

<https://doi.org/10.3799/dqkx.2021.250>



基于长短时记忆网络的深基坑变形安全风险预警

夏天, 成诚, 庞奇志*

中国地质大学工程学院, 湖北武汉 430074

摘要: 为了预防深基坑施工安全事故, 提出了一套基于监测数据的风险预警标准, 建立了基于长短时记忆网络(Long Short-Term Memory, LSTM)的深基坑变形安全风险预警模型. 依托实际深基坑工程项目, 将风险预警模型应用其中, 对基坑各监测项目的变形量进行短期的预测, 预测数据与实际数据最大误差为 5.04%, 最小误差为 0.04%, 平均相对误差为 2.41%, 证明该模型的预测效果良好. 表明基于 LSTM 的深基坑变形安全风险预警模型在基坑变形预测方面有着良好的精确性和优越性, 可以为基坑工程的安全性判断与风险管控提供可靠的保障.

关键词: 深基坑; 基坑安全; 变形量预测; 长短时记忆; 风险预警; 安全工程; 工程地质学.

中图分类号: P642

文章编号: 1000-2383(2023)10-3925-07

收稿日期: 2021-11-05

Safety Risk Warning of Deep Foundation Pit Deformation Based on LSTM

Xia Tian, Cheng Cheng, Pang Qizhi*

Faculty of Engineering, China University of Geosciences, Wuhan 430074, China

Abstract: In order to prevent deep foundation pit construction safety accidents, a set of risk warning standards based on monitoring data is proposed, and a deep foundation pit deformation safety risk warning model based on long short-term memory (LSTM) was established. Relying on the actual deep foundation pit engineering project, the risk warning model is applied to it to make short-term predictions of the deformation of each monitoring item of the foundation pit. The maximum error between the predicted data and the actual data is 5.04%, the minimum error is 0.04%, and the average relative error is 2.41%, which proves that the prediction effect of the model is good. It shows that the LSTM-based deep foundation pit deformation safety risk early warning model has good accuracy and superiority in the prediction of foundation pit deformation, and can provide a reliable guarantee for the safety judgment and risk management of foundation pit engineering.

Key words: deep foundation pit; foundation pit safety; deformation prediction; long-term and short-term memory; risk warning; safety engineering; engineering geology.

0 引言

深基坑工程在新时代背景下展现出新特点, 基坑开挖深度越来越大, 甚至达到 40 m 深; 基坑开挖

面积越来越大, 甚至达到 5 万 m²; 基坑建设紧贴建设红线; 基坑周围建筑物、地下管线和构筑物多, 周边环境复杂. 这些因素使得深基坑工程施工事故的发生概率远远高于建筑物或构筑物主体结构施工事

作者简介: 夏天(1997—), 女, 硕士研究生, 安全科学与工程专业. E-mail: 295016342@qq.com

* **通讯作者:** 庞奇志, E-mail: 644959413@qq.com

引用格式: 夏天, 成诚, 庞奇志, 2023. 基于长短时记忆网络的深基坑变形安全风险预警. 地球科学, 48(10): 3925-3931.

Citation: Xia Tian, Cheng Cheng, Pang Qizhi, 2023. Safety Risk Warning of Deep Foundation Pit Deformation Based on LSTM. *Earth Science*, 48(10): 3925-3931.

故的发生概率.因此,设法挖掘基坑变形数据变化的内在规律性,对导致基坑变形的各因素进行定量研究,建立合适的变形预测模型,反映基坑真实的变形情况和定量预测基坑未来的变形趋势,具有相当重要的现实意义.

在国外,人工神经网络理论最早是被 Ghabousi and Sidarta(1997)应用于深基坑稳定性研究中,提出了岩体材料的本构模型,之后进行完善用于岩土工程中.与此同时,Hashash and Whittle(1996)出于保护基坑周围建筑设施的目的,借助 MIT-E3 模型对深基坑工程开挖性状进行预测.而 van Starveren and Peters(2004)借助先进的监测系统监测地层的变形情况,分析风险点位与监测数据之间的变化关系,确定了基坑工程的监测风险.

