可构造样本的数量进行调整,在本文中  $m$  统一取为 5。后续采用滚动预测的方式进行预测,比如使用  $u_{(1)}, u_{(2)}, u_{(3)}, \dots, u_{(m)}$  预测  $u_{(m+1)}^*$ ,然后再使用  $u_{(2)}, u_{(3)}, u_{(4)}, \dots, u_{(m)}, u_{(m+1)}^*$  预测  $u_{(m+2)}^*$ ,通过这种方式可实现多个时刻变形值的预测。

(4) 噪声项采用 ARMA( $p, q$ ) 模型预测。

自回归移动平均模型(简称 ARMA),是用来预测平稳时间序列的一种方法。令  $X_t$  为  $t$  时刻的观测值,假设  $X_t$  不仅与  $t$  时刻之前的观测值  $X_{t-1},$

$X_{t-2}, \dots, X_{t-p}$  有关,还与  $t$  时刻之前的扰动值  $\epsilon_{t-1}, \epsilon_{t-2}, \dots, \epsilon_{t-q}$  相关,则  $X_t$  可写成如下形式:

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} \quad (4)$$

其中: $\varphi_1, \varphi_2, \dots, \varphi_p$  与  $\theta_1, \theta_2, \dots, \theta_q$  均为该线性组合的系数。

当  $X_t$  为平稳时间序列, $\epsilon_t$  为白噪声序列,且满足式(5)时,称  $\{X_t\}$  为  $p$  阶自回归与  $q$  阶滑动平均混合序列,记为 ARMA( $p, q$ )。

$$\begin{cases} \varphi_p \neq 0, \theta_q \neq 0 \\ E\epsilon_t^2 = \sigma^2 \\ EX_s \epsilon_t = 0, s < t \end{cases} \quad (5)$$

其中: $E$  表示的是数学期望。ARMA 模型的使用前提是序列的平稳性。因此,首先要使用增广迪基-富勒检验(augmented Dickey-Fuller test, ADF)单位根判别噪声序列是否平稳,若平稳,则可采用 ARMA 模型进行预测,否则需要调整小波基函数和分解层数,直至噪声序列为平稳时间序列。

随后需计算不同  $p, q$  组合下该噪声序列的信息准则值,如常用的赤池信息准则(akaike information criterion, AIC)与贝叶斯信息准则(Bayesian information criterion, BIC)等,用以评估拟合模型优劣的衡量标准,进而实现对模型中的变量起到优化选择<sup>[13]</sup>。信息准则值越小则表示相应( $p, q$ )阶的 ARMA 模型越好。

(5) 将趋势项预测值与噪声项预测值相加得到总的时间序列预测值  $y_i (i=1, 2, \dots, n)$ , 并与监测值  $f_i$  对比,分析误差情况。常用的误差评价指标有均方根误差(RMSE)与平均百分比误差(MAPE):

$$R_{\text{MAPE}} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - f_i}{f_i} \right| \quad (6)$$

