

DOI: 10.11779/CJGE2020S1044

山岭隧道收敛变形无线感知及预测方法

王天宁¹, 王利宁², 薛亚东¹, 张越², 张东明¹, 黄宏伟^{*1}

(1. 同济大学土木工程学院, 上海 200092; 2. 中建交通建设集团有限公司, 北京 100142)

摘要: 隧道施工过程中围岩的变形规律是施工安全的关键, 目前钻爆法施工隧道断面的变形检测多基于全站仪展开, 检测数据点数据量难以精细分析变形规律。借助无线传感网络(wireless sensors network), 可以实现隧道重点部位的长时间连续监测。在营盘山隧道布设了基于微机电系统(micro electro mechanical system)传感器的WSN监测设备, 并构建了基于广域网(Web)的隧道施工安全风险动态管控系统平台, 实现隧道关键位置变形的连续监测, 所得变形时间序列, 通过长短时记忆(long short-term memory)网络, 更准确地预测隧道断面收敛变形值。实际工程应用结果证明了该方法的有效性。

关键词: 山岭隧道; 收敛变形; 无线传感网络(WSN); 长短时记忆(LSTM)网络

中图分类号: TU431

文献标识码: A

文章编号: 1000-4548(2020)S1-0224-05

作者简介: 王天宁(1995—), 男, 硕士研究生, 主要从事隧道及地下工程等领域的科研工作。E-mail: wtneu@126.com。

Wireless sensing and prediction method for convergence deformation of mountain tunnels

WANG Tian-ning¹, WANG Li-ning², XUE Ya-dong¹, ZHANG Yue², ZHANG Dong-ming¹, HUANG Hong-wei¹

(1. College of Civil Engineering, Tongji University, Shanghai 200092, China; 2. China Construction Communications Engineering Group

Corp. Ltd., Beijing 100142, China)

Abstract: Mastering the deformation laws of the surrounding rock during tunnelling is the key to the safety of construction. At present, the deformation detection of the tunnel section in the drilling and blasting method is mostly based on the total stations. Nevertheless, the amount of monitoring data applied in the detection was difficult to complete the fine analysis of convergence deformation. The wireless sensors network (WSN) is employed to realize the long-term continuous monitoring of key regions of the rock tunnel. Meanwhile, by setting up WSN monitoring equipment based on micro-electrical mechanical system sensors, a dynamic risk management and control system platform during tunnel construction based on Web is developed in Yingpanshan tunnel, Yunnan, China. Thus, the continuous monitoring of the deformation at the key region of the tunnel is realized. In addition, in accordance with the time series of deformation, the convergence deformation value of tunnel section is then predicted more accurately by the long short-term memory network. In summary, the performance of practical engineering application proves the effectiveness of the proposed method.

Key words: mountain tunnel; convergence deformation; wireless sensor network; long short-term memory network

0 引言

随着中国经济的稳步发展和综合国力的不断提高, 公路隧道的建设也日新月异。新奥法是目前山岭隧道建设的主要施工技术体系, 在新奥法的设计理念中, 对现场的监控量测是不可或缺的工作之一^[1]。尤其在目前信息化、智能化的趋势下^[2], 隧道施工的动态设计和实时响应依赖于对隧道断面收敛变形的把握。目前在钻爆法施工隧道中, 主要使用全站仪对断面变形进行检测, 但是采用这种方法获得的数据量较小, 只能通过利用非线性函数对数据进行回归拟合分

析的方法对隧道断面收敛变形值进行预测, 然而由于数据量小, 单次检测误差对拟合函数的影响较大, 简单的函数曲线很难精确地反映出隧道断面的收敛变形情况。

而随着无线通信技术和智能传感器的高速发展, 精确把握隧道断面的收敛变形情况成为了可能。Straser等^[3]针对土木工程中结构的变形监测问题提出了无线传感网络(WSN)的概念。在此之后, WSN

收稿日期: 2020-06-02

*通信作者 (E-mail: huanghw@tongji.edu.cn)

