

基于 Bayes-LSTM 的公路隧道围岩变形 预测方法研究

刘智¹, 李欣雨², 李震¹, 孔宪光², 常建涛²

(1. 中交第一公路勘察设计研究院有限公司, 陕西 西安 710076; 2. 西安电子科技大学, 陕西 西安 710065)

摘要:在公路隧道施工过程中,围岩的稳定性对隧道施工的影响较大。因此公路隧道围岩变形的监控量测与准确预测是保障隧道施工安全的关键。针对当前隧道围岩变形的预测精度较低以及泛化能力较差等问题,该文提出一种基于贝叶斯(Bayes)优化长短期记忆网络(LSTM)的方法,该方法首先对拱顶沉降和周边收敛的原始监测数据进行预处理,而后构建公路隧道拱顶沉降与周边收敛的初始LSTM模型,并利用Bayes优化模型中的超参数,最终得出预测结果。利用该模型对某公路隧道拱顶沉降和周边收敛进行预测,将预测结果以均方根误差为评价指标与神经网络(CNN)和支持向量回归(SVR)进行对比。预测拱顶沉降时,Bayes-LSTM模型的平均预测精度相较于CNN与SVR模型分别提高了1.0与1.26;预测周边收敛时,Bayes-LSTM模型平均精度相较于CNN与SVR分别提高了0.3与0.32。表明Bayes-LSTM模型的预测精度较高,同时其能在训练模型过程中对历史信息进行判断和取舍,极大地提高了时序数据处理的效率,为公路隧道围岩变形预测提供了新的思路和探索。

关键词:公路隧道;围岩变形;数据分析;LSTM;贝叶斯优化

中图分类号:U456.3

文献标志码:A

Prediction Method of Surrounding Rock Deformation of Highway Tunnels Based on Bayes-LSTM

LIU Zhi¹, LI Xinyu², LI Zhen¹, KONG Xianguang², CHANG Jiantao²

(1. CCCC First Highway Consultants Co., Ltd., Xi'an, Shaanxi 710076, China; 2. Xidian University, Xi'an, Shaanxi 710065, China)

Abstract: In the process of highway tunnel construction, the stability of surrounding rock has a great impact on tunnel construction. Therefore, the monitoring measurement and accurate prediction of surrounding rock deformation of highway tunnels are the keys to ensuring the safety of tunnel construction. In view of the low prediction accuracy and poor generalization ability of tunnel surrounding rock deformation, this paper proposed a Bayesian (Bayes)-based method to optimize the long-term and short-term memory (LSTM) network. The method first preprocessed the original monitoring data of crown settlement and peripheral convergence, then constructed the initial LSTM model of crown settlement and peripheral convergence of highway tunnels, and used the super parameters in the Bayes optimization model to obtain the prediction results. The model was used to predict the crown settlement and peripheral convergence of a highway tunnel, and the prediction results were compared with convolutional neural network (CNN) and support vector regression (SVR) using root mean square error as the evaluation index. When the crown settlement was predicted, the average prediction accuracy of the Bayes-LSTM model was 1.0 and 1.26 higher than that of the CNN and SVR models, respectively. When peripheral convergence was predicted, the average accuracy

收稿日期:2022-07-27(修改稿)

基金项目:中国交建科技研发项目(编号:2019-ZJKJ-08);中交第一公路勘察设计研究院有限公司科技研发项目(编号:KYHT2020-43);中交第一公路勘察设计研究院有限公司科创基金项目(编号:KCJJ2020-19)

作者简介:刘智,男,硕士,高级工程师.E-mail:darcy_liu@163.com

of the Bayes-LSTM model was 0.3 and 0.32 higher than that of CNN and SVR, respectively. The results show that the Bayes-LSTM model has higher prediction accuracy, and it can judge and choose the historical information in the process of model training, which greatly improves the efficiency of time series data processing. The model provides a new idea for the prediction of surrounding rock deformation of highway tunnels.

Keywords: highway tunnel; surrounding rock deformation; data analysis; LSTM; Bayesian optimization

0 引言

在公路隧道施工过程中,围岩大变形是一种常见的施工灾害,对隧道的正常施工具有较大的影响^[1],隧道的监控量测工作对隧道的安全施工具有指导作用。由于隧道围岩的地质条件差异,使其具有较大的各向异性、非均质性、非连续性,导致隧道变形的理论计算较为困难。因此,在建设过程中利用稳定性或收敛变形预测方法辅助判断围岩的变形趋势及稳定性^[2],将对支护设计提供重要参考,避免施工中安全事故的出现。

目前,国内外众多学者对公路隧道围岩变形预测展开了大量的研究。张云鹏等^[3]为解决围岩大变形中出现的高度非线性时序问题,采用高斯过程回归构建隧道围岩大变形预测模型;孙柏林等^[4]提出含有4个参数的增长曲线 Richards 模型,可以较好地应用于隧道开挖施工过程中的围岩变形预测;曹孟潇等^[5]将神经网络预测模型与马尔科夫链结合应用于公路隧道围岩的开挖变形预测;冯永年^[6]通过分析隧道围岩的收敛变形特征,基于宴家隧道典型断面开挖过程中的实测围岩收敛变形数据,建立了宴家隧道围岩收敛变形预测 GM(1,1)灰色模型;廖烟开等^[7]采用挤压因子法对某软岩隧道挤压性大变形等级进行预测,然后采用隧道周边应变法对挤压性大变形的量值进行预测;文明等^[8]提出非线性自回归时间序列预测模型,引入动态施工影响因子作为附加的外部输入,提高了模型的预测精度和适应性;周冠南等^[9]通过构建基于遗传算法的BP神经网络智能反分析系统(GA-BP),实现了遗传算法自动搜索BP网络参数,大大提高了反演分析的效率;刘艳明^[10]针对石牛岭隧道出口右洞地表预固结处的灌木丛中发生地表塌陷问题,结合观测现象与量测数据对造成塌陷的原因进行分析,并采用曲线拟合的方法对隧道

