

基于 LSTM 网络的箱梁桥应变与挠度的非线性映射模型研究

宋永生¹, 丁幼亮², 董逸轩²

(1. 金陵科技学院建筑工程学院, 江苏 南京 211169; 2. 东南大学土木工程学院, 江苏 南京 210096)

摘要:以烈士河大桥(12联混凝土简支箱梁桥)为例, 基于长短期记忆(LSTM)网络建立了应变和挠度监测数据间的非线性映射模型。首先, 运用小波包分解与重构方法分离实测应变数据中的温度应变, 得到车载应变数据。然后, 运用 LSTM 网络分别构建应变和挠度的单对单和多对多映射模型。结果表明, 单对单和多对多映射模型的相关性和误差均满足控制标准; 多对多映射模型的回归预测偏差较单对单映射模型更小, 性能优于单对单映射模型。

关键词:长短期记忆网络; 箱型梁; 非线性映射; 应变; 挠度

中图分类号: U447

文献标识码: A

文章编号: 1672-755X(2021)04-0061-06

Research on Nonlinear Mapping Model of Strain and Deflection of Box-Girder Bridge Based on LSTM Networks

SONG Yong-sheng¹, DING You-liang², DONG Yi-xuan²

(1. Jinling Institute of Technology, Nanjing 211169, China; 2. Southeast University, Nanjing 210096, China)

Abstract: Taking Martyr River Bridge(a 12-box simply supported concrete box-girder bridge) as an example, a nonlinear mapping model of strain and deflection is established based on long short-term memory(LSTM) networks. First, the method of wavelet packet decomposition and reconstruction is used to separate the temperature-induced strain component to obtain the vehicle-induced strain. Then, the single-to-single and many-to-many mapping models of strain and deflection are constructed by using LSTM networks. The results show that the correlation and error of both the single-to-single and many-to-many mapping models meet the requirement of the control standards, the regression prediction error of the many-to-many mapping model is smaller than that of the single-to-single mapping model, and the performance of the many-to-many mapping model is better than that of the single-to-single mapping model.

Key words: long short-term memory networks; box beam; nonlinear mapping; strain; deflection

桥梁作为交通系统的枢纽, 在国家的交通运输行业中发挥了重要作用。其中, 中小型混凝土桥梁的数量占全部桥梁的 90% 以上^[1]。由于自然环境和交通荷载的长期作用, 不可避免地会出现一系列如材料腐

收稿日期: 2021-08-04

基金项目: 国家自然科学基金青年项目(51580251); 江苏省“六大人才高峰”高层次人才项目(jz-062); 江苏省高校自然科学基金面上项目(17KJB560004)

作者简介: 宋永生(1984—), 男, 安徽蚌埠人, 副教授, 博士, 主要从事结构健康监测与安全评估研究。

蚀、裂缝开展等影响桥梁健康状态的结构损伤。当损伤开展到一定程度,有可能酿成严重的安全事故,对人民生命安全和经济社会造成巨大的损失^[2]。桥梁健康监测是为使桥梁安全运营而发展起来的技术,旨在对桥梁结构状况进行监测和评估,保障桥梁安全运营^[3]。但是现存的桥梁健康监测系统在保证历史数据采集和储存的前提下,无法满足实时评估、预警结构性能和健康状态方面的需求^[4]。

国内外学者已经尝试将神经网络应用于桥梁健康监测。Dorafshan 等将深度卷积神经网络应用在混凝土结构的裂缝检测中^[5];Lopes 等将基于阻抗的结构健康监测技术与人工神经网络结合,提出了一种不需要模型的结构损伤定位和表征技术^[6];Carden 和 Brownjohn 采用协方差驱动的随机子空间识别方法对瑞士 Z24 桥数据进行模态参数识别^[7];Kang 和 Cha 利用超声波信号代替 GPS,建立了以卷积神经网络(convolutional neural network,CNN)进行损伤检测、以地理标记方法进行损伤定位的自主无人机检测方法^[8];Liang 提出了一种基于三层图像的钢筋混凝土桥梁灾后检测方法^[9];Alavi 等将有限元法与概率神经网络相结合,开发了一种损伤识别数据解释系统^[10];王蕾等提出了一种基于径向神经网络的有限元数值模型修正方法^[11];任普基于南京大胜关高速铁路钢桁拱桥的实际监测数据建立了基于机器学习和大数据平台的数据清洗算法^[12];肖鑫运用 BP 神经网络建立环境温度、车辆荷载与桥梁实测模态频率的映射关系模型^[13];袁灿提出一种基于前馈网络的监测系统传感器优化布置方法^[14]。但是,面对现实中桥梁的复杂工程环境条件和车辆荷载作用,以及长期服役造成的疲劳和腐蚀损伤,桥梁的性能评估和损伤预警仍存在很多需要研究的问题,数据采集、存储、传输和分析等领域都有提高的空间。