在国内,有关基坑变形的研究也逐渐从传统模型向新型技术发展.李钦(2013)使用神经网络进行预测,建立了基于 BP 神经网络和径向基神经网络两种模型进行预测,结果表明径向基神经网络收敛速度比 BP 神经网络更快,总体非线性逼近能力比 AR 模型强.李彦杰等(2015)、马琳(2018)、陈艳茹(2018)、宋楚平(2019)等研究发现 BP 神经网络存在局部最小的问题以及各指标权重初值设定的随机化问题,为提高深基坑变形预测的精度,借助遗传算法对模型权重初值进行优化.近年来随着机器学习理论与技术的快速发展,各行各业逐渐开始引用机器学习算法与技术去解决实际问题,有必要针对工程领域尤其是基坑变形预测领域对其适用性及有效性进行分析、研究与验证.

笔者拟利用 LSTM 强大的自学习能力和时序数据处理能力,结合监测数据与风险评价技术,建立深基坑变形安全风险预警模型,以此预测基坑支护结构、周边道路、地下管线等结构体的变形,结合基于监测数据的风险评价方法,评价单个风险指标和基坑整体的安全状态,动态评价深基坑安全风险并确定预警等级,从而为深基坑施工提供一个可靠的安全保障.

1 LSTM 简述

1.1 LSTM 原理

1.1.1 循环神经网络(RNN) 循环神经网络是内部将隐含层节点进行特殊处理的人工神经网络,相比于人工神经网络或 BP 神经网络等结构,RNN 隐含层节点之间是互相连接的,并且其隐含层节点增

加了自反馈连接,可以对上一隐含层传入的信息进行记忆.因此 RNN 某一层的隐含层节点的输入包括两个部分:当前输入节点的输入和上一层隐含层节点的输出.正是因为这种网络结构,使得 RNN 神经网络具备信息记忆功能,因此可以根据时序数据间的依赖关系进行拆分,按照不同时段进行组织并预测时间序列结果.

1.1.2 长短时记忆神经网络(LSTM) 长短时记忆网络(long-short term memory network, LSTM)是一种特殊的循环神经网络,是为了解决一般的 RNN 存在的长期依赖问题而专门设计出来的,各种研究表明,LSTM 更能精确地描述时间序列的长期依赖关系,并能有效地规避 RNN 所存在的梯度消失等问题(王鑫等,2018).

1.2 LSTM 传播过程

LSTM 循环神经网络信号传播过程与传统神经网络类似,同样分为两个过程:输入信号的前向传播与误差信号的反向传播(Werbos, 1990).前向传播过程是指长度为 T 的输入序列 $\{x_1, x_2, \dots, x_t, \dots, x_T\}$ 按照时间步长经隐含层递归计算产生输出的过程,而反向传播过程是指误差信号沿着输入信号相反的方向传播并逐层调整权重的过程.LSTM 网络的前向与反向传播过程,组成了网络的整体训练过程.

2 深基坑变形安全风险预警模型构建

2.1 安全风险预警指标体系建立

深基坑变形安全风险预警是对基坑主体支护结构和基坑施工对周边环境进行风险评价,确定风险等级以实现预警的技术.然而在事故发生前并非所有的监测项目都会有所反映,同时监测数据的变化具有一定离散性,其与基坑之间的关系存在很多不确定性.因此在选择评价指标时需遵循以下两个原则:(1)所选择的监测项目监测数据必须能够真实地反映此时基坑的安全状态,且相关性必须明确;(2)该项目监测技术必须是成熟的,且保证数据质量可靠充足.

根据已有的研究基础加以借鉴相关的施工规范与标准,综合各方面分析,建立安全风险预警指标体系如表 1 所示.