围岩未来的发展趋势进行预测;李贤等^[11]通过对围岩蠕变特性的理论-位移公式计算和现场监控量测数据的回归分析,得出了中和村隧道围岩变形规律和二次衬砌最佳支护时机的参考范围。

Shi等^[12]运用了支持向量机(SVM)信息粒化方法预测围岩的变形,具有较高的精度;曹怀宇^[13]在收集现有隧道围岩分类数据的基础上,运用粗糙集理论探索数据中包含的隐性知识,以实现隧道围岩的分类预测;王开洋等^[14]通过物理、化学试验确定其壁岩软岩为非膨胀岩,并预测了这些软岩的挤压变形,结合原位应力的实测数据和数值模拟结果,说明了隧道区域最大主应力的分布;Pan^[15]结合萤火虫算法(FA)和非线性自回归(NAR)动态神经网络方法,提出了一种用于预测动态非线性围岩变形的算法模型;黄永红^[16]运用了MGM(1,3)+AR(3)模型组合,不仅可以反映序列数据发展和变化的趋势,而且可以考虑数据序列中随机波动的影响,可以拟合并进行高精度的预测。

针对围岩变形的动态预测,循环神经网络(Recurrent Neural Network, RNN)的内部节点采用递归连接的方式,使各个隐藏层之间能够相互连接,更好地实现网络状态反馈。长短时记忆网络(Long Short-Term Memory, LSTM)是循环神经网络的变体,可以解决RNN无法处理长距离的依赖问题,能够更好地处理时序数据。

基于以上研究,本文采用LSTM模型对拱顶沉降与周边收敛进行预测。首先针对拱顶沉降与周边收敛构建初始LSTM模型,贝叶斯(Bayes)模型优化初始模型中的超参数,然后利用优化后的LSTM模型预测拱顶沉降与周边收敛,最后与神经网络(Convolutional Neural Network, CNN)和支持向量回归(Support Vector Regression, SVR)模型分别进行对比,以均方根误差 E_{RMSE} 评价各模型的预测精度。

核心技术方法与杨背背等^[17]针对滑坡位移动态预测方法相似。

1 Bayes-LSTM 模型构建

1.1 LSTM 网络基本原理

LSTM 网络是一种改进的循环神经网络,能够规避 RNN 中梯度爆炸和梯度消失的问题。所有 RNN 都具有一种重复神经网络模块的链式形式。在标准的 RNN 中,这个重复的模块只有一个非常简单的结构,RNN 网络结构如图 1 所示。




图 1 RNN 网络结构

Figure 1 RNN structure

图 1 中: h_t 为 t 时刻隐藏层的状态值; x_t 为当前时刻输入层的输入向量。

RNN 单元的计算公式为:

$$h_t = \tanh(W_h h_{t-1} + W_h x_t + b_h) \quad (1)$$

由式(1)可以看到:RNN 本时刻的隐藏层信息只来源于当前输入于上一时刻的隐藏层信息,没有记忆功能。

LSTM 也具有这种链式结构,如图 2 所示。显然,LSTM 的网络结构相比于 RNN 复杂了很多,从微观上看,LSTM 引入了细胞状态。同时,LSTM 拥有 3 个“门”,分别为“遗忘门”“输入门”“输出门”,其能够靠一些“门”的结构让信息有选择地影响循环神经网络的每个时刻的状态,有选择性地决定让哪些信息通过。




图 2 LSTM 网络结构

Figure 2 LSTM network structure

LSTM 的第一步“遗忘门”决定细胞状态需要丢

弃哪些信息,其决定了上一时刻的单元状态 C_{t-1} 对当前时刻单元状态 C_t 的影响程度, f_t 为遗忘门的输出,上一序列中隐藏状态 h_{t-1} 与当前时刻的序列数据 x_t 作为输入, σ 为激活函数(常用 Sigmoid 函数), b_f 为遗忘门的偏置向量, W_f 为遗忘门权值矩阵。

$$f_t = \sigma(W_f h_{t-1} + W_f x_t + b_f) \quad (2)$$

第二步“输入门”决定给细胞状态添加哪些新的信息,由两部分组成,计算公式如下:

$$i_t = \sigma(W_i h_{t-1} + W_i x_t + b_i) \quad (3)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tanh(W_c h_{t-1} + W_c x_t + b_c) \quad (4)$$

式中: i_t 决定更新到细胞状态中的所需信息; C_t 为 t 时刻新的单元状态; W_c 为输入门权值矩阵; b_c 为输入门的偏置向量;激活函数 \tanh 为双曲正切函数。

首先,利用 h_{t-1} 和 x_t 通过输入门的操作决定更新哪些信息,然后利用 h_{t-1} 和 x_t 通过 \tanh 层得到新的候选细胞信息,随后更新旧细胞信息 C_{t-1} 为新细胞信息 C_t 。

