

DOI: 10.11779/CJGE2021S2026

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

洪宇超^{1,2}, 钱建固^{*1,2}, 叶源新³, 成 龙⁴

(1. 同济大学地下建筑与工程系, 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. 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: 为了更准确地预测基坑工程领域的复杂时间序列, 提出一种以多个监测点的监测数据构成的多维时间序列作为输入的 CNN-LSTM 的组合神经网络模型。首先采用卷积神经网络(CNN)对输入的监测数据进行空间特征提取, 输出多个由空间特征构成的时间序列, 利用长短期记忆神经网络(LSTM)对空间特征序列进行学习, 预测未来的特征值, 最后通过全连接层整合空间特征, 输出预测的监测值。在此基础上, 基于上海云岭竖井超深基坑的现场地表沉降监测数据进行工程案例验证, 结果表明考虑时空关联性的组合模型精度高于仅考虑时间关联性的单一 LSTM 模型。

关键词: 基坑; 变形预测; 时间序列建模; CNN 网络; LSTM 网络

中图分类号: TU43

文献标识码: A

文章编号: 1000-4548(2021)S2-0108-04

作者简介: 洪宇超(1996—), 男, 硕士研究生, 主要从事岩土工程方面的研究。E-mail: hong_yuchao@163.com。

Application of CNN-LSTM model based on spatiotemporal correlation characteristics in deformation prediction of excavation engineering

HONG Yu-chao^{1,2}, QIAN Jian-gu^{*1,2}, YE Yuan-xin³, CHENG-Long⁴

(1. Department of Geotechnical Engineering, Tongji University, Shanghai 200092, China; 2. Key Laboratory of Geotechnical and Underground Engineering of Ministry of Education, Tongji University, Shanghai 200092, China; 3. Shanghai Chengtou Water Group Co., Ltd., Shanghai 200002, China; 4. SGIDI Engineering Consulting Group Co., Ltd., Shanghai 200093, China)

Abstract: In order to predict the complex time series in excavation engineering field more accurately, a combined neural network model of CNN and LSTM is proposed, which takes the multi-dimensional time series composed of monitoring data from multiple monitoring points as the input. Firstly, the CNN is used to extract the spatial features of the input monitoring data, and the multiple time series composed of spatial features are the output. Secondly, the LSTM is used to learn the time series and predict the future state of the spatial features. Finally, the spatial features are integrated through the fully connected layer, and the predicted monitoring values are the output. This method is used to predict the ground settlement of the deep excavation of Yunling shaft in Shanghai. The results show that the accuracy of the combined model considering temporal and spatial correlation is higher than that of the single LSTM model considering temporal correlation only.

Key words: excavation; deformation prediction; time series modeling; CNN network; LSTM network

0 引 言

随着城市化进程的推进, 基坑工程向更深、更复杂的趋势发展, 为了保证周边环境安全, 基坑变形的现场监测和预报已成为基坑工程的重要内容。传统的理论分析、数值模拟等方法虽然理论上可以实现变形的预测, 但是岩土工程的变形机理复杂, 涉及的影响因素众多, 这类方法无法全面考虑^[1]。

近年来, 基于数据分析的时间序列建模方法被逐渐应用于岩土工程领域。其中灰色预测模型对样本数据量要求低, 但对于非线性序列的预测效果较差^[2];

神经网络具有较强的非线性映射能力, 但存在网络结构难以确定、容易陷入局部最优、样本数据量要求高等缺点^[3]; 遗传算法、粒子群算法等优化算法与神经网络结合的组合模型改善了神经网络的性能, 但仍然存在数据量要求高、泛化能力差的问题^[4]。

基金项目: 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项目(22120190220); 国家自然科学基金项目(51578413)

收稿日期: 2021-08-13

*通信作者(E-mail: qianjiangu@tongji.edu.cn)

