2024年10月
第43卷 第10期

DOI:10.19652/j.cnki.femt.2406240

基于车桥耦合振动和深度学习的悬索桥损伤识别分析*

李 整[1] 李奥利[1] 陈代海[1] 许世展[1] 张 宇[2]
(1.郑州大学土木工程学院 郑州 450001;2.河南交通投资集团有限公司 郑州 450016)

摘 要:针对现有通过车辆响应识别桥梁损伤方法的不足,提出结合车桥耦合振动和深度学习理论的桥梁结构损伤识别方法。以郑州桃花峪自锚式悬索桥为例,建立桥梁和车辆的有限元分析模型,开展大跨度自锚式悬索桥的车桥耦合振动分析,获取车辆的加速度响应。以车辆加速度响应作为网络输入参数,分别构建一维卷积神经网络(one dimensional convolutional neural network,1D-CNN)和二维卷积神经网络(two dimensional convolutional neural network,2D-CNN)两种深度学习模型,对二者的识别效果进行对比分析。探讨信号噪音、低损工况等因素对桥梁结构损伤识别效果的影响规律。结果表明,2D-CNN对桥梁结构的损伤识别准确率和训练效率要优于1D-CNN;1D-CNN实现了端对端智能损伤识别,2D-CNN在识别准确率和对外界干扰因素的鲁棒性上表现更好。研究结果为进一步优化桥梁结构损伤识别方法提供参考。

关键词:公路桥梁;车桥耦合振动;损伤识别;深度学习;卷积神经网络
中图分类号:U441+.4;TN911.71 **文献标识码**:A **国家标准学科分类代码**:580.1020

Damage identification analysis of suspension bridge based on vehicle-bridge coupled vibration and deep learning

Li Zheng[1] Li Aoli[1] Chen Daihai[1] Xu Shizhan[1] Zhang Yu[2]
(1. School of Civil Engineering, Zhengzhou University, Zhengzhou 450001, China;
2. Henan Transportation Investment Group Co., Ltd., Zhengzhou 450016, China)

Abstract: To address the deficiencies in existing methods for bridge damage identification using vehicle response, a new approach integrating vehicle-bridge coupled vibration and deep learning theory is proposed. Taking the self-anchored suspension bridge of Zhengzhou Taohuayu as an example, finite element analysis models of the bridge and vehicles are established. A vehicle-bridge coupled vibration analysis is conducted on the large-span self-anchored suspension bridge to obtain vehicle acceleration responses. Using these acceleration responses as input parameters, two deep learning models—one-dimensional convolutional neural network (1D-CNN) and two-dimensional convolutional neural network (2D-CNN)—are constructed and their identification effectiveness is compared. The influence of factors such as signal noise and low damage conditions on the bridge structure damage identification effectiveness is explored. Results indicate that the 2D-CNN surpasses the 1D-CNN in terms of accuracy and training efficiency for bridge damage identification; the 1D-CNN achieves end-to-end intelligent damage identification, while the 2D-CNN demonstrates superior performance in accuracy and robustness against external interference. The research results provide a reference for further optimization of bridge structure damage identification methods.

Keywords: highway bridges; vehicle-bridge coupling vibration; damage identification; deep learning; convolutional neural network

0 引 言

土木工程结构在施工和运营阶段会出现不同程度的损伤,导致其服役寿命缩短,结构损伤识别[1]已然成为其生命周期内保障其健康运营的重要因素,桥梁结构作为土木工程结构不可或缺的一部分,其安全性是重中之重,对现有桥梁进行健康监测迫在眉睫[2]。

周宇等[3]通过模拟准静态加载提取并分析结构的位

收稿日期:2024-08-02
* **基金项目**:国家自然科学基金(51408557)、中国博士后科学基金(2013M541995)、河南省交通运输厅计划项目(2020J-2-6)资助