第三步“输出门”根据输入的和来判断输出细胞的哪些状态特征,控制 C_t 对 h_t 的影响程度,其更新公式如下:

$$o_t = \sigma(W_o h_{t-1} + W_o x_t + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

式中: o_t 决定细胞状态的输出部分; b_o 为输出门偏置向量; W_o 为输出门权值矩阵; h_t 为 t 时刻 x_t 对应单元的隐藏层状态值。

1.2 贝叶斯优化原理

贝叶斯优化是一种近似逼近的方法,用高斯过程、随机森林等各种概率代理模型拟合超参数与模型评价之间的关系,得出效果最好的超参数组合。其适用于黑箱优化(即无需知道函数具体表达式,只需指定输入和输出即可),贝叶斯参数优化会考虑之前的参数信息,更新目标函数的后验分布,直到后验分布基本贴合于真实分布。

贝叶斯优化中的概率代理模型指通过某种概率模型替代目标函数,则后验概率的更新公式为:

$$p(f|D) = \frac{p(D|f)p(f)}{p(D)} \quad (7)$$

式中: $D = \{(x_1, f_1), (x_2, f_2), \dots, (x_n, f_n)\}$ 为已采集到的样本点; $p(f)$ 为先验分布,能够通过上述贝叶斯公

式算出 f 的后验分布。

贝叶斯优化的代理模型主要分为以下3类:TPE(Tree Parzen Estimator, 树形 Parzen 评估器), SMAC(随机森林回归), GP(高斯过程)。本文采用 TPE, 一种基于树状结构 Parzen 密度估计的非标准贝叶斯优化算法, 相比于其他模型, 其在高维空间表现的效果更好, 速度有显著提高。

TPE 参数配置空间是树形的, 主要对 $p(x|y)$ 和 $p(y)$ 进行建模^[9], 前面的参数决定了后续要选择使用哪些参数以及参数的取值范围。

TPE 定义了如下两个概率密度:

$$p(x|y) = \begin{cases} l(x), & y < y^* \\ g(x), & y > y^* \end{cases} \quad (8)$$

式中: $l(x)$ 为 $f(x^i)$ 小于阈值 y^* 对应的 $\{x^i\}$ 的概率密度; $g(x)$ 为 $f(x^i)$ 大于阈值 y^* 对应的 $\{x^i\}$ 的概率密度。

通过不同的位置反复测量待优函数, 可以获得更多的信息来估计待优函数的分布, 从而搜索到最优的测量位置, 以期得到最优函数值。为了评估位置是否最优, 需要采集函数, 在最佳位置采集函数拥有最大值, 在 TPE 中其采集函数为增益期望(Expected Improvement, E_{EI}), 即 $f(x)$ 小于阈值 y^* 的期望, 其在多数情况下表现较好, 公式如下:

$$E_{EI^*}(x) = \int_{-\infty}^{-\infty} \max(y^* - y, 0) p(y|x) dy = \int_{-\infty}^{y^*} \max(y^* - y, 0) \frac{p(x|y)p(y)}{p(x)} dy \quad (9)$$

式中: 模型 p 是观测域上的后验高斯分布。

TPE 中, 令 $\gamma = p(y < y^*)$, 并且 $p(x) = \int p(x|y)p(y)dy = \gamma l(x) + (1 - \gamma)g(x)$, 则有:

$$E_{EI^*} = \frac{l(x)y^*\gamma - l(x) \int_{-\infty}^{y^*} p(y)dy}{\gamma l(x) + (1 - \gamma)g(x)} \\ E_{EI^*} \propto \left[\gamma + \frac{g(x)}{l(x)}(1 - \gamma) \right]^{-1} \quad (10)$$

式中: $l(x)$ 求出概率较高的 x , $g(x)$ 求出概率较小的 x , E_{EI} 较大, $l(x)$ 和 $g(x)$ 用树结构形式表示, 会更加便于根据 $l(x)$ 采样, 得到更多的改进信息, 在每一轮迭代中都会返回有最大 E_{EI} 的 x^* 。

贝叶斯优化问题包括目标函数、域空间、优化算

法、结果历史记录4个部分, 如表1所示。

表1 贝叶斯优化的主要部分

Table 1 Main components of Bayesian optimization

主要部分	解释
目标函数	模型想要最小化的函数, 本文中为 LSTM 模型中使用该组超参数在验证集上的损失大小
域空间	需要调优的超参数的取值范围, 本文中为 LSTM 单元内隐藏层的尺寸大小, 优化器的选择, 学习率, dropout 等参数
优化算法	构造代理函数并选择下一个超参数值的方法, 即采集函数(Acquisition function, AC)
结果历史记录(History)	目标函数评估的存储结果

2 基于 Bayes-LSTM 的模型构建

考虑公路隧道围岩变形的时序特征, 利用 python 构建包含输入层、隐藏层、输出层等部分的 LSTM 网络模型, 如图3所示。Python 中的 Keras 是基于 TensorFlow 的深度学习框架, 更是一个高度模块化的神经网络库。基于 Keras 框架构建三层神经网络结构。在构建过程中, 利用 python 中贝叶斯优化调参模块 Hyperopt 对 LSTM 单元内隐藏层尺寸大小(units)、优化器(optimizer)的选择、学习率(learn_rate)、Dropout 比例、迭代次数(epochs)等参数针对不同数据集进行优化, 选用均方误差 E_{MSE} 作为损失函数, 不断训练调节超参数, 直到参数满足精度要求, 公式如下:

$$E_{MSE} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

式中: y_i 为真实值; \hat{y}_i 为预测值。

试验时利用 python 语言进行模型搭建与数据处理, 具体步骤为:

(1) 分别针对拱顶沉降与周边收敛的机理知识进行分析。

(2) 加载数据, 对数据进行归一化处理, 将时序数据转化为有监督数据, 并将数据转化为 LSTM 所需的输入数据格式。

(3) 划分数据为训练集、验证集与测试集。

(4) 设置贝叶斯优化的参数及搜索空间, 构建 LSTM 网络模型。

(5) 加载 LSTM 模型, 并对待优化参数进行贝叶

斯优化,以 E_{MSE} 作为损失函数,根据训练集验证集损失判断模型拟合效果,效果好则进行预测,效果一般则调整参数寻优范围继续优化。

(6) 通过反归一化获得预测数据。

3 模型实现与验证

为了验证模型的准确性与有效性,选取某高速公路隧道拱顶下沉与周边收敛数据进行分析,该隧道围岩等级主要为Ⅲ、Ⅳ、Ⅴ级,Ⅴ级围岩测量间距为 10 m 左右,Ⅳ级围岩测量间距为 20 m 左右,Ⅲ级围岩测量间距为 50 m 左右,在隧道开挖毛洞的拱顶及轴线左右各 2.5 m 共设 3 个带挂钩的锚桩(或粘贴反光片),测桩深度 30 cm,用快凝水泥或早强锚固剂固定,利用全站仪进行测量。

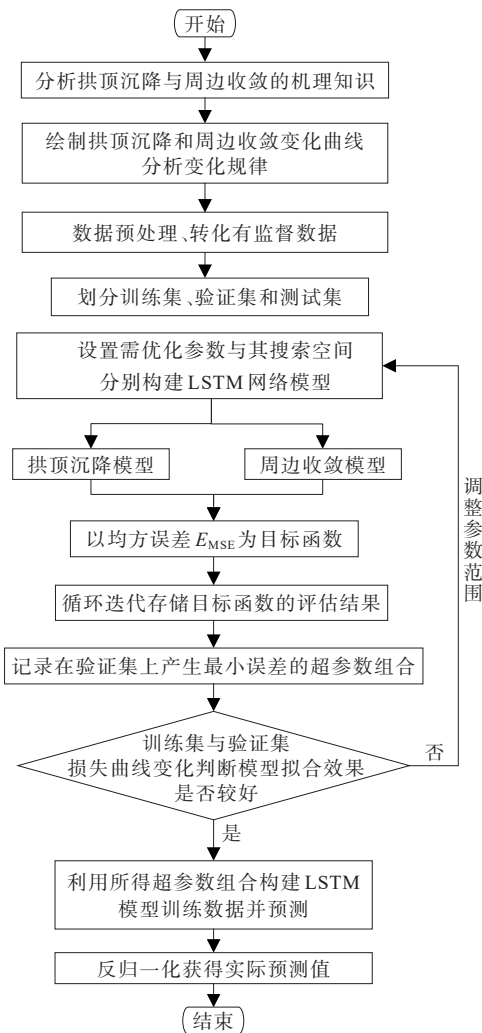


图3 Bayes-LSTM 模型

Figure 3 Bayes-LSTM model

3.1 基于 Bayes-LSTM 的拱顶沉降预测模型与验证

选取该隧道左线 ZK58+820 横断面的 3 个测点 C1、C2、C3 的拱顶变形监测数据进行分析,该断面的围岩等级为Ⅴ级,测点布置如图 4 所示。




图4 拱顶下沉测点布置示意图

Figure 4 Layout of measurement points for crown settlement

持续观测 59 d 的拱顶沉降监测数据(包含 C1、C2、C3 测点)如图 5 所示。前 47 d 的监测频率为 1 次/d,由于拱顶下沉逐渐趋于稳定,因此后 12 d 的监测频率为 1 次/(3 d)。




图5 拱顶沉降曲线

Figure 5 Crown settlement curve

为了提高模型的泛化能力,防止过拟合现象,将前 67% 的数据作为训练集,用于贝叶斯优化寻找最优模型参数,后 33% 的数据作为测试样本进行预测。设置贝叶斯优化过程中迭代次数为 30,以训练集中的 20% 作为验证集来验证模型的泛化能力,优化目标为均方误差 E_{MSE} ,所选取的需要进行优化模型参数及其参数空间与得到的各个最优参数如表 2 所示。重新使用全部训练集对模型进行训练,最终得到最优模型。

针对拱顶下沉 C1 的实测数据,首先对数据进行归一化,由于监测天数非连续,本文利用前两天的累计沉降数据与监测天数作为特征因素来预测第三天数据,并将数据转化为有监督数据,如表 3、4 所示。

表 2 贝叶斯优化的参数空间及其最优参数

Table 2 Parameter space of Bayesian optimization and its optimal parameters

参数名称	参数空间	最优参数	参数意义	
Units	1	[2,64]	50	LSTM单元内
	2	[2,64]	22	隐藏层尺寸大小
Optimizer	[‘adam’,‘rmsprop’, ‘adamax’]		adamax	优化器
Learn_rate	[0.001,0.01]	0.01		学习率
Epochs	[100,300]	280		循环迭代次数