2.2 基于监测数据的风险量转化方法

采用一种将监测数据转换为风险量的方法,用以评价基坑的安全状态并实现风险分级.此处借鉴

表 1 深基坑变形安全风险预警指标体系

Table 1 Deep foundation pit deformation safety risk warning index system

目标	一级指标	二级指标(部分可选)
深 基 坑 变 形 安 全 风 险 预 警	主 体 结 构	(坡)顶水平位移
		墙(坡)顶竖向位移
		围护墙深层水平位移
		土体深层水平位移
		墙(桩)体内力
		支撑内力
		立柱竖向位移
		锚杆、土钉拉力
		土层分层竖向位移
		坑底隆起
		土压力
		孔隙水压力
周 边 环 境	周 围 建 (构)筑物变形	地下水位
		墙后地表竖向位移
		周围建(构)筑物变形
		周围地下管线变形

表 2 风险等级划分标准及权重系数

Table 2 Risk classification standards and weight coefficients

α 值	<0.3	0.3~0.7	0.7~0.9	0.9~1.2	>1.2
风险等级 r	一级	二级	三级	四级	五级
权重系数 γ	0.018	0.050	0.135	0.368	1.000

彭铭(2008)在动态风险管理软件设计中提出的基于监测数据的动态风险评价方法,将工程监测项目作为风险指标,其监测数据转化为风险量的方法.该方法结合累计值和变化率对某个监测项目进行评价,其具体实现方式为:设第 i 次监测某个监测项目当前变形累计值为 x_i ,变化速率为 Δx ,累计变化速率的平均值为 $\Delta \bar{x}$, x_w 为预警值,则该监测项目的风险量 α 为:

$$\alpha = \omega_1 \times \omega_2, \tag{1}$$

式中: ω_1 为监测数据累计值指标,衡量监测数据累计值反映的风险信息,通过如下公式求得:

$$\omega_1 = \frac{x_i}{x_w}, \tag{2}$$

ω_2 为监测数据速率值指标,衡量监测数据速率稳定性反映的风险信息,通过如下公式求得:

$$\omega_2 = \begin{cases} 0.8, & \sigma = 0 \\ 0.2\sigma + 0.8, & 0 < \sigma < 2, \\ 1.2, & \sigma \geq 2 \end{cases} \tag{3}$$

式中: σ 为监测数据速率值的均方差,由下面的公式

求得:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n \left[\frac{\Delta x_i - \Delta \bar{x}}{\Delta \bar{x}} \right]^2}{n-1}}. \tag{4}$$

由此,通过监测项目的监测数据将其转化为对应的风险量,根据风险量判定风险等级,并采取对应的风险控制措施.

2.3 数据处理与风险评价

2.3.1 样本训练与预测 基坑变形量的预测是风险预警的根本,LSTM神经网络的训练过程即是对监测数据不断拟合,及时更新阈值及权值,逼近期望输出值的过程.最终借助最优LSTM模型对基坑变形量进行预测,为后续的基坑风险评价提供数据基础.

2.3.2 风险评价与风险等级判定 在某一时刻,各监测项目可能处于不同的风险等级,不同风险等级必然对基坑整体的安全状态影响程度不同,因此在对基坑整体安全状态评价时,需要赋予各风险等级不同的权重系数,风险等级越高,其对应的权重系数应该越大.权重系数计算公式如下:

$$\gamma_{i,r} = \frac{e^r}{e^5}, \tag{5}$$

式中: e 为自然常数, r 为风险等级, $\gamma_{i,r}$ 表示第 i 个监测项目在 r 风险等级情况下的权重系数.

这里,参考彭铭在“基于监测数据的动态管理模块研究”中提到的借助《地铁及地下工程建设风险管理指南》制定有关 α 和 r 风险等级划分标准及对应的权重系数 γ 表,如表 2 所示.

通过以上风险量转化与风险等级判定方法,可以计算单个监测项目的风险量 α ,确定其风险等级 r 并获得相应的权重系数 γ ,综合基坑工程各监测项目可得基坑整体的安全状态,由下面公式求得:

$$\alpha_t = \frac{\sum_{i=1}^m \gamma_{i,r} \alpha_i}{\sum_{i=1}^m \gamma_{i,r}}, \tag{6}$$

式中: α_t 表示基坑的整体安全状态, α_i 表示第 i 个监测项目风险量, $\gamma_{i,r}$ 表示第 i 个监测项目风险等级为 r 时的权重系数, m 为风险指标数量.

