

DOI: 10.11835/j.issn.2096-6717.2021.146



开放科学(资源服务)标识码(OSID):



基于 LSTM 神经网络的多源数据融合桥梁变形重构方法

张立奎¹, 段大猷^{2a,2b}, 王佐才^{2a,2c}

(1. 安徽省交通控股集团有限公司, 合肥 230088; 2. 合肥工业大学 a. 土木与水利工程学院; b. 安徽省基础设施安全检测与监测工程实验室; c. 土木工程防灾减灾安徽省工程技术研究中心, 合肥 230009)

摘要:桥梁变形是桥梁状态评估的重要指标,在测量桥梁位移时,直接测量方法如 LVDT、RTK-GPS、LDV 等在实际应用中有很多局限性。由于从所测得的动应变中获得实时的位移模态和应变模态较为困难,而且大多数应变测量的采样频率较低,基于应变的间接桥梁变形重构方法在应用中仍存在一定的不足。提出一种基于长短时记忆(LSTM)神经网络重构桥梁变形的办法,该网络融合应变和加速度数据在训练后可以用作测量数据实时重构桥梁的变形。在应变模态、位移模态以及桥梁中性轴未知的情况下,该方法可以准确地重构变形。通过数值模拟和试验验证了重构结果的准确性,结果表明,基于 LSTM 的数据融合方法在不同条件下都可以实现高精度的桥梁变形重构。

关键词:位移重构;数据融合;长短时记忆网络;结构健康监测;位移监测

中图分类号:U446.3 **文献标志码:**A **文章编号:**2096-6717(2022)03-0037-07

A multi-source data fusion method for bridge displacement reconstruction based on LSTM neural network

ZHANG Likui¹, DUAN Dayou^{2a,2b}, WANG Zuocai^{2a,2c}

(1. Anhui Transportation Holding Group Co., Ltd., Hefei 230088, P. R. China; 2a. School of Civil Engineering; 2b. Anhui Engineering Laboratory of Infrastructural Safety Inspection and Monitoring; 2c. Anhui Engineering Technology Research Center of Disaster Prevention and Mitigation in Civil Engineering, Hefei University of Technology, Hefei 230009, P. R. China)

Abstract: Deformation of the bridge is an important index of bridge condition assessment. The direct measurement methods for the bridge deformation such as LVDT, RTK-GPS and LDV have a lot of limitations. Because it is difficult to obtain the real-time displacement modes and strain modes from the measured dynamic strains while the sampling frequency of strain measurement is low, the indirect bridge deformation reconstruction method based on strain still has some shortcomings in engineering practice.

收稿日期:2021-04-23

基金项目:国家自然科学基金(51922036);安徽省重点研发计划(1804a0802204)

作者简介:张立奎(1967-),男,教授级高工,主要从事大跨桥梁设计及健康监测研究,E-mail:zhanglk49X@ahjkt.com.

王佐才(通信作者),男,教授,博士生导师,E-mail:wangzuocai@hfut.edu.cn.

Received:2021-04-23

Foundation items:National Natural Science Foundation of China (No. 51922036); Key Research and Development Plan of Anhui Province (No. 1804a0802204)

Author brief:ZHANG Likui (1967-), professorate senior engineer, main research interests: design and health monitoring of long span bridges, E-mail: zhanglk49X@ahjkt.com.

WANG Zuocai (corresponding author), professor, doctoral supervisor, E-mail: wangzuocai@hfut.edu.cn.

This paper proposed a data fusion method to reconstruct the deformation of bridge structure based on LSTM neural network using the measured strain and acceleration data. In this paper, the accuracy of the reconstruction results is verified by numerical simulation and experiment without strain modes, displacement modes and neutral axis. The results show that data fusion method based on LSTM can achieve high accuracy under different conditions.