$$R_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2} \quad (7)$$

式中: $R_{\text{MAPE}}$  为均方根误差; $R_{\text{RMSE}}$  为平均百分比误差。

预测流程如图 2 所示。预测前后趋势项与噪声项的曲线示意图如图 3 所示。趋势项与噪声项求和便可得到总的时间序列。

## 2 工程实例分析

### 2.1 工程概况

云岭基础设施基坑为上海苏州河段深层排水调蓄管道系统工程的一部分。基坑呈圆形,直径 34 m,



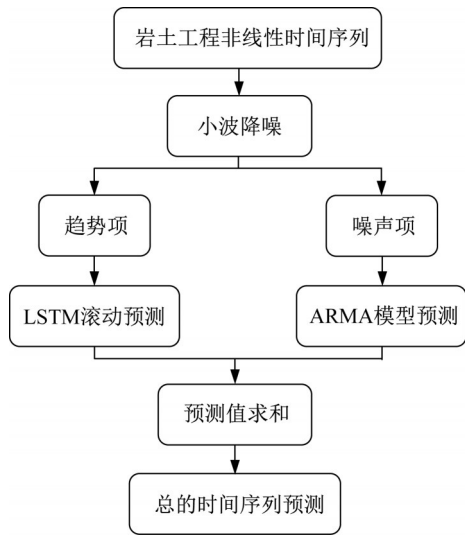


图2 预测流程图

Fig. 2 Flowchart of the forecast model




图3 预测前后趋势项与噪声项的曲线示意图

Fig. 3 Curves of trend term and noise term before and after prediction

目标深度 57.84 m, 超过国内基坑最大开挖深度 51 m. 支护结构采用 1 500 mm 连续墙, 地连墙采用铰接头, 逆作内衬墙。基坑地处上海软土区域, 地质条件复杂, 且深层土体力学特性不明, 因此周边布置了

大量监测点。基坑外地表沉降测线布设和基坑剖面分别如图4、图5所示。




图4 超深基坑平面及地表沉降测线布置

Fig. 4 Plan and monitoring arrangement of the ultra-deep foundation pit




图5 超深基坑剖面图(单位:m)

Fig. 5 Profile of ultra-deep foundation pit (unit:m)

基坑周围布设了4条沉降测线, 分别为DB1、DB2、DB3和DB4, 其与图4水平方向的夹角依次为11.6°、86.2°、8.3°和87.2°。本文选取每条测线上的第一个监测点(即DB1-1、DB2-1、DB3-1、DB4-1)的沉降监测数据用于训练和检验该预测模型。这4个监测点与竖井间的距离均约为4.8 m。

需指出的是,目前基坑开挖尚未完工,以下选取了自开工2017. 11. 6至最近2020. 8. 24期间共计10个工况,记为工况1~工况10,具体情况如表2所示。

其中,测点DB4-1在工况8中由于施工原因被毁,相应的监测数据只更新至2020. 6. 7为止。

表2 施工工况

Tab. 2 Construction conditions

编号	施工工况	起始时间	终止时间	数据个数
工况1	围护墙施工	2017. 11. 21	2019. 11. 6	120
工况2	降水试验、圈梁施工	2019. 11. 7	2019. 12. 28	8
工况3	第二层土方开挖与第一道环梁	2019. 12. 29	2020. 1. 15	3
工况4	春节停工	2020. 1. 16	2020. 3. 15	10
工况5	第三层土方开挖与第二道环梁	2020. 3. 16	2020. 4. 19	6
工况6	第四层土方开挖与第一道内衬墙	2020. 4. 20	2020. 5. 8	3
工况7	第五层土方开挖与第二道内衬墙	2020. 5. 9	2020. 5. 31	4
工况8	第六层土方开挖与第三道内衬墙	2020. 6. 1	2020. 7. 11	7
工况9	第七层土方开挖与第四道内衬墙	2020. 7. 12	2020. 7. 31	3
工况10	第八层土方开挖与第五道内衬墙	2020. 8. 1	2020. 8. 24	4

2.2 数据预处理

现场采集的监测数据并非等时间间隔,需要进行插值处理。为了减少插值的影响,维持原始时间序列的变化规律,本文选用分段线性插值的方法。插值起始时间为2017. 11. 21,间距为6 d。插值后的沉降监测点DB1-1、DB2-1、DB3-1和DB4-1的数据如图6所示,从左到右依次为工况1~工况10,分别对应120、8、3、10、6、3、4、7、3、4组数据,如表2所示。