由此,基于监测数据的动态风险评价方法包含两个方面:(1)某个监测项目的变形累计值和变化率是否超过预警值,其可通过LSTM网络得出预测值进行直观的判定;(2)单个监测项目的风险量和基坑整体的安全状态以及风险等级.基坑的安全性

评价终极目的是为基坑的安全控制提供决策,基坑工程风险接受准则如表 3 所示.

3 应用研究

3.1 工程概况

拟建场地位于 X 市工业园区唯亭街道珠泾路西侧,青青家园北侧,场地南侧为规划跨春路,西侧为规划莲心街.场地地上主体结构采用桩基础时,桩侧土分布较稳定,根据本地区经验,一般不会产生过量的不均匀沉降、倾斜等变形,本工程地基变形以垂直沉降为主.

3.2 风险预警指标体系

综合现场监测和风险源分析,由此可建立该基坑安全风险预警指标体系如图 1 所示.该指标体系以深基坑变形安全风险预警为目标,一级指标分为主体结构和周边环境两类.

主体结构下属围护桩顶部竖向位移和水平位移、立柱桩竖向位移、支撑轴力和围护桩深层水平位移 5 个二级指标,周边环境下属周边管线竖向位移、周边道路竖向位移、周边地表竖向位移、坑外地下水

下水位 4 个二级指标.

3.3 数据准备

该基坑附近情况较为复杂,需要大量的监测工作,结合工程实际需求与安全风险预警指标体系,搜集各个指标点位数据,截至数据采集日期 2019 年 8 月 17 日,选取其中各指标监测点位中变形量最大的作为数据样本,即周边地表竖向位移(DB9-1)、周边管线竖向位移(J3)、周边道路竖向位移(DL-1)、坑外地下水水位(SW-1)、围护桩顶部竖向位移和水平位移(B1)、围护体深层水平位移(P1)、立柱桩竖向位移(LZ12)、支撑轴力(ZL2-1).将数据分为训练样本集和预测结果对比样本集.

在实际工程项目中训练样本应该是截至当前的所有数据,然而这里为了分析研究模型的准确性,需要提取部分数据作结果对比,因此将实际数据拆分为训练样本集与预测结果对比样本集.预测结果对比样本集将分为 3 d、7 d 和 10 d 样本,为保证训练样本集的统一,即选取预测样本集中 2019-04-19~2019-08-04 数据作为训练样本,预测结果对比样本集中 2019-08-05~2019-08-15 数据作为未来 10 d 预测结果对比样本集.

3.4 训练与预测

由于所有的监测项目数据都是时序数据,为了将时序数据切分形成一组组输入与输出的训练样本,需要对训练样本集进行切分并组织.本文采用与之前数据进行关联,即利用前 N 天数据作为输入,第 $N+M$ 天数据作为输出的方法,最大限度地避免其他因素对变形预测精度的影响.其组织结构图 ($M=1$) 如图 2 所示.

表 3 风险接受准则

Table 3 Risk acceptance criteria

等级	接受准则	控制方案
一级	可忽略	日常管理和审视
二级	可容许	需注意,加强日常管理审视
三级	可接受	引起重视,需防范,监控措施
四级	不可接受	需决策,指定控制、预警措施
五级	拒绝接受	立即停止,整改,规避或启动预案