移、应力影响线，构造柔度曲率差变化率指标，用于悬索桥结构构件损伤识别。研究表明，柔度曲率差变化率损伤识别指标比影响线损伤识别指标对悬索桥构件损伤更为敏感，且具有较好的噪声鲁棒性。郭旭等[4]建立基于卷积神经网络(convolutional neural network，CNN)的传感器故障诊断模型，判断传感器故障类型和故障位置，并探讨不同噪声水平对信号恢复结果的影响。研究结果表明，基于CNN传感器故障诊断模型具有较好的抗噪性能，传感器的故障诊断准确率在90%以上。翁顺等[5]基于有限元模型修正的损伤识别方法基本原理与过程，详细介绍了子结构有限元模型修正的土木工程损伤识别方法在提高计算效率方面的优势。为大型结构基于有限元模型修正的损伤识别开辟高精度和高效率的途径。阳洋等[6]提出一种融合位移四阶矩和加速度八阶矩的特征指标，并结合L1正则化优化准则进行模型修正的框架结构损伤识别新方法。结果表明，结合L1正则化优化准则的模型修正方法较常规残差优化准则的传统模型修正方法具有更高的稳定性及有效性。传统的结构损伤识别方法存在着需要耗费大量的人力物力、识别精度较低、检测周期长、适用范围较小等局限性，而基于深度学习的结构损伤识别方法能够弥补传统方法的不足。近年来，关于基于深度学习的桥梁结构损伤识别方法研究成果也较多。李子奇等[7]针对结构振动损伤识别技术展开研究，探讨不同深度学习方法发展情况及其利弊，研究结果表明，应用深度学习开发新的结构损伤识别技术，无需冗余的数据预处理以及手工提取损伤特征，实现以较高精度实现损伤识别任务。李雪松等[8]在分析CNN自动提取特征的鲁棒性时，发现单一噪声数据训练的特征抗噪能力有一定局限性，为获得更好的特征抗噪能力，提出混合噪声训练模式，验证了含噪声0%～50%的样本数据，均取得良好识别结果。Bilotta等[9]采用卷积神经网络的方法对钢－混凝土组合梁连接中的损伤进行识别。通过评估损伤的位置和强度，展示了如何训练简单的卷积神经网络来识别损伤。He等[10]根据原始结构响应信号涉及车桥耦合振动，建立了一种基于卷积神经网络和递归图的损伤识别方法。通过数值仿真和模型实验验证，卷积神经网络可以实现更精确的损伤位置和损伤程度识别。Resende等[11]研究了使用CNN和瞬时位移测量进行梁损伤识别的有效性。结果表明，在对所有损伤场景的数据进行训练时，CNN模型能够正确地定位和量化损伤等级。Zhang等[12]通过一种简单的一维卷积神经网络(one dimensional convolutional neural network，1D-CNN)来检测结构局部微小的刚度和质量变化，并在实际结构上验证了所提出的CNN，经过训练的CNN几乎完美地识别到了结构局部发生微小质量和刚度变化的位置。韩宇等[13]提出一种基于联合CNN和长短期记忆神经网络(long short-term memory neural network，LSTM)模型的桥梁结构损伤诊断方法。实验结果表明，该方法对桥梁结构损伤的诊断准确率高达87.6%，具有实际工程价值。

已有研究均只考虑了单一的CNN模型或CNN与其他模型的结合，并未考虑基于不同CNN模型的特征提取；另外，在实际的工程应用中，车辆的振动信号较易受到路面粗糙度等因素的干扰，以往的研究中往往采取简化的方法，将空间车辆模型简化，不考虑或者只考虑单一的路面粗糙度；同时，信号噪音、低损工况等因素对识别效果的影响也值得进一步研究。针对上述问题，本文提出一种基于车桥耦合振动和深度学习的桥梁结构损伤识别方法，采用Fortran计算机语言编制了车桥耦合振动分析程序[14]，通过程序计算获取车体的加速度响应信号，并将其用于桥梁损伤识别分析模型中。建立1D-CNN和二维卷积神经网络(two dimensional convolutional neural network，2D-CNN)两种神经网络模型，对采集到的数据进行特征提取和损伤预测。以郑州桃花峪黄河大桥主桥－大跨度自锚式悬索桥为例，完成了对桥梁损伤位置的分类和损伤程度的回归预测，并对两种神经网络模型的优劣性进行对比，所得结论可为桥梁结构损伤识别提供参考。

1 基于车桥耦合振动与深度学习的桥梁损伤间接识别方法

1.1 公路桥梁车桥耦合振动分析理论

将汽车和桥梁分为两个子系统，通过分离迭代法求解车桥耦合运动方程。考虑耦合节点处的作用力平衡关系与变形协调条件，车桥系统动力平衡方程为：

$$[\boldsymbol{M}_v]\{\ddot{\boldsymbol{u}}_v\}+[\boldsymbol{C}_v]\{\dot{\boldsymbol{u}}_v\}+[\boldsymbol{K}_v]\{\boldsymbol{u}_v\}=\{\boldsymbol{F}_v\} \quad (1)$$

$$[\boldsymbol{M}_b]\{\ddot{\boldsymbol{u}}_b\}+[\boldsymbol{C}_b]\{\dot{\boldsymbol{u}}_b\}+[\boldsymbol{K}_b]\{\boldsymbol{u}_b\}=\{\boldsymbol{F}_b\} \quad (2)$$

式中：下角标v和b分别代表车辆和桥梁；$[\boldsymbol{M}]$、$[\boldsymbol{C}]$和$[\boldsymbol{K}]$分别为质量矩阵、阻尼矩阵和刚度矩阵；$\{\boldsymbol{u}\}$为位移向量；$\{\boldsymbol{F}\}$为荷载向量。$\{\boldsymbol{F}_v\}$与桥梁振动和路面粗糙度有关，$\{\boldsymbol{F}_b\}$来自于车辆和桥梁振动，因此可等价替换为：

$$\{\boldsymbol{F}_v\}=\{\boldsymbol{F}_v\}(\{\ddot{\boldsymbol{u}}_b\},\{\dot{\boldsymbol{u}}_b\},\{\boldsymbol{u}_b\},\{\boldsymbol{r}_x\}) \quad (3)$$

$$\{\boldsymbol{F}_b\}=\{\boldsymbol{F}_b\}(\{\ddot{\boldsymbol{u}}_v\},\{\dot{\boldsymbol{u}}_v\},\{\boldsymbol{u}_v\},\{\ddot{\boldsymbol{u}}_b\},\{\dot{\boldsymbol{u}}_b\},\{\boldsymbol{u}_b\}) \quad (4)$$