本文基于长短期记忆(long short-term memory,LSTM)网络的深度学习技术,对烈士河大桥 57 d 的监测数据进行处理和分析,构建局部响应和全局响应间的非线性映射模型,从而建立局部响应和全局响应之间稳定的非线性映射关系。


1 烈士河大桥监测系统

1.1 桥梁概况

烈士河大桥位于江苏沿海高速公路盐城—南通段,跨越如皋市烈士河,2001 年建成通车。桥梁上部结构采用 25 m 跨径、先简支后连续、部分预应力混凝土组合箱梁,共 72 孔,分 12 联,每联 6 孔,桥梁全长 2 168.20 m。桥梁梁高约 1.5 m,下部结构为桩柱式墩台。设计荷载为汽车—超 20 级,挂车—120。

1.2 桥梁监测系统

2015 年,烈士河大桥安装了监测系统。系统将左幅和右幅第 2 联第 5 跨跨中截面作为应变、位移和温度监测截面,应变、位移和温度的采样频率均为 200 Hz。以左幅第 5 跨为例,其跨中测点整体布置见图 1(a),横向布置见图 1(b)。



2 桥梁车载响应数据分析

2.1 车载应变数据提取

桥梁结构处于复杂的车辆荷载和环境之下,应变响应主要受温度荷载和车辆荷载影响。为了研究车辆荷载导致的桥梁应变效应与位移响应之间的关系,有必要对桥梁动应变数据进行分离,剔除其中的温度影响成分。由于温致应变信号主要集中在低频带,而车致应变信号主要集中在高频带,因此采用小波变换分析方法对应变数据进行处理。为减少数据量,对应变信号采集过程进行降频(采集频率由 200 Hz 降低为 50 Hz)处理后,再对温度和应变数据进行频谱分析,得到温度数据的主要频率范围在 $[0 \text{ Hz}, 2 \times 10^{-3} \text{ Hz}]$,由此将小波包分解的最佳分解尺度 N 定为 13^[15]。

通过上述方法对 2018 年 4—6 月共 57 d 的应变数据进行处理。图 2(a)为 S1 传感器的车致应变时程曲线;图 2(b)为相同时段的 D1 传感器的位移时程曲线。从图中可以看出,当横坐标在 $1.0 \times 10^4 \sim 1.4 \times 10^4$ 时,应变时程和位移行程均有 3 个波动段,且横坐标相近,表明车致应变与动位移具有一定的映射关系,因此车致应变的数据处理结果是合理的。




图 2 S1 和 D1 的响应曲线

2.2 数据归一化

为消除奇异样本数据导致的不良影响,需对数据进行归一化处理。采用式(1)所示的均值方差归一化方法,即将数据集变换为均值为 0、标准差为 1 的样本数据 x_i , μ 表示样本集 X_i 的均值, σ 表示 X_i 的标准差。在下文模型的建立过程中,首先对训练集进行归一化,并将训练集的归一化参数应用于验证集和测试集。

$$x_i = \frac{X_i - \mu}{\sigma} \quad (1)$$

3 桥梁应变-挠度多尺度响应非线性映射模型

3.1 模型结构

图 3 为基于 LSTM 网络的桥梁应变-挠度非线性映射分析流程。采用的 LSTM 网络由 6 层组成,即

序列输入层、LSTM 隐藏层、第一全连接层、Dropout 层、第二全连接层、回归输出层。结构参数主要包括隐藏层单元数、全连接层单元数、网络训练的最大训练轮次(epochs, EP)、最小批处理(mini-batch, MB)大小、学习率及其下降方案、Dropout 层丢失概率等。在训练时,如 LSTM 网络可以通过 T_a 校验,且人工检查回归结果与实测结果的变化趋势一致,则可认为该 LSTM 网络合格。反之,则需要调整参数,重新训练网络,直到 LSTM 网络通过校验为止。