Keywords: deformation reconstruction; data fusion; long-short term memory network; structural health monitoring; displacement monitoring

桥梁的位移是桥梁健康监测中的重要参数,可以直接反映桥梁的变形及运营状态。在工程中,通常采用水准测量系统直接测量位移,但这种方法难以长期监测位移且测量频率低。其他的位移直接测量方法,如线性差动变压器(LVDT)、实时动态差分全球定位系统(RTK-GPS)^[1]、激光多普勒振动仪(LDV)^[2]、雷达传感器^[3]、激光雷达(LiDAR)^[4]、计算机视觉方法^[5],存在设备成本高、采样率低、适用性有限等缺点。对于间接测量法,倾角仪挠曲重构法的测量精度相对较低,而且用倾角仪进行动挠度测量时,对各倾角仪的相位差、瞬态反应以及零漂等有着较高的要求^[6]。近年来,应变的测量精度获得了较大提高,特别是分布式光纤光栅传感技术的应用,可以实现桥梁应变的分布式监测,故基于应变的挠度测量方法获得较广泛的应用^[7-9]。

对于使用动应变的桥梁实时动态变形重构,主要使用基于位移-应变传递关系的方法,该方法需要提前获得结构的位移模态和应变模态^[10-11]。然而由于车桥耦合结构系统随时间变化,且测得的桥梁动应变受环境因素和噪声影响^[12-13],难以直接从所测得的动应变中获得实时的位移模态和应变模态。动应变的采样频率通常比加速度的采样频率低,基于动应变获得的桥梁动态变形会受到采样频率的影响。最近,有学者提出基于融合应变和加速度数据的桥梁变形监测方法,即通过动应变获得桥梁结构的变形后,再与加速度数据融合,以获得桥梁振动变形,提高桥梁动态变形的测量精度^[14]。

对于实际桥梁的复杂结构,难以准确地获得桥梁的边界条件及模态振型,产生的误差可能影响最终变形重构的精度。Moon 等^[15]提出了一种基于 BP 神经网络和桥梁纵向应变的实时桥梁挠度重构方法。Tian 等^[16]使用双向 LSTM 神经网络构建了斜拉桥索力监测数据与主梁挠度的关系模型。LSTM 作为一种循环神经网络(RNN)体系结构被广泛应用于时间序列建模中^[17-19],也可以应用于基

于监测数据的变形监测。笔者建立了多层堆叠 LSTM 神经网络,通过数据训练建立应变、加速度监测数据与桥梁变形的关系,实现了数据融合,变形重构在数值模拟及试验验证中获得良好的结果,具有较高的精度。

1 多源数据融合 LSTM 神经网络

1.1 LSTM 算法原理

LSTM 神经网络具有长时间记忆信息的特性,不仅可以从单个数据点提取信息,还可以从整个系列数据中提取信息。LSTM 神经网络允许信息持久化循环,其结构由元胞序列构成。神经网络的元胞结构如图 1 所示, x_t 是时间序列的输入, h_t 是时间序列的输出, t 表示时间。




图 1 LSTM 元胞的结构

Fig. 1 The structure of the LSTM cell

在 LSTM 单元中,函数 σ 和 \tanh 表示为

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

神经网络元胞中有 3 种门:遗忘门、输入门和输出门。遗忘门通过式(3)决定需要保留多少 C_{t-1} 状态参数;输入门使用式(4)和式(5)确定保存到 C_t 的输入;输出门通过式(6)~式(8)控制输出。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (5)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(C_t) \quad (7)$$

$$C_t = f_t \times C_{t-1} + i_t * \tilde{C}_t \quad (8)$$

式中: $f_t, i_t, \tilde{C}_t, o_t$ 均为 LSTM 元胞内部函数; C_t 和 h_t 是两个记忆向量; 通过神经网络的训练获得参数 $W_f, b_f, W_i, b_i, W_c, b_c, W_o$ 和 b_o 。式(8)中的 \times 表示 Hadamard 乘积。使用的堆叠 LSTM 神经网络示意图如图 2 所示, 该网络由 3 层 LSTM 层组成, 每层 LSTM 由图 1 所示的元胞链式构成, 图中的 A 表示 LSTM 元胞。