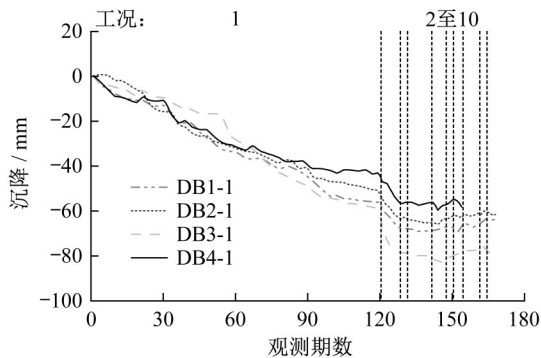


图6 地表沉降时程曲线

Fig. 6 Ground surface deformation

2.3 DB1-1 监测数据建模预测

现以DB1-1沉降监测数据为例,详细描述如何建立LSTM-ARMA时序预测模型。

首先利用工况1的监测数据建模预测工况2的沉降变形,接着利用工况1和工况2的监测数据建模预测工况3的沉降变形,依此类推,最后利用工况1~工况10的监测数据建模预测未来工况的沉降变形。

2.3.1 工况2沉降变形的预测

(1) 小波降噪分析

实际工程由于受到各种因素的干扰,所采集的监测数据将会包含一定的噪声,需要对其进行小波降噪从而获得真实的历史沉降信息。去噪步骤为:首先,分别选用小波基函数db10、db15和db20对工况1的监测数据依次进行3层、4层和5层的小波分解;提取出高频噪声后分别计算信噪比SNR和均方根误差RMSE,信噪比越大、均方根误差越小则代表分解效果越好<sup>[14]</sup>。计算结果如表3所示。

表3 小波降噪结果对比

Tab. 3 Comparison of different wavelet denoises

小波基函数	分解尺度	信噪比 (SNR)	均方根误差 (RMSE)
db10	3	23.795 8	0.597 2
	4	23.790 8	0.836 2
	5	23.759 0	0.990 4
db15	3	23.799 3	0.604 7
	4	23.799 9	0.825 4
	5	23.785 0	1.019 6
db20	3	23.802 5	0.550 3
	4	23.798 8	0.874 4
	5	23.772 1	1.110 7

在小波基函数为db20且分解层数为3的情况下,信噪比为23.802 5,均方根误差为0.550 3,去噪效果最为理想。此时,提取的趋势项与噪声项如图7所示。

(2) 趋势项预测

趋势项采用LSTM网络进行预测,样本构造采用“5+1”模式,即采用当前时刻以及前4个时刻的值不断滚动预测下一时刻的值。

(3) 噪声项预测




图7 DB1-1工况1的趋势项与噪声项

Fig. 7 Trend and noise term of DB1-1 in working condition 1

噪声项采用ARMA模型进行预测。图7表明噪声曲线直观上为平稳时间序列,需要经过ADF单位根进行进一步的平稳性检验。经过计算,ADF值为-7.3433,由表4可知,该噪声序列在99%的置信概率下为平稳时间序列,因此可使用ARMA模型。

表4 不同置信区间对应的临界ADF值

Tab. 4 Critical ADF values corresponding to different confidence intervals

置信区间	99 %	95 %	90 %
临界ADF值	-3.4936	-2.8892	-2.5815

根据AIC准则<sup>[13]</sup>绘制噪声序列的热力图,如图8所示。图中,信息准则值与热力图颜色深浅的对应关系参照图右方的色带。当 $p$ (即AR系数)取2、 $q$ (即MA系数)取5时,图中小矩形的颜色最深,表示此时的信息准则值最小、模型最优。