表 3 C1 测点归一化后数据

Table 3 Normalized data of C1

日期(年-月-日)	归一化天数	归一化累计下沉
2018-10-28	0	0
2018-10-29	0.017 241 4	0.119 454
2018-10-30	0.034 482 8	0.262 799
2018-10-31	0.051 724 1	0.361 775
2018-11-01	0.068 965 5	0.426 621
.....
2018-12-13	0.844 828 0	0.986 348
2018-12-16	0.896 552 0	0.996 587
2018-12-19	0.948 276 0	1
2018-12-22	1	0.996 587

表 4 C1 测点有监督数据

Table 4 Supervised data of C1

监测天数	$t-2$ 拱顶沉降	监测天数	$t-1$ 拱顶沉降	监测天数	t 拱顶沉降
0	0	0.017	0.120	0.035	0
0.017	0.120	0.035	0.263	0.052	0.017
0.034	0.263	0.052	0.362	0.069	0.035
.....
0.845	0.986	0.897	0.997	0.948	1
0.897	0.997	0.948	1	1	0.997

分别利用 Bayes-LSTM、CNN、SVR 3 个模型对拱顶沉降进行预测,并以均方根误差 E_{RMSE} (Root Mean Square Error, RMSE) 为评价指标,对预测结果进行比较。

$$E_{\text{RMSE}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{m}}$$

(12)

式中: y_i 为真实值; \hat{y}_i 为预测值; m 为样本数量。

拱顶沉降预测对比分析结果如图 6 所示,3 种模型对比结果列于图 7 和表 5。

从图 6 中 C1 测点的沉降预测曲线可以看出:利用 Bayes-LSTM 可以较好地预测拱顶沉降的变化特征。从图 7 和表 5 计算结果可以看出:Bayes-LSTM 网络的拟合效果优于 CNN 和 SVR。CNN 神经网络预测的最大误差、最小误差、平均误差、平均相对误差和 E_{RMSE} 值分别为 3.1 mm、0.12 mm、0.99 mm、3.43% 和






图 6 拱顶沉降预测值与实测值对比曲线

Figure 6 Comparison curve between predicted and measured values of crown settlement



(a) 误差



(b) 相对误差

图 7 C1 测点误差对比

Figure 7 Error comparison of C1

表 5 C1测点沉降值与预测值比较

Table 5 Comparison between settlement value and predicted value of C1

天数/d	实测值/mm	Bayes-LSTM			CNN			SVR		
		预测	误差/	相对误	预测	误差/	相对误	预测	误差/	相对误
		值/mm	mm	差/%	值/mm	mm	差/%	值/mm	mm	差/%
36	28.0	27.59	0.41	1.46	26.97	1.03	3.68	25.92	2.08	7.42
37	28.1	27.79	0.31	1.10	27.22	0.88	3.13	26.40	1.70	6.06
38	28.3	27.94	0.36	1.27	27.47	0.83	2.93	26.74	1.56	5.52
39	28.4	28.12	0.28	0.99	27.72	0.68	2.39	27.07	1.33	4.70
40	28.4	28.27	0.13	0.46	27.96	0.44	1.55	27.32	1.08	3.79
41	28.5	28.36	0.14	0.49	28.19	0.31	1.09	27.42	1.08	3.77
42	28.3	28.47	0.17	0.60	28.42	0.12	0.42	27.53	0.77	2.71
43	28.2	28.47	0.27	0.96	28.63	0.43	1.52	27.65	0.55	1.94
44	28.5	28.46	0.04	0.14	28.82	0.32	1.12	27.76	0.74	2.61
45	28.6	28.62	0.02	0.07	29.06	0.46	1.61	27.66	0.94	3.29
46	28.4	28.77	0.37	1.30	29.32	0.92	3.24	27.50	0.90	3.17
47	28.5	28.78	0.28	0.98	29.53	1.03	3.61	27.56	0.94	3.28
50	28.9	28.91	0.01	0.03	30.17	1.27	4.39	27.33	1.57	5.45
53	29.2	29.23	0.03	0.10	30.88	1.68	5.75	27.10	2.10	7.19
56	29.3	29.56	0.26	0.89	31.60	2.30	7.85	26.79	2.51	8.57
59	29.2	29.77	0.57	1.95	32.30	3.10	10.62	26.71	2.49	8.52
精度	平均		0.23	0.80		0.99	3.43		1.40	4.87
指标	E_{RMSE}		0.28			1.25			1.52	

1.25,SVR 预测的最大误差、最小误差、平均误差、平均相对误差和 E_{RMSE} 值分别为 2.51 mm、0.55 mm、1.40 mm、4.87% 和 1.52,而 Bayes-LSTM 预测的最大误差、最小误差、平均误差、平均相对误差和 E_{RMSE} 值分别为 0.57 mm、0.01 mm、0.23 mm、0.80% 和 0.28,明显看出 Bayes-LSTM 网络预测效果较佳。CNN 与 SVR 网络预测误差离散度较大,在多数情况下, Bayes-LSTM 预测的相对误差与残差均比 CNN 和 SVR 小。

针对拱顶沉降 C2、C3 测点的监测数据,分别进行归一化并利用前两天数据预测第 3 天数据,将其转化为有监督数据,分别利用 Bayes-LSTM、CNN、SVR 3 个模型对拱顶沉降进行预测,结果如图 8、9 所示。