现有方法在预测时都以单测点的监测数据作为输入变量, 只关注数据在时间维度上的关联性, 而忽略了邻近监测点之间空间维度上的关联性。实际工程会设置大量的监测点, 如何充分利用多个监测点的监测数据以提高预测精度是值得进一步研究的问题。针对上述不足, 本文提出运用卷积神经网络与长短期记忆神经网络 (CNN-LSTM) 结合的组合模型, 考虑监测数据在时间维度和空间维度上的关联性, 对基坑工程多维序列进行预测。该方法在上海云岭超深基坑工程的地表沉降实际监测数据预测中取得了令人满意的效果。

1 CNN-LSTM 模型

1.1 卷积神经网络 (CNN)

卷积神经网络 (convolutional neural networks) 是一类包含卷积运算的前馈神经网络。CNN 通过对数据的卷积和池化操作, 提取数据之间的相互关系, 可以用少量参数表达数据的空间特征, 具有优秀的高维特征提取能力, 被广泛用于图像处理、计算机视觉等问题。CNN 网络的核心结构如图 1 所示。卷积层通过设置卷积核, 对输入数据按式 (1) 进行离散卷积运算, 提取输入数据的空间特征。池化层通过对卷积核内的数据进行取最大值、取平均值等操作, 实现数据的降采样, 即去除杂余信息, 保留关键特征。




图 1 CNN 网络核心结构示意图

Fig. 1 Structure of convolutional neural networks

$$y_{i,j} = \sigma(W_k \otimes x_{i,j} + b_k) \quad (1)$$

$$W_k \otimes x_{i,j} = \sum_{m=0}^{a-1} \sum_{n=0}^{b-1} w_{m,n} \times x_{i+m,j+n} \quad (2)$$

式中 x_{ij} 为卷积层的输入数据; y_{ij} 为卷积层的输出数据; \otimes 为离散卷积运算; W_k 和 b_k 分别为第 k 个卷积核的权重系数和偏置参数; σ 为神经元的激活函数; a, b 为卷积核的尺寸参数。

1.2 长短期记忆神经网络 (LSTM)

LSTM 神经网络 (long short-term memory neural network) 是循环神经网络 RNN (recurrent neural network) 的一种变体。LSTM 神经网络通过设置特殊的“门”结构, 可以有选择性地记忆长短期信息, 解决了 RNN 结构的长时间依赖问题, 在时序数据的预测问题上表现优异。LSTM 单元结构如图 2 所示。




图 2 LSTM 结构示意图

Fig. 2 Structure of LSTM

1.3 CNN-LSTM 模型

卷积神经网络 CNN 与循环神经网络 LSTM 结合的 CNN-LSTM 神经网络结构如图 3 所示。CNN 部分以多个监测点的标准化后的历史数据构成的多维时间序列 $X_{t,n}$ 作为输入数据。 $X_{t,n}$ 是一个二维矩阵, 一行表示某一时刻 n 个监测点的监测值, 一列表示某一监测点在时间步长 t 内的监测值。将该序列输入 CNN 部分后, 进行卷积运算, 提取空间特征, 输出多个由空间特征组成一维序列。LSTM 部分以 CNN 网络输出的一维序列作为输入数据。LSTM 对序列进行回归预测, 输出多个空间特征的预测值。最后通过全连接层整合空间特征预测值, 输出监测数据的预测值。

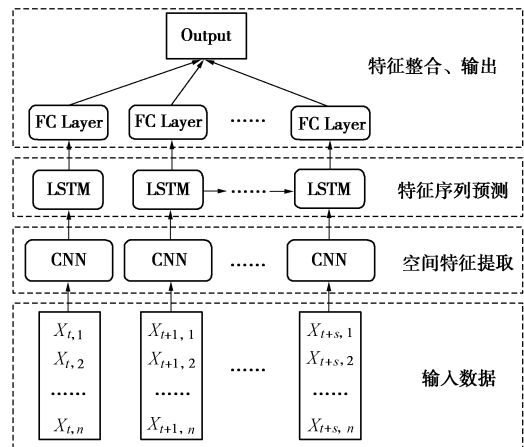


图 3 CNN-LSTM 模型结构示意图

Fig. 3 Structure of CNN-LSTM model

2 工程实例验证

2.1 工程概况

云岭竖井基坑是上海苏州河深隧工程的一部分。竖井基坑为圆形, 深度约 60 m, 支护结构为 1500 mm 地下连续墙。基坑位于上海软土地区, 且基坑开挖深度范围内的深层土体力学特性尚不明确, 给基坑周边地表沉降的计算带来了困难。为了实时地进行动态化施工反馈, 在基坑周边布置了大量监测点。基坑周边对称布置 DB-1、DB-2、DB-3 和 DB-4 四条测线, 其中 DB-4 的监测点在施工中被破坏, 监测数据不完整。