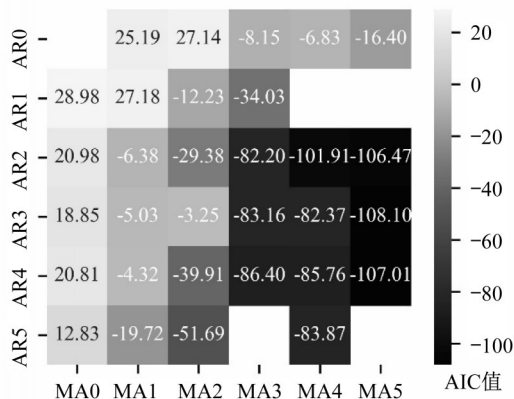


图8 噪声项热力图

Fig. 8 Thermograph of noise term

(4)总的变形预测

将趋势项的预测结果和噪声项的预测结果之和作为总的预测值,如图9所示。为了证明该组合模

型的优越性,在不采用小波降噪与ARMA模型的前提下,直接使用LSTM模型预测工况2的沉降变形,结果如图10所示。

2.3.2 后续工况沉降变形的预测

按照同样的方法,分别利用工况1~2、1~3、1~4、1~5、1~6、1~7、1~8、1~9与1~10的监测数据建模预测工况3、4、5、6、7、8、9、10与未来工况的沉降变形,结果如图9所示。同时,也只使用LSTM模型对后续工况进行了预测,预测结果如图10所示。




图9 DB1-1工况2~工况10的LSTM-ARMA预测结果

Fig. 9 LSTM-ARMA prediction results of DB1-1 in working conditions 2-10




图10 DB1-1工况2~工况10的LSTM预测结果

Fig. 10 LSTM prediction results of DB1-1 in working conditions 2-10

图9表明,工况2的预测精度最差,最大相对误差高达8.00%,而其余工况的最大相对误差均不超过4.20%。这主要是由于工况2为抽水试验和疏干降水,其引起监测点变形的速率要大于工况1中的围护墙施工,而工况2的预测采用的是工况1的变形数据进行建模,LSTM网络所学习的变形规律均为工况1监测点的变形规律,所以不能很好地预测工况2的沉降变形。相比之下,工况3~工况10阶段产生的变形较小,预测也更加准确。

图9说明,当使用基于小波优化的LSTM-ARMA模型时,相对误差在0.30%~8.00%之间,平均值为2.66%,方差为2.64。而根据图10,只使

用 LSTM 模型进行预测时,相对误差在 0.09 %~8.78 % 之间,平均值为 2.89 %,方差为 3.16。虽然在少部分期数中(如第 122 期、第 123 期等),后者的预测误差稍低,但从整体上看,前者的预测误差在平均值和方差上都比后者更小,因此 LSTM-ARMA 模型的预测效果更加理想。

2.4 其余监测点监测数据的建模预测

基于同样的方法和步骤,对插值后 DB2-1、DB3-1 和 DB4-1 的沉降数据进行建模预测,结果如图 11、图 12 和图 13 所示。




图 11 DB2-1 工况 2~工况 10 的 LSTM-ARMA 预测结果  
Fig. 11 LSTM-ARMA prediction results of DB2-1 in working conditions 2-10




图 12 DB3-1 工况 2~工况 10 的 LSTM-ARMA 预测结果  
Fig. 12 LSTM-ARMA prediction results of DB3-1 in working conditions 2-10




图 13 DB4-1 工况 2~工况 7 的 LSTM-ARMA 预测结果  
Fig. 13 LSTM-ARMA prediction results of DB4-1 in working conditions 2-7

显然,4 个监测点的沉降规律基本一致,且工况 2 的预测误差都比较大,最大相对误差超过 18 %;而工况 3~工况 10 的预测误差均比较小,最大相对误差不超过 6 %。这与监测点在工况 1 和工况 2 下的变形速率相差过大有关。

此外,利用 LSTM-ARMA 模型预测 DB2-1、DB3-1 和 DB4-1 的平均相对误差分别为 2.91 %、3.80 % 和 4.61 %,方差分别为 12.91、19.39 和 22.21。而只采用 LSTM 模型预测的平均相对误差为 4.35 %、6.14 % 和 4.18 %,方差为 20.17、42.73 和 16.95。综合来看,LSTM-ARMA 模型取得了更好的预测结果。