由图 8 可知:对拱顶 C2 测点的沉降预测,CNN 神经网络预测的 E_{RMSE} 值为 1.98,SVR 预测的 E_{RMSE} 值为 1.13, Bayes-LSTM 预测的 E_{RMSE} 值 0.33, Bayes-LSTM 网络预测效果较佳。Bayes-LSTM 网络预测误差离散程度较小,在多数情况下,Bayes-LSTM 预测的相对误差与残差均比 CNN 和 SVR 小。




图 8 C2 测点拱顶沉降预测值与实测值对比曲线

figure 8 Comparison curve between predicted and measured values of crown settlement of C2




图 9 C3 测点拱顶沉降预测值与实测值对比曲线

Figure 9 Comparison curve between predicted and measured values of crown settlement of C3

由图 9 可知:CNN、SVR、Bayes-LSTM 预测的 E_{RMSE} 值分别为 0.68、2.03、0.29。可以明显看出, Bayes-LSTM 网络精度指标均优于 CNN 与 SVR, Bayes-LSTM 网络预测效果较佳。

Bayes-LSTM 模型针对拱顶沉降 C1、C2、C3 测点的 E_{RMSE} 平均值为 0.30, CNN 模型的 E_{RMSE} 平均值为 1.30, SVR 模型的 E_{RMSE} 平均值为 1.56。相较于 CNN, Bayes-LSTM 的预测精度提升了 1.0, 相较于 SVR, Bayes-LSTM 的预测精度提升了 1.26。由此可见, 本文提出的 Bayes-LSTM 模型具有较高的可靠性。

3.2 基于 Bayes-LSTM 的周边收敛预测模型与应用验证

选取此段高速公路隧道洞口开挖面(ZK58+847 处)的周边收敛进行分析, 其测线布置如图 10 所示。




图 10 周边收敛测线布置

Figure 10 Layout of peripheral convergence survey lines

本监测断面周边收敛共有 35 条监测数据, 前 15 d 监测频率为 1 次/d, 后 20 d 监测频率为 1 次/(2 d)。周边收敛的变化曲线如图 11 所示。




图 11 周边收敛曲线

Figure 11 Peripheral convergence curve

利用前 67% 的数据作为训练样本, 用于贝叶斯优化寻找最优模型参数, 后 33% 的数据作为测试样本进行预测, 表 6 为贝叶斯优化后的最优参数。

为检验 Bayes-LSTM 模型的有效性, 针对收敛监测数据, 分别应用 Bayes-LSTM、CNN 和 SVR 进行预测, 并将预测结果进行比较, 分析对比结果如图 12、13 所示, 计算结果列于表 7。

表 6 最优参数

Table 6 Optimal parameters				
参数名称	参数空间	最优参数	参数意义	
Units	[2, 64]	1	63	LSTM 单元内隐
		2	10	藏层尺寸大小
Optimizer	['adam', 'rmsprop', 'adamax']	adam	优化器	
Learn_rate	[0.001, 0.01]	0.01	学习率	
Epochs	[100, 300]	245	循环迭代次数	






图 12 周边收敛量预测值与实测值对比曲线

Figure 12 Comparison curve between predicted and measured values of peripheral convergence



(a) 相对误差



(b) 误差

图 13 周边收敛误差对比

Figure 13 Comparison of peripheral convergence errors

表 7 周边收敛量与预测值比较

Table 7 Comparison of peripheral convergence and predicted values

天数/d	实测值/ mm	Bayes-LSTM			CNN			SVR		
		预测 值/mm	误差/ mm	相对误 差/%	预测 值/mm	误差/ mm	相对误差/%	预测 值/mm	误差/ mm	相对误 差/%
37	2.29	2.35	0.06	2.62	2.05	0.24	10.48	2.17	0.12	5.31
39	2.34	2.36	0.02	0.85	2.05	0.29	12.39	2.17	0.17	7.26
41	2.40	2.38	0.02	0.83	2.06	0.34	14.17	2.22	0.18	7.60
43	2.41	2.41	0	0.00	2.08	0.33	13.69	2.28	0.13	5.34
45	2.41	2.44	0.03	1.24	2.10	0.31	12.86	2.29	0.12	5.13
47	2.43	2.44	0.01	0.41	2.11	0.32	13.17	2.29	0.14	5.68
49	2.45	2.45	0	0.00	2.11	0.34	13.88	2.32	0.14	5.57
51	2.47	2.46	0.01	0.40	2.12	0.35	14.17	2.34	0.13	5.37
53	2.50	2.48	0.02	0.80	2.13	0.37	14.80	2.36	0.14	5.52
55	2.53	2.49	0.04	1.58	2.14	0.39	15.42	2.39	0.14	5.57
精度	平均		0.021	0.88		0.33	3.43		0.35	12.07
指标	E_{RMSE}		0.03			0.33			0.35	

由图 12、表 7 和图 13 可知：利用 Bayes-LSTM 可以很好地拟合周边收敛的变化特征。CNN 神经网络预测的最大误差、最小误差、平均误差、平均相对误差和 E_{RMSE} 值分别为 0.39 mm、0.24 mm、0.33 mm、3.43% 和 0.33；SVR 预测的最大误差、最小误差、平均误差、平均相对误差和 E_{RMSE} 值分别为 0.18 mm、0.12 mm、0.35 mm、12.07% 和 0.35；Bayes-LSTM 预测的最大误差、最小误差、平均误差、平均相对误差和 E_{RMSE} 值分别 0.06 mm、0 mm、0.021 mm、0.88% 和 0.03。可以明显看出 Bayes-LSTM 网络预测效果较佳，Bayes-LSTM 网络预测误差离散程度较小，Bayes-LSTM 具有较高的可靠性。