式中：$r^i(x)$是路面粗糙度；e^i是轴到质心的距离；θ_b^i是相对于平衡位置的转动位移。根据耦合节点处的变形协调条件，包含路面粗糙度的位移表达式为：

$$\{u_v^i\}=\{u_b^i\}+\{e^i\theta_b^i\}+\{r^i(x)\} \quad (5)$$

1.2 深度学习理论

1)CNN

CNN具有较高的模型复杂度，对数据尤其是图像等二维数据特征具有更高的敏感性。CNN基本结构如图1所示。

CNN对图像的识别和分类更为敏感，因此可考虑将一维信号和二维信号变换为图像，再输入到CNN网络中进行损伤识别，构成1D-CNN和2D-CNN。这些网络仅需

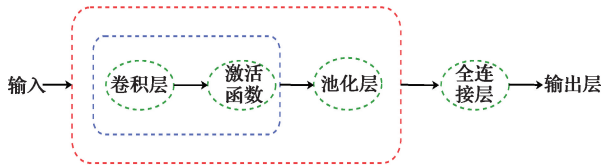

图 1　CNN 基本结构

Fig. 1　Basic structure diagram of CNN

要较少的数据进行训练，用迁移学习来处理数据不足的问题，可利用数值模型、试验结构等来验证所提方法的有效性。

2）1D-CNN

1D-CNN 的工作原理和传统的卷积神经网络类似，通过卷积、下采样、非线性激活等操作提取特征，然后再通过全连接层等操作实现分类、回归等任务。一维卷积核可以沿着输入序列的单个维度一次处理一个滑动窗口，从而获取序列的局部结构特征。在 1D-CNN 中，卷积核的深度等于输入序列的通道数，卷积核的宽度决定了“局部感受野”的大小，可以设置不同的卷积核宽度、通道数、步幅等超参数，从而有效提取不同尺度的特征。

1D-CNN 可以通过堆叠多个卷积层和池化层来构建深层网络，还可以使用批量正则化、残差连接等技术来优化网络结构。在深度学习领域，1D-CNN 在处理文本、时间序列分析等任务中表现出很好的性能。

3）2D-CNN

2D-CNN 是一种深度学习模型，能够有效地处理图像和视频等二维数据。它通过卷积操作从输入图像中提取特征，然后通过使用池化层减小特征图的大小，最后通过全连接层和 Softmax 分类器进行分类或回归等任务。在二维卷积神经网络中，卷积核从图像的高和宽的两个维度滑动，提取图像的局部特征。通过改变卷积核的大小、深度、步幅和填充等超参数，可以调整网络的感受野大小和输出大小，以及提高特征提取的效果。二维卷积神经网络是计算机视觉领域中常用的模型之一，其主要应用于图像分类、目标识别、语义分割、物体检测等任务。

利用 2D-CNN 的桥梁损伤识别方法总体框架如图 2 所示。

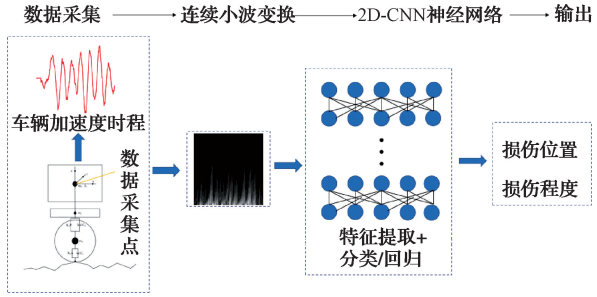

图 2　2D-CNN 总体框架

Fig. 2　Overall framework of 2D-CNN

1.3　基于车桥耦合振动与深度学习的桥梁损伤识别方法

近些年来，针对利用车辆响应来识别桥梁损伤位置和损伤程度的方法，相关领域专家学者做了大量研究[15-17]。但仍有车桥耦合数值模型不够精细、未考虑粗糙度随机性等不足之处，面向工程应用方面还需对该方法进行进一步研究。

对桥梁的损伤识别实质上是对桥梁的损伤位置进行分类和损伤程度进行回归预测，以往在对桥梁进行损伤识别时，需要专业人员依据经验进行人工特征设计，再对提取到的特征进行分析判断，从而实现对桥梁损伤状态的预测。本文提出的基于深度学习的桥梁损伤间接识别则可直接对采集到的数据进行特征提取和损伤预测，实现端对端的桥梁损伤智能识别。