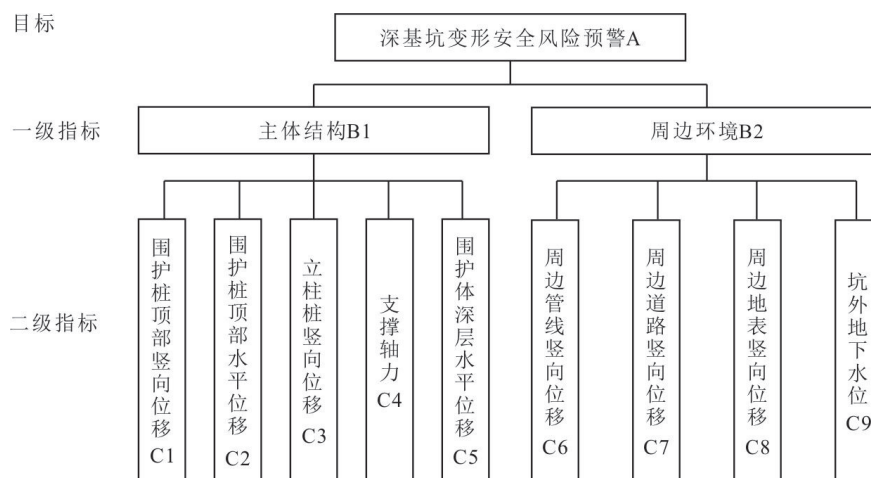


图 1 基坑安全风险预警指标体系

Fig.1 Pre-warning indicator system for safety risks of foundation pits




图 2 训练样本组织结构

Fig.2 Organization structure of training samples




图 3 DB9-1 的 LSTM 模型损失函数

Fig. 3 DB9-1's LSTM model loss function graph




图 4 DB9-1 拟合曲线

Fig 4 DB9-1 fitting curve

本文所使用的仿真环境是借助 Python 3.7.0 建立的,使用其开源的 Keras 深度学习框架,并以 tensorflow 作为后端 (backend) 对训练样本集中的数据集进行训练建模.其中,模型的权重调优选择 Adam 优化器,学习率为 0.01,期望误差为 0.01,最大迭代次数为 500,并允许连续 5 次误差不下降时提前结束训练.为训练出理想的预测模型,需要不断调整 LSTM 神经网络结构.本文采用试错法,不断调整 N 与 M 的大小、隐含层节点数,最终确定 N 为 2, M 为 1,隐含层节点数为 10 时,训练效果最佳.另外,数据归一化区间为 $[0, 1]$,误差函数采用均方误差 (MSE),期望误差为 0.01,迭代次数最大为 500.对

2019-08-05~2019-08-15 的数据进行预测,各点位预测结果如表 4 所示.

3.5 结果分析

为详细分析 LSTM 模型预测结果,选取点位 DB9-1 进行模拟分析,按照以上步骤,对 DB9-1 训练样本数据进行模拟,如图 3 所示为 DB9-1 训练的损失函数图.

损失函数是通过将拟合结果映射为非负实数,用以表示该项数据的误差函数.因此,损失函数在实际应用中用以表示样本训练集的训练结果与实测结果的误差,损失函数越小则表明模型的训练效果越好,当损失函数小于期望误差时说明模型训练成功.而训练样本在训练过程中的拟合曲线如图 4 所示.

由此,将已训练好的模型,对 DB9-1 未来 10 d 的变形量进行预测,并将监测数据与预测值进行对比,结果如下表 5 所示.

由上表可知,DB9-1 点位的预测结果,最大误差为 5.04%,最小误差为 0.04%,平均相对误差为 2.41%,证明该模型的预测效果较好,该点位监测数据与预测值曲线对比如图 5 所示.

拟采用 2.2 节提出的基于监测数据的风险量转化方法,计算各个风险指标的风险量,判定各个监测项目的风险状态与风险等级,再通过拟合各个风险指标风险量,确定基坑整体的安全状态.

通过研究,得到未来 10 d 内各监测项目的预测数据,通过 2.2 节提出的风险量转化方法,计算各监测项目当天的风险量,并最终拟合基坑整体的安全状态.由于数据量较多,这里以点位 DB9-1 为例,由公式 (1)~(4) 计算单个监测项目的风险量,将其与表 2 中的监测风险等级进行对比并划分,对比分析实测风险量与预测风险量,其对比结果如表 6 所示.可见,实测值与预测值计算得到的风险等级均为四级,一方面表明基于 LSTM 模型的预测结果误差处于可接受范围内,另一方面应对该监测项目加强管控措施,并制定相应的预警方案.

采取相同的方法计算各个监测项目的预测风险量.结果表明,基坑整体安全状态处于四级风险预警等级,需制定相应的控制与预警措施.