图 3 基于 LSTM 网络的桥梁应变-挠度非线性映射分析流程

3.2 模型参数

网络训练时,将学习率设置为随训练轮次增加而逐渐减小,减小方式为每训练 10 个批次,学习率降为原来的 1/2。以 1 200 为模数对数据序列进行拆分,分成若干条长度为 1 200 的数据序列段,形成总数据集。选取其中前 90% 作为训练集,中 9% 作为验证集,后 1% 作为测试集。

经多次训练,选择第一全连接层的输入维度为 50,输出维度为 1,Dropout 层的丢失概率设定为 0.5,第二全连接层的输入维度和输出维度均为 1,网络训练求解器选择自适应矩估计优化器,LSTM 隐藏层单元数设置为 150,EP 设置为 100,MB 为 128,初始学习率设置为 0.01。

3.3 损失函数

损失函数采用预测响应的平均方误差指标,其计算公式如下。

$$loss = \frac{1}{2} \sum_{j=1}^R (t_j - y_j)^2 \quad (2)$$

式中 R 表示预测响应数量, t_j 表示实测响应, y_j 是对 t_j 的预测响应输出。训练时,模型会计算每个小批次中所有实测值的平均损失。

3.4 判定模型

采用均方根误差(RMSE)作为模型是否通过验证集校验的判断指标。RMSE 的计算公式如下。

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - r_k)^2} \quad (3)$$

式中 N 表示测试序列长度, y_k 表示第 k 个实测响应, r_k 表示对第 k 个实测响应的模型回归值。定义 T_a 为 RMSE 除以目标测试序列数据的幅值:

$$T_a = \frac{RMSE}{A_t} \quad (4)$$

式中 A_t 表示每个目标序列数据的幅值,幅值等于序列的最大值减去最小值。测试序列中 T_a 的平均值应当小于预期值(本文取为 0.05^[12])。

4 结果与分析

4.1 单对单映射模型

在建立桥梁应变-挠度非线性映射模型时,选取 S1 采集的动应变数据作为输入,将 D1 采集的动位移数据作为输出,构建单对单映射模型。图 4 为单对单映射模型在测试集的时程拟合曲线和散点图。从图中可以看出,单对单映射模型准确地预测了目标数据的变化趋势,得到了局部响应和全局响应的稳定非线性映射关系;散点图相关系数接近 1.0,大多数数据比较接近真实值。但是,仍有部分数据点偏离拟合直线,这可能是因相邻车辆在过桥时对彼此的结构响应造成影响。

表 1 为单对单映射模型在训练集、验证集、测试集的相关参数。从表中可以看出 $RMSE$ 和 T_a 在训练集上较低,在验证集上略有提升,在测试集上最高;相关系数 R 在各种数据集上都大于 0.9; T_a 在 3 个数据集上均远低于上限值 0.075。可以认为模型得到良好训练,并且在测试集上表现优秀,映射关系明显且稳定。




图 4 单对单映射模型测试结果

表 1 单对单映射模型分析参数

集合	$RMSE$	T_a	R
训练集	0.066 8	0.004 9	0.959 0
验证集	0.091 8	0.007 0	0.935 8
测试集	0.113 4	0.019 8	0.921 2

4.2 多对多映射模型

多对多映射模型选取 S1、S3、S5、S7 这 4 个传感器采集到的动应变数据作为输入,将 D1、D2、D3、D4 采集到的动位移数据作为输出,构建多对多映射模型。模型构建和检验流程与单对单映射模型相同。以 D1 处的动位移数据为例,图 5 为多对多映射模型在测试集的时程拟合曲线和散点图。可以看出,拟合数据和实际数据吻合较好。表 2 为多对多映射模型在训练集、验证集、测试集的相关参数。




图 5 多对多映射模型测试结果

表 2 多对多映射模型分析参数

集合	$RMSE$				T_a				R			
	D1	D2	D3	D4	D1	D2	D3	D4	D1	D2	D3	D4
训练集	0.056 4	0.071 5	0.062 0	0.072 2	0.004 2	0.004 8	0.004 7	0.004 5	0.971 5	0.989 6	0.983 8	0.992 2
验证集	0.067 3	0.081 7	0.080 7	0.081 3	0.005 2	0.005 4	0.008 1	0.006 6	0.968 8	0.988 3	0.985 3	0.990 7
测试集	0.085 1	0.096 5	0.089 9	0.097 4	0.015 7	0.008 3	0.009 4	0.007 3	0.961 6	0.987 5	0.983 4	0.988 4