2　大跨度自锚式悬索桥损伤识别分析

2.1　车桥耦合振动分析模型

1）工程概况

郑州桃花峪黄河大桥是郑州市区第 4 座跨黄河公路大桥，采用双向 6 车道高速公路标准设计，大桥于 2013 年 4 月完工。该桥主桥为双塔三跨自锚式悬索桥，跨径布置为 160 m＋406 m＋160 m，是当时世界上跨度最大的三跨双塔全钢梁自锚式悬索桥。桥梁主梁采用标准截面高度为 3.5 m 的钢箱梁，桥面总宽 39 m。主缆采用空间平面线形体系，由 127d5.3 m 高强度镀锌钢丝编织，共计 37 股；吊索采用 109Φ5.0 编束，布置基本间距为 13.5 m，桥塔两侧吊索对称布置纵向相距 28 m。其中，边跨 10 对吊索，中跨 29 对吊索。桥塔塔柱顶高 219.647 m，上塔柱高 71 m，北塔和南塔柱底部高程分别为 94.5 和 92 m，桥面上部塔柱高 78.913 m。主塔和支座均采用 C50 混凝土，辅助墩及共用墩采用 C40 混凝土。其立面布置和钢箱梁标准断面如图 3 和 4 所示。

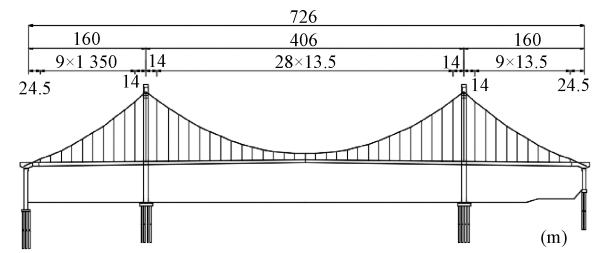

图 3　桃花峪黄河大桥主桥立面布置

Fig. 3　Main bridge elevation layout of Taohuayu yellow river bridge

2）桥梁分析模型的建立

采用通用有限元软件 ANSYS 建立桥梁三维有限元模型，主缆和吊杆采用 link10 单元离散，主梁、主塔和横梁采用 beam44 单元模拟，二期恒载和压重以等效添加至主

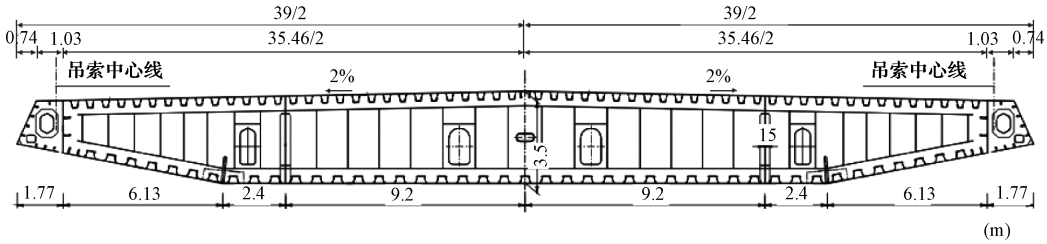

图 4　钢箱梁标准断面图

Fig. 4　Standard cross-sectional diagram of steel box beam

梁单元对应位置材料密度的形式加以考虑。成桥状态的初始应变施加于主梁、主缆、主塔和吊杆各单元中。边界条件设置为主缆与主塔顶部固结，主缆锚固端与主梁固结，主梁与主塔的横竖向自由度耦合，桥塔底部固结。全桥三维有限元模型共划分 2 123 个单元，1 737 个节点，如图 5 所示。

图 5　全桥三维有限元模型

Fig. 5　3D finite element model of the whole bridge

根据桥梁的 ANSYS 有限元模型，采用子空间迭代法分析桥梁的自振特性，并将 ANSYS 软件和参考文献[18]的计算结果进行对比，桥梁的前 5 阶自振频率及振型特征如表 1 所示。

表 1　桥梁的前五阶自振频率及振型特征

Table 1　The first five natural frequencies and mode shapes of the bridge

阶数	ANSYS /Hz	文献[18] /Hz	偏差 /%	振型特征
1	0.117 5	0.115 5	1.70	纵飘
2	0.246 4	0.244 1	0.93	加劲梁一阶对称竖弯
3	0.264 5	0.278 1	5.14	加劲梁一阶反对称竖弯
4	0.468 6	0.453 4	3.24	加劲梁二阶反对称竖弯
5	0.491 9	0.496 8	1.00	加劲梁一阶对称横弯

由表 1 可知，桥梁的基频为 0.12 Hz，第 1 阶振型为桥梁整体纵飘；在桥梁前 5 阶振型中，以加劲梁竖向振动为主，该桥的竖向刚度较小；另外，ANSYS 软件和参考文献[18]的计算结果偏差基本在 5%以内，验证了桥梁有限元模型的可靠性。

3)车辆分析模型的建立

采用国 AASHTO 规范中的三轴拖挂卡车进行车辆竖向加速度数据采集。该车辆模型的理想化简化模型仅考虑车体、悬挂装置以及车轴等组件，且只考虑车体的竖向、俯仰、侧滚以及车轮的竖向运动，以此获取该模型的 11 个独立自由度。该车辆模型如图 6 所示。