系统也被应用到了隧道变形的监控量测中^[4-6]。WSN 是一种分布式传感网络, 它通过无线通信技术将各种传感器节点联系起来。相较于使用全站仪每天或多天的检测频率, WSN 系统可以对隧道重点部位进行每小时甚至更密集的长时间连续监测, 这样可以得到较大的监测数据量, 并且呈现时间序列的特点。近年来, 国内外众多学者针对时间序列提出了很多处理方法。赵洪波^[7]基于支持向量机算法对围岩变形监测数据的非线性时间序列进行滚动预测。齐甦等^[8]建立了灰色-马尔可夫链模型对围岩的变形进行预测。Yao 等^[9]建立了递归神经网络的预测方法, 并采用插值的方法弥补了训练集不足的问题, 提高了预测模型的精度。Xu 等^[10]利用长短时记忆网络预测了边坡位移的周期项时间序列。Yang 等^[11]提出了一种基于长短时记忆网络的动态模型来预测三峡库区的边坡位移。但是, 对山岭隧道的实时无线安全感知和预测的研究尚少。

本文在营盘山隧道布设了一套 WSN 监测设备, 并构建了基于 Web 的隧道施工安全风险动态管控系统平台。通过 WSN 设备获得监控量测数据的时间序列, 用以此训练构造的长短时记忆 (long short-term memory, LSTM) 网络, 预测出监测位置的稳定变形值。

1 工程概况

营盘山隧道属于国家高速公路网 G4216 上海至成都高速公路工程华丽高速第 9 合同段, 位于云南省丽江市华坪县, 为双向四车道高速公路, 全长 11.31 km, 属特长公路隧道。隧道最大埋深约 877 m, 穿越地层条件复杂, 工程风险较高。

本文所监测的隧道段围岩属 IV 级围岩, 埋深约 450 m。营盘山隧道整体采用初期支护和二次衬砌相结合的复合式衬砌, 监测隧道段的监测时间为初期支护施作后至二次衬砌施作前的一段时间。

2 数据的采集及预处理

2.1 WSN 监测系统

无线传感网络 (WSN) 是一种分布式传感网络, 它通过无线通信技术将各种传感器节点联系起来。WSN 系统包括数据采集节点、中继节点、网关和云端服务器等。传感器节点使用 MEMS (micro electro mechanical system) 传感器, 具有体积小、成本低、功耗低和易于实现智能化等优点。数据采集节点采集该节点处所监测的数据, 基于 ZigBee 通讯协议通过中继节点传递给网关, 再通过 4G 网络从网关传递到云端服务器。在监测过程中, 用户可以使用个人电脑或移动终端等在云端对各传感节点的数据进行分析处理。

本文中布设的无线激光传感器属于数据采集节点 (图 1), 内置超低功耗的 CPU、RTC 芯片以及铁电存储器, 采用锂电池供电, 搭配高效 DC/DC 降压转换器, 并用 100 mm×100 mm×60 mm 大小的金属铸铝外壳封装, 具有 P6 防水能力。网关布设需要在 4G 信号良好的位置, 一般布设在隧道洞口。当数据采集节点与网关之间距离超过 500 m 时, 需要布设中继节点, 以便将监测数据由数据采集节点传输至网关。



图 1 无线激光传感器

Fig. 1 Wireless laser sensors

无线传感网络还可以调节其传感器节点的监控频率 (本文工程项目所采用的频率默认设定为每小时 1 次) 以适应不同的工程需求。凭借其小型化、无线化、实时性、灵活性等优势, 无线传感器网络将越来越多地应用于隧道结构的监控量测中。

2.2 WSN 系统布设

营盘山隧道采用上下台阶法钻爆开挖, 监测方案包含隧道左线的 3 个断面 (图 2), 其中, ZK23+080 断面下台阶已开挖, ZK23+110 和 ZK23+140 两个断面尚未进行下台阶开挖。本文选取较典型的 ZK23+080 里程断面的实际监测数据为研究对象, 共布设 3 个无线激光传感器 (图 3), 分别监测上台阶水平收敛值、下台阶水平收敛值和拱顶沉降值。为保护传感器设备不被钻爆施工破坏, 在初衬面施工前预留了 450 mm×300 mm×300 mm 大小的洞位, 用于布设无线激光传感器。另外, 施工粉尘沉积会对监测精度造成一定的影响, 本项目通过人工擦拭的方式除尘。




图 2 无线激光传感器布设位置

Fig. 2 Installation scheme of wireless laser sensors




图3 ZK23+080断面布设位置

Fig. 3 Installation scheme of section ZK23+080

在监测断面洞周上, 布设了一条 LED 风险警示灯带(图4), 基于隧道的收敛变形对现场工人进行预警、报警, 在隧道施工处于安全、预警和报警状态时, 灯带分别显示绿色、黄色和红色。根据《公路隧道设计规范》(JTG D70—2004), 各监测位置收敛变形的预警和报警值分别取 0.8%和 2.0%的洞周相对收敛值。