从上述拱顶沉降与周边收敛的预测结果来看，LSTM 网络能够较好地拟合拱顶下沉与周边收敛的变化特征，相较于 CNN、SVR，其预测结果准确性更高。

3.3 模型验证

为了验证模型的泛化能力，选取此高速公路隧道Ⅲ、Ⅳ、Ⅴ级围岩中桩号 ZK58+066 等 6 处断面的拱顶下沉数据和周边收敛数据进行模型验证与分析，以 E_{RMSE} 为评价标准，比对结果如表 8、9 所示。

对比 E_{RMSE} 值可以发现：Bayes-LSTM 模型在围岩变形预测中表现较好，证明该模型具有一定的泛化能力。

表 8 拱顶沉降验证结果 E_{RMSE} 比对

Table 8 E_{RMSE} comparison of crown settlement verification results

围岩 类别	桩号	测 点	E_{RMSE}			最优 模型
			Bayes-LSTM	CNN	SVR	
Ⅴ	ZK58+066	C1	0.44	0.75	0.45	Bayes-LSTM
		C2	0.27	0.42	0.41	
		C3	0.16	0.43	0.20	
Ⅳ	ZK58+087	C1	0.47	0.59	0.54	
		C2	0.43	0.76	0.86	
		C3	0.36	0.88	0.43	
Ⅲ	ZK58+177	C1	0.23	0.31	1.03	
		C2	0.64	1.00	0.81	
		C3	0.42	0.80	0.70	

表 9 周边收敛验证结果 E_{RMSE} 比对

Table 9 E_{RMSE} comparison of peripheral convergence verification results

桩号	E_{RMSE}			最优模型
	Bayes-LSTM	CNN	SVR	
ZK58+497	0.07	0.26	0.35	Bayes-LSTM
ZK58+867	0.20	0.40	0.50	
ZK58+777	0.14	0.60	0.49	

4 结论

针对公路隧道施工过程中拱顶沉降和周边收敛的非线性与复杂性等特征,提出 Bayes-LSTM 时间序列预测模型,构建分别针对拱顶沉降与周边收敛的模型,将数据归一化并将其转化成有监督数据,利用贝叶斯优化对超参数进行优化,计算得到预测结果,并以某高速公路隧道施工中开挖面里程 ZK58+820 的拱顶实测数据和 ZK58+847 周边收敛量实测数据为例,对该模型进行应用验证,得到以下主要结论:

(1) 利用 Bayes-LSTM 模型进行预测时,C1、C2 和 C3 拱顶沉降的平均预测精度相较于 CNN 模型、SVR 模型分别提高了 1.0 和 1.26;周边收敛的预测精度相较于 CNN 模型、SVR 模型分别提高了 0.3 和 0.32,证明了 Bayes-LSTM 模型的有效性。

(2) 基于 6 个断面实测的围岩拱顶下沉数据和周边收敛数据对 Bayes-LSTM 模型进行了泛化能力验证,结果显示:Bayes-LSTM 模型的 E_{RMSE} 小于 CNN、SVR 模型,验证了 Bayes-LSTM 模型的泛化能力。

(3) 针对拱顶沉降与周边收敛变形这一复杂的非线性动态系统,提出一种基于 Bayes-LSTM 算法的公路隧道围岩变形预测模型,与目前流行的预测模型相比,该模型具有以下优点:① LSTM 模型具有记忆功能,能够充分地利用围岩变形的历史数据,从而提高围岩变形的预测精度;② LSTM 模型通过“三个门”对元细胞状态进行交互,能够有效实现对历史数据的判断与取舍。训练好的算法模型可以融入监测预警系统中进行工程应用,该方法为隧道围岩变形预测提供了新的思路与探索。

影响隧道拱顶沉降与周边收敛的因素是多方面的,隧道施工过程中的岩土体特性非常复杂,本文仅考虑了围岩变形不同等级的隧道变形情况,没有充分考虑地应力、岩性等特性,从而导致计算的结果与实际数据有一定的差距。此外,数据量的大小也会影响模型的预测效果。因此将会进一步采集隧道的特征参数,收集更多的训练样本,针对不同地应力、不同岩性的围岩进行进一步的研究。

参考文献:

References:

- [1] 张碧.基于小波变换的隧道大变形组合预测方法[J].长江科学院院报,2017,34(7): 94-98,105.
ZHANG Bi. Combinatorial forecasting method for large deformation of tunnel based on wavelet transform[J]. Journal of Yangtze River Scientific Research Institute, 2017,34(7): 94-98,105.
- [2] 叶超.基于 BP 神经网络修正的自适应灰色模型的隧道变形预测研究[J].铁道标准设计,2017,61(11): 76-81.
YE Chao. Research on deformation prediction of tunnel based on adaptive grey model of BP neural network correction[J]. Railway Standard Design, 2017,61(11): 76-81.
- [3] 张云鹏,李利平,贺鹏,等.隧道围岩大变形高斯过程回归预测模型及其工程应用[J].科学技术与工程,2018,18(1): 122-127.
ZHANG Yunpeng, LI Liping, HE Peng, et al. Gaussian process regression prediction model for the big deformation of the tunnel rock and its application[J]. Science Technology and Engineering, 2018,18(1): 122-127.
- [4] 孙柏林,乔松林,张乾青,等.隧道拱顶沉降及周边收敛动态过程预测的 Richards 时间函数模型[J].公路工程,2015,40(6): 114-118.
SUN Bolin, QIAO Songlin, ZHANG Qianqing, et al. Richards time function model of dynamic process prediction for tunnel vault sedimentation and peripheral convergence[J]. Highway Engineering, 2015,40(6): 114-118.
- [5] 曹孟潇,吕文黔,张金瑞,等.基于马尔可夫链修正的神经网络隧道围岩变形预测[J].中国水运(下半月),2019,19(2): 191-193.
CAO Mengxiao, LYU Wenqian, ZHANG Jinrui, et al. Deformation prediction of tunnel surrounding rock based on neural network modified by Markov chain[J]. China Water Transport, 2019,19(2): 191-193.
- [6] 冯永年.宴家隧道围岩收敛灰色系统预测模型[J].公路交通科技(应用技术版),2015,11(3): 169-172.
FENG Yongnian. Grey system prediction model of surrounding rock convergence in Yanjia tunnel[J]. Journal of Highway and Transportation Research and Development(Application Technology Edition), 2015, 11(3): 169-172.
- [7] 廖烟开,郭德平,刘志强,等.隧道周边应变与挤压因子法在隧道围岩大变形预测中的应用[J].现代隧道技术,

- 2020,57(4): 20-26.
- LIAO Yankai, GUO Deping, LIU Zhiqiang, et al. Application of peripheral strain and squeezing factor methods in the prediction of large deformation of tunnel surrounding rocks [J]. Modern Tunnelling Technology, 2020, 57(4): 20-26.
- [8] 文明, 张顶立, 房倩, 等. 隧道围岩变形的非线性自回归时间序列预测方法研究[J]. 北京交通大学学报, 2017, 41(4): 1-7.
- WEN Ming, ZHANG Dingli, FANG Qian, et al. Research on nonlinear auto regressive time series method for predicting deformation of surrounding rock in tunnel[J]. Journal of Beijing Jiaotong University, 2017, 41(4): 1-7.
- [9] 周冠南, 孙玉永, 贾蓬. 基于遗传算法的BP神经网络在隧道围岩参数反演和变形预测中的应用[J]. 现代隧道技术, 2018, 55(1): 107-113.
- ZHOU Guannan, SUN Yuyong, JIA Peng. Application of genetic algorithm based BP neural network to parameter inversion of surrounding rock and deformation prediction [J]. Modern Tunnelling Technology, 2018, 55(1): 107-113.
- [10] 刘艳明. 石牛岭隧道地表坍塌原因分析及处理方案探讨[J]. 中外公路, 2018, 38(3): 228-231.
- LIU Yanming. The cause analysis and treatment scheme of surface collapse in Shi-Niu-ling tunnel[J]. Journal of China & Foreign Highway, 2018, 38(3): 228-231.
- [11] 李贤, 蔡林真. 某软岩隧道变形规律和二衬最佳支护时机选择研究[J]. 中外公路, 2019, 39(3): 189-192.
- LI Xian, CAI Linzhen. Research on deformation rule and optimal lining time of a tunnel in soft rock[J]. Journal of China & Foreign Highway, 2019, 39(3): 189-192.
- [12] SHI S S, ZHAO R J, LI S C, et al. Intelligent prediction of surrounding rock deformation of shallow buried highway tunnel and its engineering application[J]. Tunnelling and Underground Space Technology, 2019, 90: 1-11.
- [13] 曾怀宇. 基于粗糙集综合权重法的公路隧道围岩等级预测方法研究[J]. 路基工程, 2018(4): 69-74.
- ZENG Huaiyu. Study on prediction methods of highway tunnel surrounding rock class based on rough set comprehensive weight method[J]. Subgrade Engineering, 2018(4): 69-74.
- [14] 王开洋, 尚彦军, 何万通, 等. 深埋公路隧道围岩大变形预测研究[J]. 地下空间与工程学报, 2015, 11(5): 1164-1174.
- WANG Kaiyang, SHANG Yanjun, HE Wantong, et al. Prediction of surrounding rock deformation in deep highway tunnel[J]. Chinese Journal of Underground Space and Engineering, 2015, 11(5): 1164-1174.
- [15] PAN Y, CHEN L, WANG J, et al. Research on deformation prediction of tunnel surrounding rock using the model combining firefly algorithm and nonlinear auto-regressive dynamic neural network[J]. Engineering with Computers, 2021, 37(2): 1443-1453.
- [16] 黄永红. 基于灰色时间序列组合的隧道变形预测研究[J]. 城市勘测, 2016(6): 127-130.
- HUANG Yonghong. Deformation prediction of tunnel surrounding rock based on grey time series combined model[J]. Urban Geotechnical Investigation & Surveying, 2016(6): 127-130.
- [17] 杨背背, 殷坤龙, 杜娟. 基于时间序列与长短时记忆网络的滑坡位移动态预测模型[J]. 岩石力学与工程学报, 2018, 37(10): 2334-2343.
- YANG Beibei, YIN Kunlong, DU Juan. A model for predicting landslide displacement based on time series and long and short term memory neural network[J]. Chinese Journal of Rock Mechanics and Engineering, 2018, 37(10): 2334-2343.