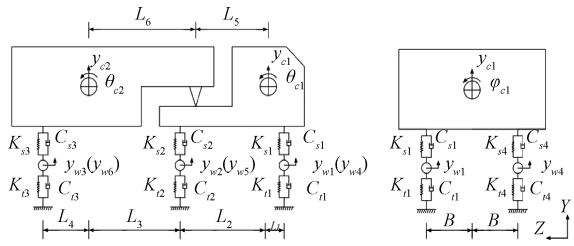

图 6　三轴拖挂卡车模型

Fig. 6　Model diagram of three-axle trailer truck

图 6 中 y_{w1}～y_{w6} 为 6 个车轮的竖向自由度，y_{c1}、y_{c2} 为车头与车厢的竖向自由度，θ_{c1} 为车头俯仰自由度，φ_{c2}、φ_{c2} 是车头与车厢的侧滚自由度。采用弹簧－阻尼系统模拟车辆的悬挂系统及路面与车轮的相互作用，其中 m_1、m_2 为车头和车厢的质量，m_{w1}～m_{w6} 为 6 个车轮的质量，k_{s1}～k_{s6}、c_{s1}～c_{s6} 为悬挂系统刚度与阻尼，k_{t1}～k_{t6}、c_{t1}～c_{t6} 为轮胎刚度与阻尼。车辆参数如表 2 所示。

表 2　车辆参数

Table 2　Vehicle parameters

参数	数值	参数	数值
m_1/kg	2.61×10^3	c_{t3}/c_{t6}/(N·s/m)	2.00×10^3
m_2/kg	2.61×10^4	k_{s1}/k_{s4}/(N/m)	2.42×10^5
m_{w1}/m_{w4}/kg	4.90×10^2	k_{s2}/k_{s5}/(N/m)	1.90×10^6
m_{w2}/m_{w5}/kg	8.08×10^2	k_{s3}/k_{s6}/(N/m)	1.97×10^6
m_{w3}/m_{w6}/kg	6.53×10^2	k_{t1}/k_{t4}/(N/m)	8.75×10^5
θ_{c1}/(kg·m^2)	2.02×10^3	k_{t2}/k_{t5}/(N/m)	3.50×10^6
φ_{c2}/(kg·m^2)	8.54×10^3	k_{t3}/k_{t6}/(N/m)	3.50×10^6
θ_{c1}/(kg·m^2)	3.31×10^4	L_1/m	1.70
φ_{c2}/(kg·m^2)	1.81×10^5	L_2/m	2.57
c_{s1}/c_{s4}/(N·s/m)	2.19×10^3	L_3/m	4.45
c_{s2}/c_{s5}/(N·s/m)	7.88×10^3	L_4/m	4.70
c_{s3}/c_{s6}/(N·s/m)	7.18×10^3	L_5/m	2.22
c_{t1}/c_{t4}/(N·s/m)	2.00×10^3	L_6/m	4.81
c_{t2}/c_{t5}/(N·s/m)	2.00×10^3	B/m	1.10

4)路面粗糙度的数值模拟

依据我国《机械振动道路路面谱测量数据报告》(GB/T 7031—2005)标准对路面粗糙度进行模拟。根据 GB/T 7031—2005,路面等级可分为 8 种,A 等最好,H 等最差。路面粗糙度一般可通过实验法和数值模拟法来获得,实验法应用范围有限,常用三角级数叠加法等方法对路面粗糙度进行数值模拟。三角级数法精度较高,计算简单快捷,且能满足数值方法中积分长度变化的要求。可通过式(6)生成路面粗糙度样本。

$$R(x)=\sum_i A_i\cos(n_{s,i}x+\theta_i) \tag{6}$$

式中:$n_{s,i}$ 为第 i 阶空间频率;A_i 为函数幅值;θ_i 为第 i 个余弦函数的随机相位信息;x 为桥梁路面粗糙度离散点距起始点的距离。

空间频率的采样间隔 $\Delta n=0.04$ cycle/m,考虑的空间频率 n_s 范围为 1～100 cycle/m。拟模拟的路面等级为 A,$G_d(n_0)$ 上限为 32×10^{-6} m^3。汽车频率的上下限为 0.5～50 Hz,数值模拟中汽车行驶速度范围为 10～50 m/s,可得空间频率 n 的范围为 0.01～5 m^{-1}。采样间距 Δl 设为 0.05 m,路面粗糙度样本长度 L 为 800 m。

根据以上参数和规范限值,$G_d(n_0)$ 在 A 级路面范围内取不同的值,采用三角级数法,在 MATLAB 软件中编制程序生成 50 条不同的粗糙度样本,样本长度为 800 m。

2.2 车辆响应数据集的构建

1)损伤工况的设定

基于上述桥梁有限元模型,假定主梁指定位置发生损伤,为了扩增数据集,增加识别可靠度,选取 20%、30%、40%和 50%的结构损伤程度,损伤程度通过调整损伤位置处的单元弹性模量来实现,同时考虑 7 种不同的损伤位置,单损工况和多损工况设定如表 3 所示。

表 3 桥梁预设的损伤工况

Table 3 Individual preset damage scenarios for the bridge

损伤工况	损伤位置	损伤程度/%
单个单元损伤	1/8 跨	20、30、40、50
	1/4 跨	20、30、40、50
	3/8 跨	20、30、40、50
	1/2 跨	20、30、40、50
	5/8 跨	20、30、40、50
	3/4 跨	20、30、40、50
	7/8 跨	20、30、40、50
两单元损伤	1/4 跨 &1/2 跨	20&50、30&40、40&30、50&20
	1/2 跨 &3/4 跨	20&50、30&40、40&30、50&20
	3/4 跨 &1/4 跨	20&50、30&40、40&30、50&20
三单元损伤	1/4 跨 &1/2 跨 &3/4 跨	20&30&40、30&20&50、40&50&20