本文选取其余三条测线的第一个测点 (DB1-1、

DB2-1、DB3-1) 从 2020 年 7 月 27 日至 2020 年 12 月 28 日, 共计 155 组数据, 前 135 组数据用于训练模型, 后 20 组数据用于验证模型的精度。

2.2 监测数据建模预测

现在以 DB1-1 测点的监测数据作为预测目标, 详细描述如何利用 CNN-LSTM 模型进行时序预测。

(1) 数据预处理

现场采集的数据受各种因素的干扰, 包含大量噪声^[5]。为避免拟合噪声, 在导入模型训练前, 对原始数据进行降噪处理。降噪后数据如图 4 所示。此外, 不同监测点的监测数据在绝对值上相差较大, 为了避免模型训练时的梯度方向被某一监测点的数据控制, 本文按式 (3) 标准化数据, 标准化后的数据符合均值为 0, 方差为 1 的正态分布。

$$x'_{t,i} = \frac{x_{t,i} - \mu_i}{\sigma_i}, \quad (3)$$

式中, μ_i , σ_i 为第 i 个测点全部监测数据的均值和方差。




图 4 降噪后数据示意图

Fig. 4 Curves of data after noise reduction

(2) CNN-LSTM 模型构建

本文基于 Python 的 Keras 库构建 CNN-LSTM 模型。第一层为卷积层, 卷积核个数为 80, 即提取 80 个空间特征, 卷积核尺寸为 1×3 ; 第二层为 LSTM 层, LSTM 层的神经元个数对网络的性能影响最大, 因此取初始值 80, 在训练过程中优化; 第三层为 Dense 层。需要指出的是由于本文选取的数据集在空间维度上只有 3 个监测点, 数据规模不大, 不设置池化层可以取得更好的效果。

(3) 训练样本构造与模型训练

本文采用“5+1”的样本构造模式, 即以 3 个测点前 5 天的监测数据作为输入数据, 输入数据为 5×3 的二维矩阵, 第 6 天 DB1-1 测点的监测数据作为输出数据。训练集共 135 组监测数据构造 130 组训练样本。训练优化器选择 Adam, 迭代次数 epoch 取 100 次, 损失函数为均方误差 MSE, 模型收敛。

(4) 监测值预测

最后利用训练完毕的模型对最后 20 组数据进行

滚动预测。考虑到前期数据的降噪预处理, 本文同时对噪声采用统计学模型 ARMA 进行分析、预测后, 与 CNN-LSTM 的输出结果合并, 作为最终预测值。为了验证 CNN-LSTM 模型的预测效果, 本文同时单独采用 LSTM 模型进行预测, 两种方法的结果和预测相对误差对比如图 5、6 所示。对 DB2-1、DB3-1 测点采用同样方法的预测结果和误差如图 7~10 所示。

图 5 和图 6 表明, CNN-LSTM 组合模型的预测结果与单一 LSTM 模型相比, 在所有观测时间点上更接近实测值, 但是两种模型预测结果的趋势仍然与实测值有明显不同, 这是由于噪声的预测模型难以拟合本例的数据。采用 CNN-LSTM 模型时, 预测结果的相对误差介于 $0.01\% \sim 3.44\%$ 之间, 平均值为 2.00% , 而 LSTM 模型相对误差介于 $0.02\% \sim 4.36\%$, 平均值为 2.84% , 说明前者预测精度更高, 效果更为理想。