2.5 样本数量的影响

样本数量对于 LSTM 正确学习序列规律具有较大的影响,样本数量若过少,LSTM 则难收敛,甚至得不到最优解,为此,以下将探讨样本数量对 LSTM-ARMA 模型预测精度的影响。以测点 DB1-1 为示例,分别用最新 30 期、60 期、90 期和 120 期工况 1 的沉降监测数据训练 ARMA-LSTM 模型,并使用训练完毕的模型预测工况 2 的沉降值。预测误差结果如图 14 所示。




图 14 不同样本数量下的模型预测误差对比  
Fig. 14 Comparison of prediction errors in different sample quantities

不难看出,样本数量的增加能提高模型的预测精度。当样本数量为 30,即仅使用工况 1 最新 30 期数据预测工况 2 沉降值时,最大预测误差高达 18 %;而当样本数量增加至 60 时,最大误差减小一半,约为 9 %;此后继续增加样本数量,预测精度可以进一步提高,但是提高幅度减小。由此可见,依据预测精度要求,有必要合理地选择样本数量;在满足工程需求的条件下,继续增大样本数量,对提高预测精度非常有限,反之还将显著降低计算效率。

3 有限元验证

为了说明 LSTM-ARMA 智能预测模型的有效



性,这里将地表总沉降分成两部分,即基坑开挖诱发沉降与非开挖诱发沉降,其中,基坑开挖诱发的地表沉降采用弹塑性有限元预测,而非开挖因素(降水、围护墙施工、地表堆载等)诱发的沉降变形则仍采用智能预测模型预测,二者叠加之后便与现场实测的真实变形作对比验证,计算剖面为DB1-1。

有限元数值模型如图15所示,考虑圆形基坑的轴对称性,建立轴对称准三维模型。土层剖面按图5确定,土体模型采用适用于软土应力应变响应的HS(Hardening-Soil)模型<sup>[15]</sup>,参数如表5所示,取值参考文献[16]。有限元模型的结构参数如表6所示,其中包括地连墙、围檩与内衬墙,当土体开挖至指定深度时,便将围檩与内衬墙相应范围内的刚度附加至地连墙中,以模拟围檩与内衬墙的施工。以DB1-1工况1的沉降监测序列预测工况2~工况10的沉降变形为例,该过程具体如下所示。




图15 有限元模型网格划分(单位: m)

Fig. 15 Mesh generation of finite element model (unit: m)

表5 有限元模型土体参数

Tab. 5 Soil parameters of finite element model

土层号	$\gamma / (\text{kN} \cdot \text{m}^{-3})$	$E_{50}^{\text{ref}} / \text{kPa}$	$E_{\text{ocd}}^{\text{ref}} / \text{kPa}$	$E_{\text{ur}}^{\text{ref}} / \text{kPa}$	$c' / \text{kPa}$	$\phi' / (^\circ)$	$\psi / (^\circ)$
② <sub>3</sub>	18.6	9 000	9 000	45 000	10	30	0
④	17	2 700	2 700	13 500	3	27.3	0
⑤ <sub>1</sub>	17.6	4 000	4 000	20 000	1	38	0
⑤ <sub>3</sub>	17.8	5 500	5 500	27 500	20	26.7	0
⑤ <sub>4</sub>	19.5	7 000	7 000	35 000	6	31	0
⑦	19.5	12 000	12 000	36 000	1	38	8
⑧ <sub>1</sub>	18	5 500	5 500	27 500	16	28.9	0
⑧ <sub>2</sub>	18.5	6 500	6 500	26 000	15.7	30.1	0
⑨	19.4	15 000	15 000	45 000	0	34.6	8