2)车体竖向加速度的数据采集

假设车辆行驶速度为 72 km/h,针对每种工况选取 50 个长度为 800 m 的路面粗糙度样本,积分步长为 0.02 s,每 1 s 数据段包含 50 个数据点。在中跨损伤工况下,选取进入中跨后的 1 024 个车辆加速度响应数据点作为初始采集的数据样本。根据预选的单元损伤位置和程度,转换并修改桥梁的 ANSYS 有限元模型数据,得到车桥耦合程序中的桥梁数据卡,在车桥耦合程序中运行以分析不同工况下的车辆响应,从而生成所需的车辆响应结果文件,从而获得车体竖向加速度的初始数据。

3)神经网络的搭建

为了研究适用于桥梁结构损伤识别的网络模型,建立了一维深度卷积神经网络(模型 1)和二维深度卷积神经网络(模型 2)两种神经网络模型。1D-CNN 模型的结构如表 4 所示。首先将要训练的数据输入到网络中,经过 4 个卷积层和 4 个池化层进行特征提取,然后连接到两个全连接层和一个十分类的输出层,每个卷积层均采用 Same 方式进行特征提取,且卷积层后方均按照相同的顺序设置了最大池化层。池化层的感受野尺寸设置为 2,滑移步长设置为 2。

表 4 1D-CNN 网络结构

Table 4 1D-CNN network structure

名称	核尺寸	核数量	步长	输出尺寸
输入层	—	—	—	1 024×1
卷积层 1	1×32	16	1	1 024×16
池化层 1	1×2	16	2	512×16
卷积层 2	1×3	32	1	512×32
池化层 2	1×2	32	2	256×32
卷积层 3	1×3	64	1	256×64
池化层 3	1×2	64	2	128×64
卷积层 4	1×3	96	1	128×96
池化层 4	1×2	96	2	64×96
全连接层 1	—	—	—	256
全连接层 2	—	—	—	128
输出层	—	—	—	10

2D-CNN 模型的结构如表 5 所示。第 1 个卷积层对输入尺寸为 224×224×1 的图像进行特征提取,然后使用最大池化层对数据进行降维,并通过 3 层卷积层进行特征提取,最后将数据拉平连接到全连接层,得到网络输出。使用 Adam 优化器来优化训练过程,初始学习率为 0.000 1,卷积层之后进行正则化处理以提高训练效率。批量大小(batch)设置为 300,训练轮数(epochs)为 160。

2.3 损伤识别结果分析

1)单损工况的损伤位置识别

在进行单损工况损伤位置识别时,数据集划分的比例为 8∶1∶1,即共有 6 400 条数据,训练集共有 5 120 条数据,验证集和测试集各有 640 条数据。输出层为 8 个节点,采用 Softmax 激活函数,分别对应无损工况和其余

表 5　2D-CNN 网络结构

Table 5　2D-CNN network structure

名称	核尺寸	核数量	步长	输出尺寸
输入层	—	—	—	224×224×1
卷积层 1	3×3	8	1×1	222×222×8
池化层 1	2×2	8	2×2	111×111×8
卷积层 2	3×3	16	1×1	109×109×16
池化层 2	2×2	16	2×2	55×55×16
卷积层 3	3×3	32	1×1	53×53×32
池化层 3	2×2	32	2×2	27×27×32
全连接层 1	—	—	—	256
全连接层 2	—	—	—	64
输出层	—	—	—	10

7 个位置损伤工况。根据最终选定的网络结构参数进行损伤识别，训练过程准确率上升曲线如图 7 所示。

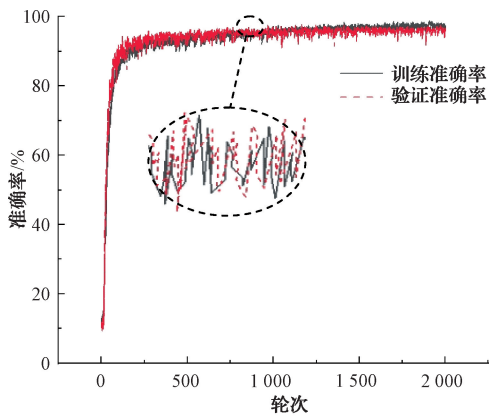

(a) 模型1准确率上升曲线
(a) Model 1 accuracy rising curve

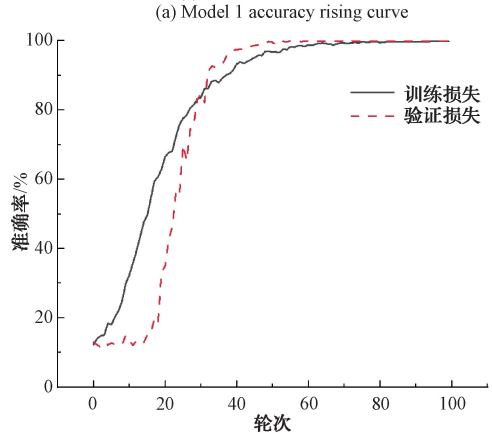

(b) 模型2准确率上升曲线
(b) Model 2 accuracy rising curve

图 7　网络训练过程

Fig. 7　Neural network training process

由图 7 可知，模型 1 迭代轮次为 2 000，验证集准确率为 96.08%，测试集准确率为 97.2%；模型 2 迭代轮次为 100，验证集和测试集准确率均为 100%。