图 5 DB1-1 测点监测值与预测值

Fig. 5 Measured and predicted values of DB1-1




图 6 DB1-1 测点预测相对误差对比

Fig. 6 Comparison of prediction relative errors of DB1-1

图 7~10 表明, DB2-1 测点和 DB3-1 测点的预测结果与 DB1-1 测点基本一致, CNN-LSTM 模型的预测结果更接近实测值。采用 CNN-LSTM 模型, DB2-1 测点、DB3-1 测点的预测平均相对误差分别为 0.93% 、 1.35% , 而采用 LSTM 模型的平均相对误差分别为 1.84% 和 1.69% , 综合来看, CNN-LSTM 模型取得了更好的效果。

需要指出的是, CNN-LSTM 的精度优化得益于测点之间的空间关联度, 选择测点时可综合测点的几何分布和历史监测曲线两方面判断。本例测点对称分布于基坑周边, 且历史监测曲线的趋势也具有 consistency。




图 7 DB2-1 测点监测值与预测值

Fig. 7 Measured and predicted values of DB2-1




图 8 DB2-1 测点预测相对误差对比

Fig. 8 Comparison of prediction relative errors of DB2-1




图 9 DB3-1 测点监测值与预测值

Fig. 9 Measured and predicted values of DB3-1




图 10 DB3-1 测点预测相对误差对比

Fig. 10 Comparison of prediction relative errors of DB3-1

3 结 论

本文在已有岩土工程时间序列预测方法的基础上,提出可以考虑监测数据空间关联性的 CNN-LSTM 组合模型。通过基于上海云岭竖井超深基坑工程现场地表沉降监测数据的工程实例验证,得出以下结论:

(1)多个监测点的监测数据构成一个多维时间序

列,不同监测点数据之间的空间关联特征可以用 CNN 网络中的卷积运算提取。

(2) CNN-LSTM 模型采用 CNN 网络提取多维时间序列的空间特征, LSTM 网络多空间特征序列进行回归预测。工程实例表明,该模型在预测精度上相较于基于单测点数据的 LSTM 模型具有更高的精度。

(3) 本文预测的多维时间序列的均为地表沉降,即同一类监测数据。工程现场的不同监测项目之间,理论上也可采用 CNN-LSTM 模型建模预测,如何将该模型推广到任意监测项目组成的多维时间序列是值得深入研究的问题。

参考文献:

- [1] 龚 剑, 王旭军, 赵锡宏. 深大基坑首层盆式开挖对基坑变形影响分析[J]. 岩土力学, 2013, **34**(2): 439 - 448. (GONG Jian, WANG Xu-jun, ZHAO Xi-hong. Analysis of effect of first-level basin excavation on deformation of deep and large foundation pits[J]. Rock and Soil Mechanics, 2013, **34**(2): 439 - 448. (in Chinese))
- [2] 于怀昌, 刘汉东, 丁仁伟. 深基坑降水过程中周围建筑物沉降的系统预测[J]. 岩石力学与工程学报, 2004, **23**(22): 3905 - 3909. (YU Huai-chang, LIU Han-dong, DING Ren-wei. Forecasting building settlement around dewatering deep foundation pit by grey system theory[J]. Chinese Journal of Rock Mechanics and Engineering, 2004, **23**(22): 3905 - 3909. (in Chinese))
- [3] 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 - 96.
- [4] 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 Yan-jie, XUE Ya-dong, YUE Lei, et al. Displacement prediction of deep foundation pit based on genetic algorithms and BP neural network[J]. Chinese Journal of Underground Space and Engineering, 2015, **11**(S2): 741 - 749. (in Chinese))
- [5] 郭 健, 查吕应, 庞有超, 等. 基于小波分析的深基坑地表沉降预测研究[J]. 岩土工程学报, 2014, **36**(增刊 2): 343 - 347. (GUO Jian, ZHA Lü-ying, PANG You-chao, et al. Prediction for ground settlement of deep excavations based on wavelet analysis[J]. Chinese Journal of Geotechnical Engineering, 2014, **36**(S2): 343 - 347. (in Chinese))

(编辑: 明经平)