对比单对单映射模型可以发现,多对多映射模型在测试集中的 T_a 平均值为 0.010 2、 R 平均值为 0.980 2,分别较单对单映射模型减少 48.6%、增加 6.4%。这意味着多对多映射模型的回归预测偏差较单对单映射模型更小,模型性能优于单对单映射模型。因此,多源输入数据联合训练得到的映射模型的准确率和稳定性比仅采用单维数据进行训练的模型更高。

5 结 语

1)桥梁动应变的主要影响因素是温度荷载和车辆荷载,其中温致应变集中在低频带,车致应变主要集中在高频带。采用小波包分解与重构的方法,可将温致应变剔除,得到车致应变,可用于构建桥梁局部响应与全局响应的非线性映射关系。

2)将监测数据集按 90%、9%、1% 的比例构建训练集、验证集和测试集,无论单对单还是多对多映射模型,其测试集 T_a 均远低于控制上限 0.075,表明使用 LSTM 网络能够构建稳定的局部响应-全局响应的非线性映射模型。

3)多对多映射模型的回归预测偏差较单对单映射模型更小,模型性能明显优于单对单映射模型。这说明多对多映射模型可对输出数据进行多维校正和修复,因此得到的映射模型的准确率和稳定性比仅采用单维数据进行训练的模型更高。

参考文献:

- [1] 中华人民共和国交通运输部. 2018 年交通运输行业发展统计公报[EB/OL]. (2019-04-12)[2021-07-05]. https://xxgk.mot.gov.cn/2020/jigou/zhghs/202006/t20200630_3321179.html
- [2] 孙信,武建,章吉祥,等. 拓宽工程中既有桥梁加固方案的多指标模糊综合评价[J]. 南京工程学院学报(自然科学版), 2020,18(4):77-83
- [3] 李爱群,缪长青. 桥梁结构健康监测[M]. 北京:人民交通出版社,2009
- [4] 李爱群,丁幼亮,王浩,等. 桥梁健康监测海量数据分析与评估——“结构健康监测”研究进展[J]. 中国科学:技术科学, 2012,42(8):972-984
- [5] DORAFSHAN S, THOMAS R J, MAGUIRE M. Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete[J]. Construction and Building Materials, 2018,186:1031-1045
- [6] LOPES Jr V, PARK G, CUDNEY H H, et al. Impedance-based structural health monitoring with artificial neural networks[J]. Journal of Intelligent Material Systems and Structures, 2000,11(3):206-214
- [7] CARDEN E P, BROWNJOHN J M W. Fuzzy clustering of stability diagrams for vibration-based structural health monitoring[J]. Computer-Aided Civil and Infrastructure Engineering, 2008,23(5):360-372
- [8] KANG D, CHA Y J. Autonomous UAVs for structural health monitoring using deep learning and an ultrasonic beacon system with geo-tagging[J]. Computer-Aided Civil and Infrastructure Engineering, 2018,33(10):885-902
- [9] LIANG X. Image-based post-disaster inspection of reinforced concrete bridge systems using deep learning with Bayesian optimization[J]. Computer-Aided Civil and Infrastructure Engineering, 2019,34(5):415-430
- [10] ALAVI A H, HASNI H, LAJNEF N, et al. An intelligent structural damage detection approach based on self-powered wireless sensor data[J]. Automation in Construction, 2016,62:24-44
- [11] 王蕾,郁胜,李宾宾,等. 基于径向神经网络的桥梁有限元模型修正[J]. 土木工程学报, 2012(S2):11-15
- [12] 任普. 基于大数据的桥梁监测数据清洗方法研究[D]. 南京:东南大学, 2019
- [13] 肖鑫. 基于车-桥一体化监测的铁路钢桥损伤预警及可靠度评估研究[D]. 北京:中国铁道科学研究院, 2017
- [14] 袁灿. 基于深度学习的桥梁健康监测传感器优化布置方法研究[D]. 重庆:重庆交通大学, 2018
- [15] ZHAO H W, DING Y L, LI A Q, et al. Digital modeling on the nonlinear mapping between multi-source monitoring data of in-service bridges[J]. Structural Control and Health Monitoring, 2020,27(11):e2618

(责任编辑:湛 江)