2)单损工况的损伤程度识别

将损伤位置分类模型转化为损伤程度预测模型，按照 8∶1∶1 的比例划分出训练集、验证集和测试集。表 6 为损伤程度预测模型的最终识别结果。其中，MSE 代表均方误差，R^2 代表度量函数。其中，度量函数 R^2 一般为 0～1 的值，越靠近 1 说明拟合效果越佳。计算 R^2 的公式为：

$$R^2 = SSR/SST = \frac{\sum(pre_y - mean_y)^2}{\sum(y - mean_y)^2} = 1 - \frac{SSE}{SST} \tag{7}$$

式中：$SST = SSR + SSE$，SSR 为回归平方和，SST 为总平方和，SSE 为残差平方和(残差为预测数据与实际数据之间的差值)。

表 6　损伤程度预测结果

Table 6　Prediction results of damage degree

损伤位置	模型 1		模型 2	
	MSE /($\times10^{-4}$)	R^2	MSE /($\times10^{-4}$)	R^2
1/8	7.25	0.961 7	2.23	0.996 2
1/4	6.57	0.957 3	4.16	0.980 9
3/8	6.37	0.958 3	3.08	0.987 8
1/2	6.04	0.965 9	2.62	0.993 2
5/8	11.03	0.929 6	4.27	0.980 7
3/4	7.55	0.953 9	2.76	0.991 2
7/8	11.38	0.929 2	3.30	0.987 4

由表 6 可知，模型 1 迭代 2 000 轮次后，测试集的损伤程度预测准确度为 95.13%。而模型 2 经过 500 轮次迭代后，测试集的预测准确度为 98.82%。两种模型均能对桥梁损伤程度进行准确预测，但模型 2 的识别准确率更高。

3)多损工况的损伤位置识别

多损工况包括两单元损伤工况和三单元损伤工况，原始加速度响应数据共计 150 条。在添加 20 组 3%水平的噪声后，多损工况数据集共计 3 000 条数据，按照 8∶1∶1 的比例来划分训练集、验证集和测试集。模型 1 经过训练 1 000 轮次后，损失函数达到了收敛状态。而模型 2 仅需迭代 50 轮次便达到了收敛状态。图 8(a)和(b)所示分别为模型 1 和模型 2 在训练过程中损失函数下降曲线。两种模型在多损工况损伤位置预测方面均取得了非常好的效果，识别成功率均达到了 100%。

4)多损工况的损伤程度识别

按照 8∶1∶1 的比例划分训练集、验证集和测试集，在训练集上完成模型训练，使用测试集评估模型的准确度。表 7 为最终模型的预测结果。

模型 1 经过 2 000 轮次迭代后，损伤程度预测准确度为 99.26%；而模型 2 经过 500 轮次迭代后的拟合准确度为 99.24%。两种模型在多损工况损伤程度预测方面都表现出较高的精确度。

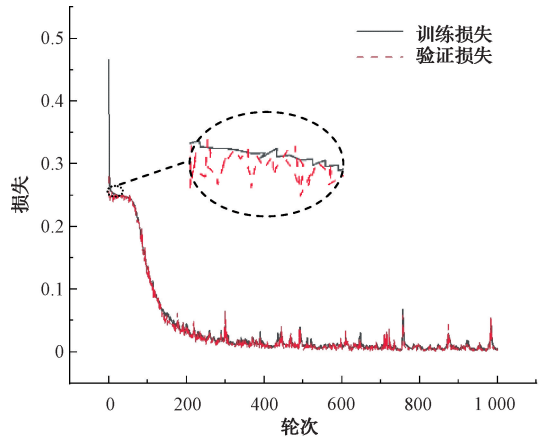

(a) 模型1损失函数下降曲线
(a) Model 1 loss function decline curve

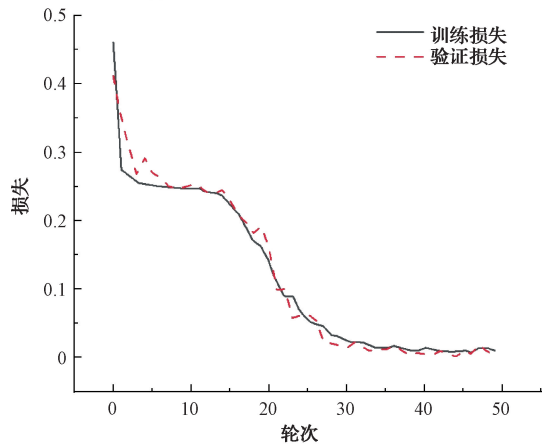

(b) 模型2损失函数下降曲线
(b) Model 2 loss function decline curve

图 8　多损工况损伤位置训练过程

Fig. 8　Training process of multi-load condition damage localization

表 7　多损工况不同单元损伤程度预测结果

Table 7　Prediction results of damage severity for different units under multi-load conditions