图4 LED 风险警示灯带

Fig. 4 LED light strip as risk level sign

2.3 监测数据预处理

本文构建了基于 Web 的隧道施工安全风险动态管控系统平台, 平台上直观地展现了工程概况、地理位置、工程进度及传感器的工作情况等, 管理人员还可以填写项目的相关资料并对隧道段进行风险评估。



图5 基于 Web 的管理平台

Fig. 5 Web-based management platform

由于初期支护的混凝土表面不平整等原因, 在平台上获得的实际施工中的监测数据不可避免地会产生一定的误差, 所以首先采用高斯滤波器对监测数据进

行降噪处理(图6)。高斯滤波器是一种线性平滑滤波器, 可以有效消除噪声的影响。对于缺损的数据点, 采用线性插值的方法进行补全^[9]。




图6 WSN 监测数据预处理

Fig. 6 Preprocessing of WSN monitoring data

无线激光传感器的监测精度为 1 mm, 去噪后的数据的误差都在可接受范围内。经过高斯滤波器去噪处理, 数据更加合理可信。

3 围岩变形时间序列预测

3.1 LSTM 网络介绍

长短时记忆(long short-term memory, LSTM)网络是循环神经网络(recurrent neural network, RNN)的一个变种, 它可以解决标准 RNN 神经网络对早期信息学习不足的问题^[12], 其核心是通过 3 个门来控制单元信息: 遗忘门、输入门和输出门。遗忘门决定丢

弃旧单元中的哪些信息,输入门决定在新单元中存储哪些信息,输出门决定输出哪些单元信息。LSTM 网络通过这种方式可以记住有用的信息,也可以忘记无用的信息,在时间序列的预测方面更具优势。

3.2 隧道监测位置变形预测

本文构建了1个3层LSTM网络来对隧道监测位置变形的时间序列进行预测,其中输入层、隐藏层、输出层神经元个数分别为1,4,1。在LSTM网络中对预处理后的数据进行训练,训练集与测试集的比例为2:1,预测至收敛变形值接近稳定为止(图7),得到各预测曲线的误差(表1)。由于训练样本的波动,得到的预测曲线仍具有一定的波动,故采用高斯滤波器进行去噪,可以得到隧道变形趋于稳定的收敛变形值。




图7 LSTM 时间序列预测
Fig. 7 Prediction of time series using LSTM

由此可以得到各监测位置稳定阶段的收敛变形值,上台阶水平收敛值为15.89 mm,下台阶水平收敛值为12.39 mm,拱顶沉降值为22.72 mm。

表1 LSTM 网络的均方根误差(RMSE)

Table 1 RMSE of LSTM networks		
监测项目	训练集误差	测试集误差
上台阶水平收敛	0.1310	0.1277
下台阶水平收敛	0.3570	0.4165
拱顶沉降	0.3012	0.2256

3.3 预测结果分析

模仿全站仪检测的模式,对每个时间序列等间距取6个数据点作为基础数据点,对于上台阶水平收敛和拱顶沉降,取11月6日下台阶开挖之后的数据。每个监测位置用3种常用非线性函数曲线对基础数据点进行拟合(图8),拟合结果用均方根误差评价(表2)。




图8 变形拟合曲线
Fig. 8 Fitting curves of deformation

在上、下台阶水平收敛的预测结果中可以看出,LSTM 网络对时间序列曲线的趋势预测更加准确,在基础数据点较少的情况下,相对于非线性曲线拟合的方法可以更加准确地反应隧道监测位置的变形细节。由于本文拱顶沉降的监测数据量过少,选取的基础数

据点尚不能反映变形之规律，因而不具有参考意义。

表 2 拟合曲线的均方根误差(RMSE)

Table 2 RMSE of fitting curves		
监测位置	拟合曲线	RMSE
上台阶水平收敛	LSTM	0.1310
	$y=15.47-11.11/x$	0.4200
	$y=x/(0.0118+0.0260x)-21.89$	0.3347
	$y=-13.81x^{(-0.634)}+18.39$	0.3105
下台阶水平收敛	LSTM	0.3570
	$y=14.99-14.39/x$	0.7181
	$y=x/(0.00187+0.0102x)-82.18$	0.8091
	$y=3120x^{(0.00227)}-3118$	1.3605

4 结 论

本文在营盘山隧道布设 WSN 系统的基础上，基于监测数据的时间序列，采用 LSTM 网络对监测位置的收敛变形进行预测。主要结论如下：

（1）将 WSN 系统布设在营盘山隧道中，有效地监测了 ZK23+080 里程断面各位置的收敛变形，证明 WSN 系统对山岭隧道施工期的形变监测具有一定的工程可行性和应用价值。