4 结论

(1)对基于 LSTM 网络的变形预测方法进行研究,综合基于监测数据的风险预警标准,建立了基

表 4 所有点位 LSTM 预测结果

Table 4 LSTM prediction results of all points

日期	DB9-1	J3	DL-1	SW-1	B1(竖向)	B1(水平)	P1	LZ12	ZL2-1
2019-08-05	-26.20	-3.35	-8.68	-833.74	11.27	5.99	29.92	12.26	3 455.46
2019-08-06	-26.19	-3.64	-8.65	-831.61	11.31	5.99	29.93	12.22	3 523.61
2019-08-07	-26.19	-3.55	-8.72	-860.73	11.33	5.99	29.93	12.28	3 549.88
2019-08-08	-26.18	-3.30	-8.69	-868.82	11.31	6.23	29.93	12.29	3 538.18
2019-08-09	-26.19	-3.14	-8.72	-876.15	11.28	6.23	29.93	12.24	3 230.88
2019-08-11	-26.19	-3.09	-8.72	-882.62	11.28	6.23	29.94	12.24	4 265.69
2019-08-12	-26.18	-3.04	-8.66	-875.40	11.27	6.23	29.95	12.20	3 999.38
2019-08-13	-26.18	-3.11	-8.70	-816.85	11.29	6.23	29.95	12.18	4 015.25
2019-08-14	-26.17	-3.22	-8.75	-751.35	11.24	6.23	29.95	12.15	4 152.56
2019-08-15	-26.17	-3.46	-8.75	-799.07	11.24	6.40	29.96	12.15	4 821.04

表 5 DB9-1 监测数据与预测值

Table 5 DB9-1 monitoring data and predicted values

日期	实测值 (mm)	预测值 (mm)	绝对误差 (mm)	相对误差 (%)
2019-08-05	-25.36	-26.20	0.84	3.31
2019-08-06	-25.94	-26.19	0.25	0.96
2019-08-07	-26.58	-26.19	0.39	1.47
2019-08-08	-26.89	-26.18	0.71	2.64
2019-08-09	-26.20	-26.19	0.01	0.04
2019-08-11	-26.20	-26.19	0.01	0.04
2019-08-12	-26.88	-26.18	0.70	2.60
2019-08-13	-26.98	-26.18	0.80	2.97
2019-08-14	-27.56	-26.17	1.39	5.04
2019-08-15	-27.56	-26.17	1.39	5.04

表 6 点位 DB9-1 实测数据与预测数据风险量对比

Table 6 Comparison of measured data and predicted data risk of DB9-1 at points

日期	实测数据			预测数据		
	累积 变形量 (mm)	风险 量 等级	风险 等级	累积变形量 (mm)	风险 量 等级	风险 等级
2019-08-05	-25.36	0.90	四级	-26.2	0.93	四级
2019-08-06	-25.94	0.92	四级	-26.19	0.93	四级
2019-08-07	-26.58	0.94	四级	-26.19	0.93	四级
2019-08-08	-26.89	0.95	四级	-26.18	0.92	四级
2019-08-09	-26.2	0.92	四级	-26.19	0.92	四级
2019-08-11	-26.2	0.92	四级	-26.19	0.92	四级
2019-08-12	-26.88	0.94	四级	-26.18	0.92	四级
2019-08-13	-26.98	0.95	四级	-26.18	0.92	四级
2019-08-14	-27.56	0.97	四级	-26.17	0.92	四级
2019-08-15	-27.56	0.96	四级	-26.17	0.91	四级




图 5 点位 DB9-1 累积变形量实测数据和 LSTM 模型预测数据曲线对比

Fig.5 Comparison of the measured data of the cumulative deformation of the point DB9-1 and the predicted data curve of the LSTM model

于 LSTM 的深基坑变形安全风险预警模型,并结合工程实例,对预测模型的有效性和准确性进行验证,通过结果对比分析得出,文中选用点位 DB9-1 作为结果对比分析样本,观察点位训练数据的拟合曲线及最终预测数值对比,基于 LSTM 的变形预测方法对原始数据的拟合速度较快,精度较高。