图 2 堆叠 LSTM 神经网络结构

Fig. 2 The structure of the stacked LSTM neural network

1.2 LSTM 神经网络重构变形流程

多源数据融合变形重构方法流程示意图如图 3 所示。首先对应变和加速度的原始数据进行预处理, 采样频率与加速度一致的应变数据可以直接作为神经网络的输入, 对低采样频率的应变数据进行三次样条插值至与加速度数据采样频率一致。

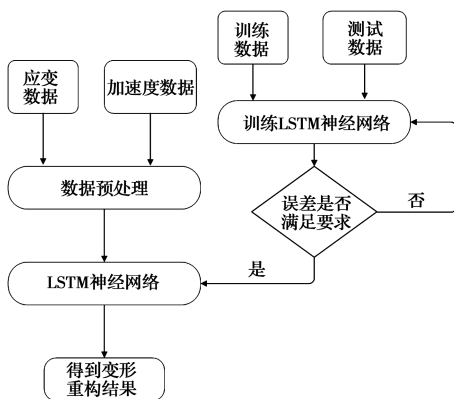


图 3 桥梁变形重构流程

Fig. 3 The process of bridge displacement reconstruction

由于输入原始加速度数据后神经网络的变形重构精度不理想, 为保证重构变形的高频精度, 对加速度数据进行预处理。对加速度二次积分并通过 FIR 滤波器去除积分过程中产生的低频漂移现象, 将预处理后的数据作为神经网络的输入数据。通过有限

元模拟或者实际测量获得神经网络训练数据, 经过训练获得 LSTM 神经网络。实际应用中, 将预处理之后的数据输入训练好的堆叠 LSTM 神经网络中, 即可获得桥梁的变形位移。

2 数值模拟

2.1 有限元模型

使用有限元模拟软件建立桥梁动态车桥耦合系统的有限元模型。该桥为混凝土桥面、工字钢主梁 4 跨连续梁桥, 每跨 35 m。混凝土桥面厚度为 0.22 m, 杨氏模量为 34.5 GPa, 泊松比为 0.2, 密度为 2 700 kg/m³。工字梁高 1.8 m, 截面面积为 854.4 cm², 上翼缘宽度为 800 mm, 下翼缘宽度为 960 mm。工字钢梁的杨氏模量为 206 GPa, 泊松比为 0.28, 密度为 7 850 kg/m³。车辆为具有二次悬挂的 55 t 卡车。桥梁整体如图 4 所示, 桥梁横截面如图 5 所示。桥面铺装的不平整度为国家标准 GB/T 920—2002 中规定的 c 类。




图 4 桥梁有限元模型

Fig. 4 The bridge finite element model




图 5 桥梁模型横截面

Fig. 5 The cross-section of the bridge model

选取一侧主梁对该方法进行验证, 通过有限元法获得主梁测点处的应变、加速度和位移。应变、加速度和位移的采样率均为 100 Hz, 对数值计算获得的应变和加速度数据添加 5% 的高斯白噪声以模拟实际测量的误差。测量点的布置如图 6 所示。

2.2 神经网络训练

通过有限元车桥耦合系统模拟获得神经网络的




图 6 测点分布图

Fig. 6 The arrangement of the measuring points

训练数据。训练数据包括一辆卡车以 50 km/h 和 80 km/h 的速度行驶通过桥梁,以及多辆卡车以 50 km/h 的速度通过桥梁。

在 LSTM 神经网络的训练中,较大的批量 (batch size) 通常导致更快的模型收敛,但可能最终收敛不佳;较小的批量会导致训练过程波动较大。基于 Bengio^[18] 的研究,大于 10 的批量计算速度较快,本文使用的神经网络训练批次大小设为 32。选取激活函数时,由于 Sigmoid 函数容易产生梯度消失,Relu 函数可能导致训练过程中梯度归零的问题,因此,激活函数选用 Tanh 函数。优化算法为 Adam,该算法对每个配置参数使用最佳实践初始值,适用于各种问题。当 dropout 参数为 0 时,神经网络训练出现了过拟合;当 dropout 参数设为 0.3 时,神经网络开始欠拟合。为了使 LSTM 达到最佳精度,使用正则化方法将 dropout 参数设为 0.2。