整个基坑开挖全过程对应于表2中的工况2~工况10,预测的最大开挖深度35 m,考虑软土地层渗透性小,且施工期相对较短,数值分析忽略开挖期

表6 有限元模型结构参数

Tab. 6 Structure parameters of finite element model

结构	厚度 /m	$EA / (\text{MN} \cdot \text{m}^{-1})$	$EI / (\text{MN} \cdot \text{m}^2 \cdot \text{m}^{-1})$	顶部深度 /m	长度 /m
地下连续墙	1.5	45 000	8 438	0	105
围檩1	2.0	60 000	20 000	8.5	1.3
围檩2	2.0	60 000	20 000	15.0	1.3
内衬墙1	1.0	30 000	2 500	16.5	15.5
内衬墙2	1.5	45 000	8 438	32.0	3.0

间的排水固结效应。开挖有限元预测、非开挖人工智能模型预测及二者叠加如图16所示,对比实测结果可以看出,不仅二者的发展趋势上吻合较好,同时在数量上也较为接近,其最大相对误差不超过9%,平均相对误差也仅为5%左右。值得一提的是,开挖初期采用有限元预测与人工智能预测的叠加结果,要好于单一的人工智能模型预测,而随着后期工况的发展,两类预测结果差异性逐渐减小,表明单一的人工智能预测在工况突变阶段(对应于本案例为非开挖到开挖过渡阶段),可能引起较大的约误差。




图16 DB1-1工况2-10的模型预测结果

Fig. 16 Prediction results of DB1-1 in working conditions 2-10

## 4 结论与展望

针对岩土工程领域的非线性时间序列预测问题,本文提出了基于小波优化的LSTM-ARMA模型。作为案例,将其运用到上海云岭超深基坑工程的地表沉降预测中,通过与沉降监测值的比较,得到以下结论:

(1)实际工程由于受到各种随机因素的干扰,所采集的监测数据将会包含噪声信号。通过小波降噪提取的趋势项可以更真实地反映基坑变形规律;

(2)将原始时间序列小波分解成趋势项与噪声项,并分别使用LSTM模型与ARMA模型进行预测,预测值之和作为总的变形预测值。该组合模型同时综合了LSTM与ARMA的优势。工程案例表明,LSTM-ARMA模型比单纯使用的LSTM模型预测误差更小、



精度更稳定,从而效果更加理想;

(3)案例分析表明:若后续工况与前置工况沉降规律相近,则预测误差较小;若二者沉降规律相差过大,预测误差则会明显变大。

(4)采用弹塑性有限元对开挖诱发的地表沉降进行了预测,验证了人工智预测模型的合理性。在非开挖工况向开挖工况突变阶段,单一人工智能预测模型预测可能产生较大的误差,随着后续开挖工况的发展,人工智能预测误差将逐渐减小。

(5)该组合模型适用于非线性时间序列的分析,在岩土工程领域,可实测的应力与变形指标都具有非线性特点。因此,该流程分析也可推广预测工程中应力与变形等变量的演化规律。