(2) 基于 LSTM 循环神经网络模型在基坑变形预测方面有着良好的精确性和优越性,在工程中可以采取该方法对基坑各监测项目的累积变形量进行预测,结合监测数据转化为风险量方法,确定基坑各监测项目以及基坑整体的风险等级,结合科学合理的评判准则,从而为基坑工程的安全性判断与风险管控提供可靠的保障。

References

- Chen, Y. R., 2018. Application of Intelligent Algorithm Based on Genetic Algorithm and Extreme Learning Machine to Deformation Prediction of Foundation Pit. *Tunnel Construction*, 38(6): 941—947(in Chinese with English abstract).
- Ghaboussi, J., Sidarta, D. E., 1997. New Method of Material Modeling Using Neural Networks. 6th International Symposium On Numerical Models in Geotechnics, 393—400.
- Hashash, Y. M. A., Whittle, A. J., 1996. Ground Movement Prediction for Deep Excavations in Soft Clay. *Journal of Geotechnical Engineering*, 122(6): 474—486. [https://doi.org/10.1061/\(asce\)0733-9410\(1996\)122:6\(474\)](https://doi.org/10.1061/(asce)0733-9410(1996)122:6(474))
- Li, Q., 2013. Application Research of Generalized Regression Neural Network in Deep Foundation Pit Deformation Monitoring (Dissertation). Central South University, Changsha(in Chinese with English abstract).
- Li, Y.J., Xue, Y.D., Yue, L., et al., 2015. Displacement Prediction of Deep Foundation Pit Based on Genetic Algorithms and BP Neural Network. *Chinese Journal of Underground Space and Engineering*, 11(S2): 741—749 (in Chinese with English abstract).
- Ma, L., 2018. Study of Deformation Law of Deep Foundation Pit Based on Chaotic Progressive Prediction Model and Trend Test. *Tunnel Construction*, 38(6): 934—940 (in Chinese with English abstract).
- Peng, M., 2008. Research and Development of Dynamic Risk Management Software (TRM2.0) for Shield Tunnel Construction (Dissertation). Tongji University, Shanghai(in Chinese with English abstract).
- Song, C.P., 2019. Improved BP Neural Network Method for Deformation Prediction of Deep Excavation. *Journal of Civil Engineering and Management*, 36(5): 45—49, 55 (in Chinese with English abstract).
- van Staveren, M. T., Peters, T. J. M., 2004. Matching Monitoring, Risk Allocation and Geotechnical Baseline Reports. *Engineering Geology for Infrastructure Planning in Europe*. Springer, Berlin, Heidelberg : 786—791. https://doi.org/10.1007/978-3-540-39918-6_87
- Wang, X., Wu, J., Liu, C., et al., 2018. Exploring LSTM Based Recurrent Neural Network for Failure Time Series Prediction. *Journal of Beijing University of Aeronautics and Astronautics*, 44(4): 772—784(in Chinese with English abstract).
- Werbos, P. J., 1990. Backpropagation through Time: What It Does and How to do It. *Proceedings of the IEEE*, 78(10): 1550—1560. <https://doi.org/10.1109/5.58337>

附中文参考文献

- 陈艳茹, 2018. 基于遗传算法和极限学习机的智能算法在基坑变形预测中的应用. *隧道建设(中英文)*, 38(6): 941—947.
- 李钦, 2013. 泛化回归神经网络在深基坑变形监测中的应用研究(硕士学位论文). 长沙: 中南大学.
- 李彦杰, 薛亚东, 岳磊, 等, 2015. 基于遗传算法—BP神经网络的深基坑变形预测. *地下空间与工程学报*, 11(增刊2): 741—749.
- 马琳, 2018. 基于混沌递进预测模型与趋势检验的深基坑变形规律研究. *隧道建设(中英文)*, 38(6): 934—940.
- 彭铭. 2008. 盾构隧道施工动态风险管理软件(TRM2.0)开发研究(硕士学位论文). 上海: 同济大学.
- 宋楚平, 2019. 一种改进的BP神经网络深基坑变形预测方法. *土木工程与管理学报*, 36(5): 45—49, 55
- 王鑫, 吴际, 刘超, 等, 2018. 基于LSTM循环神经网络的故障时间序列预测. *北京航空航天大学学报*, 44(4): 772—784.