为了选择合适的隐藏层数,图 7 比较了不同隐藏层的堆叠 LSTM 神经网络的训练损失,训练的遗忘率都设为 0.2。均方误差 (Mean Squared Error, MSE) 表示在训练堆叠 LSTM 网络时每个时间步的训练损失。训练损失可以表示为

$$\text{loss} = \frac{1}{n} \sum_{i=1}^n (\bar{d}_i - d_i)^2 \quad (9)$$

式中: \bar{d}_i 和 d_i 分别表示变形重构值和实际位移值。具有 3 层隐藏 LSTM 层的神经网络在训练中可以达到更高的精度。




图 7 不同层数 LSTM 神经网络的训练损失

Fig. 7 The traing losses of LSTM neural networks with rarious hidden layers

2.3 变形重构结果

经过训练的神经网络可以完成对桥梁变形的重

构,对基于加速度的 FIR 滤波器^[19]、基于应变模态^[10]以及 LSTM 数据融合的变形重构方法结果进行对比。本例中,3 辆载重 55 t 的卡车以 60 km/h 的速度通过桥梁,卡车之间的距离是 35 m。重构位移与实际位移的对比如图 8 所示。




图 8 位移重构结果对比

Fig. 8 Comparisons of deformation reconstruction results

各个测点的重构位移误差如表 1 所示,提出的方法在多车荷载情况下具有较高的准确性,误差最大不超过 7.5%。而基于加速度的位移重构方法, FIR 滤波器消除了输入数据的低频信息,避免了低频漂移,但也因此导致位移重构误差较大。与基于应变的方法相比,提出的 LSTM 神经网络变形重构方法增加了加速度数据,提高了变形重构的精度。经过简单的训练,堆叠 LSTM 神经网络即可完成数据融合并构建测量数据与变形的关系,结果表明,该方法可以获得更高的精度。

表 1 各测点的误差

Table 1 Errors at different measuring points

测点	误差/%		
	数据融合方法	基于应变	基于加速度
N2	7.50	13.05	96.67
N5	5.45	7.14	43.53
N8	4.13	5.41	44.37
N11	3.98	4.44	36.53

3 试验验证

3.1 试验概况

为了进一步验证利用应变和加速度数据融合的位移重构方法,对不同边界条件的梁进行试验。试验梁为长 2.8 m 的铝梁,宽度为 100 mm,厚度为 20 mm,弹性模量为 70 GPa,泊松比为 0.33,梁的密度为 2 700 kg/m³。试验验证了简支梁和连续梁的工况。

简支梁表面均匀放置 7 个应变传感器,间距为 35 cm。在 1/4、1/2 和 3/4 跨距处安装加速度传感器和电涡流位移传感器。对于两跨连续梁,去除了梁中点处的传感器,其余传感器的布置与简支梁相同。简支梁和两跨连续梁的传感器布置如图 9 所示,整体布置和信号采集系统如图 10 所示。在采样频率为 200 Hz 的情况下,测量了应变、加速度和位移。




图 9 传感器布置示意图

Fig. 9 Arrangement diagram of the sensors




图 10 试验梁和数字采集系统

Fig. 10 The tested beam and data acquisition system


3.2 试验结果

在变形重构前需要对 LSTM 神经网络进行训练,使用的 LSTM 神经网络结构以及相关参数与 2.2 节一致。


3.2.1 简支梁 对试验梁施加随机锤击激励,先通过 20 s 数据对 LSTM 神经网络进行训练。训练后的神经网络即可重构目标点的位移,位移重构结果如图 11 所示。