#### 作者贡献说明:

钱建固:课题研究与论文撰写的指导。

吴安海:课题研究与论文撰写。

季军:提供相关工程资料。

成龙:提供相关工程资料。

徐巍:编程指导。

#### 参考文献:

- [1] 杨敏,任红林.智能岩土工程的特点初探[J].同济大学学报(自然科学版),2000,28(6):636.  
YANG Min, REN Honglin. Preliminary research on characteristics of intelligent geotechniques [J]. Journal of Tongji University (Natural Science), 2000, 28(6): 636.
- [2] SAGASETA C. Analysis of undrained soil deformation due to ground loss[J]. Geotechnique, 1987, 37(3): 301.
- [3] 李小青,王朋团,张剑.软土基坑周围地表沉降变形计算分析[J].岩土力学,2007,28(9):1879.  
LI Xiaoqing, WANG Pengtuan, ZHANG Jian. Calculation analysis of circumferential surface settlement of soft soil foundation pit[J]. Rock and Soil Mechanics, 2007, 28(9): 1879.
- [4] 杨晶,楼晓明,黄江枫,等.常见沉降预测方法在软基堆载预压实例中的应用比较[J].工程勘察,2011,39(3):18.  
YANG Jing, LOU Xiaoming, HUANG Jiangfeng, et al. Comparison of common settlement predicting methods in application of a project case of surcharge preloading method[J]. Geotechnical Investigation & Surveying, 2011, 39(3): 18.
- [5] 金路,姜谱男,赵文.基于差异进化支持向量机的基坑变形时间序列预测[J].岩土工程学报,2008,30(S1):216.  
JIN Lu, JIANG Annan, ZHAO Wen. Time series forecast model of foundation pit deformation based on DE-SVM[J]. Chinese Journal of Geotechnical Engineering, 2008, 30(S1): 216.
- [6] 邓传军,欧阳斌,陈艳红.一种基于PSO-BP神经网络的建筑物沉降预测模型[J].测绘科学,2018,43(6):27.  
DENG Chuanjun, OUYANG Bin, CHEN Yanhong. A building settlement prediction model based on PSO-BP neural network[J]. Science of Surveying and Mapping, 2018, 43(6): 27.
- [7] HOCHREITE S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735.
- [8] 木林隆,黄茂松,吴世明.基于反分析法的基坑开挖引起的土体位移分析[J].岩土工程学报,2012,34(S1):60.  
MU Linlong, HUANG Maosong, WU Shiming. Soil responses induced by excavation based on inverse analysis [J]. Chinese Journal of Geotechnical Engineering, 2012, 34(S1): 60.
- [9] QIAN Jiangu, XU Wei, MU Linlong, et al. Calibration of soil parameters based on intelligent algorithm using efficient sampling method[J]. Underground Space, 2021, 6(3): 329.
- [10] ZHANG Pin, YIN Zhenyu, JIN Yinfu, et al. An AI-based model for describing cyclic characteristics of granular materials [J]. International Journal for Numerical and Analytical Methods in Geomechanics, 2020, 44(9): 1315.
- [11] 徐一帆.基于小波降噪技术的OPAX方法改进研究及应用[D].沈阳:沈阳理工大学,2020.  
XU Yifan. Study and application of OPAX method based on wavelet denoising technology[D]. Shenyang: Shenyang Ligong University, 2020.
- [12] 赵其华,孙钧,徐伟.地连墙变形的神经网络多步预测研究[J].成都理工学院学报,2002,29(5):581.  
ZHAO Qihua, SUN Jun, XU Wei. Displacement prediction of underground continuous wall by the multi step neural network method[J]. Journal of Chengdu University of Technology, 2002, 29(5): 581.
- [13] 贾易.加法风险模型下关于右侧失生存数据的变量选择方法的研究[D].武汉:华中师范大学,2019.  
JIA Yi. Variable selection in additive hazard model for right censored data [D]. Wuhan: Central China Normal University, 2019.
- [14] 李宗春,邓勇,张冠宇,等.变形测量异常数据处理中小波变换最佳级数的确定[J].武汉大学学报(信息科学版),2011,36(3):285.  
LI Zongchun, DENG Yong, ZHANG Guanyu, et al. Deformation measurement of abnormal data in the wavelet transform to determine the best series[J]. Geomatics and Information Science of Wuhan University, 2011, 36(3): 285.
- [15] 刘书斌,王春波,周立波,等.硬化土模型在无锡地区深基坑工程中的应用与分析[J].岩石力学与工程学报,2014,33(S1):3022.  
LIU Shubin, WANG Chunbo, ZHOU Libo, et al. Application and analysis of hardening soil model in deep foundation pits in Wuxi district [J]. Chinese Journal of Rock Mechanics and Engineering, 2014, 33(S1): 3022.
- [16] 王浩然.上海软土地区深基坑变形与环境影响预测方法研究[D].上海:同济大学,2012.  
WANG Haoran. Prediction of deformation and response of adjacent environment of deep excavations in Shanghai soft deposit [D]. Shanghai: Tongji University, 2012.