（2）构建了基于 Web 的隧道施工安全风险动态管控系统平台，管理人员可以在平台上获取项目的有关信息并实时查看传感器的工作情况。

（3）提出了采用 LSTM 网络预测山岭隧道的收敛变形值，利用机器学习方法结合 WSN 系统得到的大量数据，可以更加准确地反映隧道断面变形的过程。

参考文献：

[1] 孙克国, 李术才, 张庆松, 等. 特长山岭隧道衬砌监测及模拟研究[J]. 岩石力学与工程学报, 2007, **26**(增刊 2): 4465 - 4470. (SUN Ke-guo, LI Shu-cai, ZHANG Qing-song, et al. Study on monitoring and simulation of super-long mountain tunnel lining[J]. Chinese Journal of Rock Mechanics and Engineering, 2007, **26**(S2): 4465 - 4470. (in Chinese))

[2] 钱七虎. 隧道工程建设地质预报及信息化技术的主要进展及发展方向[J]. 隧道建设, 2017, **37**(3): 251 - 263. (QIAN Qi-hu. Main developments and directions of geological prediction and informatized technology of tunnel construction[J]. Tunnel Construction, 2017, **37**(3): 251 - 263. (in Chinese))

[3] STRASER E G, KIREMIDJIAN A S, MENG T H, et al. Modular, wireless network platform for monitoring structures[J]. Computer Standards & Interfaces, 1999, **21**(2): 117.

[4] 徐 然. 地铁盾构隧道结构变形的无线 MEMS 倾角传感器研究[D]. 上海: 同济大学, 2013. (XU Ran. Study of Wireless MEMS Inclinator for Structural Deformation Monitoring of Shield Subway Tunnel[D]. Shanghai: Tongji University, 2013. (in Chinese))

[5] 王明卓, 黄宏伟. 土木工程风险可视化的监测预警方法[J]. 防灾减灾工程学报, 2015, **35**(5): 612 - 616. (WANG Ming-zhuo, HUANG Hong-wei. Monitoring and pre-warning of risk visualization for civil engineering[J]. Journal of Disaster Prevention and Mitigation Engineering, 2017, **37**(3): 251 - 263. (in Chinese))

[6] 张东明, 黄宏伟, 王 飞, 等. 盾构隧道结构安全智慧感知技术研究[C]// 中国土木工程学会 2016 年学术年会论文集, 2016 北京. (ZHANG Dong-ming, HUANG Hong-wei, WANG Fei, et al. Wireless sensing network based monitoring system for safety of shield tunnel structures[C]// Proceedings of the 2016 Annual Conference of the China Civil Engineering Society, 2016, Beijing. (in Chinese))

[7] 赵洪波. 支持向量机在隧道围岩变形预测中的应用[J]. 岩石力学与工程学报, 2005, **24**(4): 649 - 652. (ZHAO Hong-bo. Predicting the surrounding deformations of tunnel using support vector machine[J]. Chinese Journal of Rock Mechanics and Engineering, 2005, **24**(4): 649 - 652. (in Chinese))

[8] 齐 甦, 周德军, 王立英, 等. 基于灰色-马尔可夫链的隧道围岩变形预测研究[J]. 现代隧道技术, 2013, **50**(1): 80 - 86. (QI Su, ZHOU De-jun, WANG Li-ying, et al. Research on forecast of tunnel surrounding rock deformation based on Grey-Markov Chain[J]. Modern Tunnelling Technology, 2013, **50**(1): 80 - 86. (in Chinese))

[9] YAO W, ZENG Z, LIAN C, et al. Training enhanced reservoir computing predictor for landslide displacement[J]. Engineering Geology, 2015, **188**: 101 - 109.

[10] XU S, NIU R, et al. Displacement prediction of Baijiabao landslide based on empirical mode decomposition and long short-term memory neural network in Three Gorges area, China[J]. Computers and Geosciences, 2018, **111**(1): 87 - 96.

[11] YANG B, YIN K, LACASSE S, et al. Time series analysis and long short-term memory neural network to predict landslide displacement[J]. Landslides (Springer), 2019, **16**: 677 - 694.

[12] SCHMIDHUBER J. Gradient Flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies[M]. Gradient Flow in Recurrent Nets: The Difficulty of Learning Long Term Dependencies, Wiley-IEEE Press, 2001.

（编校：黄贤沙）