(a) 测点 2 处的位移



(b) 测点 4 处的位移



(c) 测点 6 处的位移

图 11 简支梁重构位移对比

Fig. 11 Reconstructed displacement comparisons of the simply supported beam

为了深入分析变形重构结果,每 2 s 对试验结果计算一次误差,误差函数定义为

$$E = \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{d}_i - d_i)^2} \times 100\% \quad (10)$$

max(d_i)

式中: n 为数据的数量; \bar{d}_i 和 d_i 分别为重构位移和真实位移。误差如图 12 所示。

3.2.2 连续梁 对连续梁施加随机锤击激励,位移对比如图 13 所示。基于数据融合的 LSTM 变形重构方法结果,每 2 s 的误差如图 14 所示。

数据融合的 LSTM 变形重构方法最大误差小于 8%,堆叠 LSTM 网络在不同情况下均性能稳定。相比之下,基于应变和基于加速度的变形重构方法误差高于 LSTM 神经网络变形重构方法。




图 12 简支梁各测点变形重构误差

Fig. 12 The displacement reconstruction errors at different measurement points of the simply beam

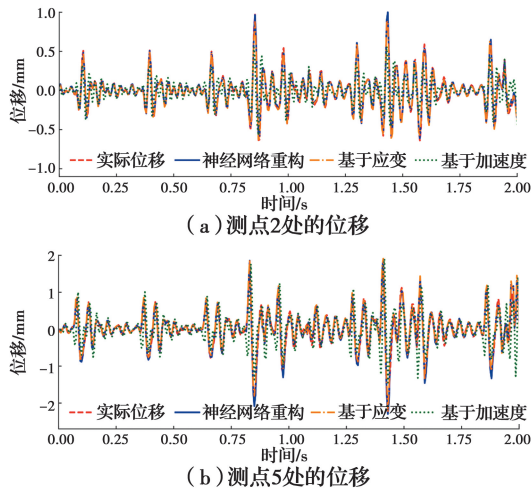


图 13 连续梁重构位移对比

Fig. 13 Reconstructed displacement comparisons of the continuous beam




图 14 连续梁各测点变形重构误差

Fig. 14 The displacement reconstruction errors at different measurement points of the continuous beam

4 结论

提出了一种基于 LSTM 神经网络的多源数据融合变形重构方法。该方法可以将实测加速度和应

变数据融合,实现高精度的位移重构。其主要优点包括:

1)提出的基于堆叠 LSTM 网络的位移重构方法,数据经过简单预处理后即可输入神经网络,数据融合过程由网络自动完成。

2)经过简单的训练后,LSTM 网络可以准确地重构不同工况下的位移。在位移重构过程中,不需要预先知道结构的中性轴和模态振型。

3)经过训练的堆叠 LSTM 神经网络可以自动融合不同类型的测量数据,位移重构精度比基于单一源的方法更准确。

参考文献:

- [1] 余加勇, 邵旭东, 晏班夫, 等. 基于全球导航卫星系统的桥梁健康监测方法研究进展[J]. 中国公路学报, 2016, 29(4): 30-41.
YU J Y, SHAO X D, YAN B F, et al. Research and development on global navigation satellite system technology for bridge health monitoring [J]. China Journal of Highway and Transport, 2016, 29(4): 30-41. (in Chinese)
- [2] GARG P, NASIMI R, OZDAGLI A, et al. Measuring transverse displacements using Unmanned Aerial Systems Laser Doppler Vibrometer (UAS-LDV): Development and field validation [J]. Sensors, 2020, 20(21): 6051.
- [3] HUANG Q H, WANG Y A, LUZI G, et al. Ground-based radar interferometry for monitoring the dynamic performance of a multitrack steel truss high-speed railway bridge [J]. Remote Sensing, 2020, 12(16): 2594.
- [4] LEE J, LEE K C, LEE S, et al. Long-term displacement measurement of bridges using a LiDAR system [J]. Structural Control and Health Monitoring, 2019, 26(10): e2428.

- [5] YE X W, YI T H, DONG C Z, et al. Multi-point displacement monitoring of bridges using a vision-based approach [J]. *Wind and Structures*, 2015, 20(2): 315-326.
- [6] VURPILOT S, KRUEGER G, BENOUAICH D, et al. Vertical deflection of a pre-stressed concrete bridge obtained using deformation sensors and inclinometer measurements [J]. *ACI Structural Journal*, 1998, 95(5): 518-526.
- [7] ZHANG Q Q, SUN T F, WANG J, et al. Deflection distribution estimation of the main arch of arch bridges based on long-gauge fiber optic sensing technology [J]. *Advances in Structural Engineering*, 2019, 22(15): 3341-3351.
- [8] XU H, REN W X, WANG Z C. Deflection estimation of bending beam structures using fiber Bragg grating strain sensors [J]. *Advances in Structural Engineering*, 2015, 18(3): 395-403.
- [9] 沈圣, 吴智深, 杨才千, 等. 基于分布式光纤应变传感技术的改进共轭梁法监测结构变形分布研究[J]. *土木工程学报*, 2010, 43(7): 63-70.
- SHEN S, WU Z S, YANG C Q, et al. An improved conjugated beam method for structural deformation monitoring based on distributed optical fiber strain sensing technique [J]. *China Civil Engineering Journal*, 2010, 43(7): 63-70. (in Chinese)
- [10] 汪莲, 王佐才, 耿栋, 等. 基于应变模态的连续梁动挠度识别[J]. *工程力学*, 2017, 34(1): 130-138.
- WANG L, WANG Z C, GENG D, et al. Strain modes based dynamic deflection estimation of continuous beam structures [J]. *Engineering Mechanics*, 2017, 34(1): 130-138. (in Chinese)
- [11] WANG Z C, GENG D, REN W X, et al. Strain modes based dynamic displacement estimation of beam structures with strain sensors [J]. *Smart Materials and Structures*, 2014, 23(12): 125045.
- [12] 李苗, 任伟新, 胡异丁, 等. 基于解析模态分解法的桥梁动态应变监测数据温度影响的分离[J]. *振动与冲击*, 2012, 31(21): 6-10, 29.
- LI M, REN W X, HU Y D, et al. Separating temperature effect from dynamic strain measurements of a bridge based on analytical mode decomposition method [J]. *Journal of Vibration and Shock*, 2012, 31(21): 6-10, 29. (in Chinese)
- [13] DING H P, SHEN Q H, DU S D. Structural condition assessment of the herringbone middle pylon of the Taizhou bridge using SHM strain data [J]. *Journal of Sensors*, 2017, 2017: 1-10.
- [14] SARWAR M Z, PARK J W. Bridge displacement estimation using a co-located acceleration and strain [J]. *Sensors (Basel, Switzerland)*, 2020, 20(4): 1109.
- [15] MOON H S, OK S, CHUN P J, et al. Artificial neural network for vertical displacement prediction of a bridge from strains (part 1): Girder bridge under moving vehicles [J]. *Applied Sciences*, 2019, 9(14): 2881.
- [16] TIAN Y D, XU Y, ZHANG D Y, et al. Relationship modeling between vehicle-induced girder vertical deflection and cable tension by BiLSTM using field monitoring data of a cable-stayed bridge [J]. *Structural Control and Health Monitoring*, 2021, 28(2): e2667.
- [17] LI S C, LU J Y, CHENG L, et al. A high precision in-bore velocity measurement system of railgun based on improved Bi-LSTM network [J]. *Measurement*, 2021, 169: 108501.
- [18] BENGIO Y. Practical recommendations for gradient-based training of deep architectures [M]//Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012: 437-478.
- [19] 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.

(编辑 黄廷)