损伤位置	模型 1		模型 2	
	MSE /($\times10^{-4}$)	R^2	MSE /($\times10^{-4}$)	R^2
1/4	2.61	0.991 2	2.49	0.991 9
1/2	2.52	0.992 5	2.58	0.992 3
3/4	2.03	0.994 2	2.45	0.992 9

从以上损伤识别结果可以看出，模型 2 在单损工况识别效果上更具有优势；多损工况下两种模型也有较高的识别准确度。说明本文所提桥梁结构损伤识别方法具有可行性。

3　桥梁损伤识别的影响因素分析

在实际的工程应用中，除了路面粗糙度和噪声之外还会有其他因素对损伤识别结果造成一定程度的干扰。在考虑路面粗糙度和较低水平噪声的基础上，对其他可能出现的不确定性因素进行分析。

3.1　噪声比例的影响

本文已构造的数据集拟定噪声水平为 3%，然而，在实际工程中，噪声水平可能会更高。传统信号分析方法通常会对采集到的数据进行人工降噪处理，然后再进行特征提取。相比之下，深度学习网络自身具有一定的抗噪能力。为研究所提出的损伤识别方法的抗噪能力，构建了 5%、10%和 30% 3 组不同噪声水平的单损工况数据集，并使用这些数据集对模型的识别效果进行分析。本文模拟的不同噪声水平的示例图像如图 9 所示。

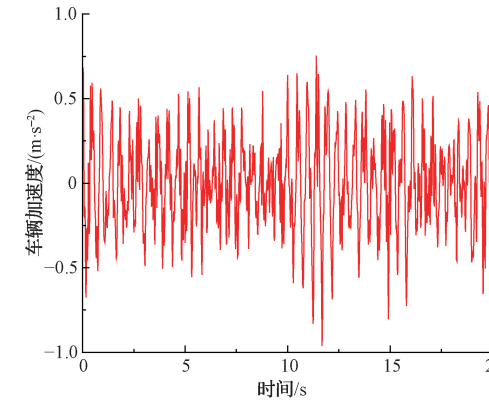

(a) 车辆原始加速度响应
(a) Vehicle original acceleration response

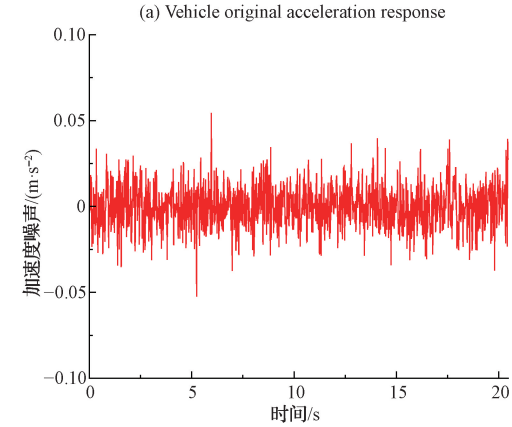

(b) 噪声水平5%
(b) Noise level 5 %

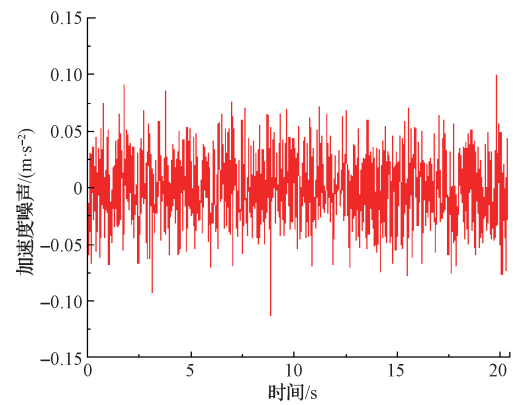

(c) 噪声水平10%
(c) Noise level 10 %

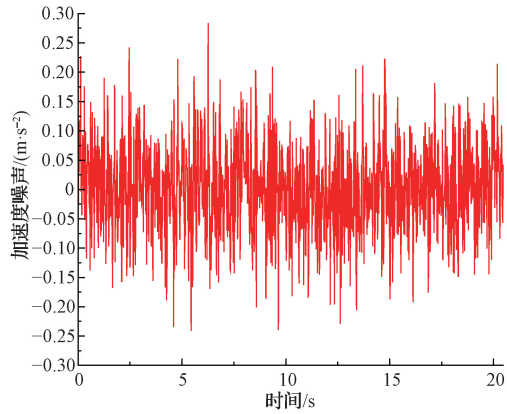

(d) 噪声水平30%
(d) Noise level 30 %

图 9　原始加速度响应与噪声模拟

Fig. 9　Original acceleration response and noise simulation

不同水平噪声下的损伤识别结果如图 10 所示。从图 10 可以看出，当噪声水平较低时，模型 1 和模型 2 均能取得较好的识别效果。然而，随着噪声水平的增加，直接处理加速度响应数据的模型 1 受到的噪声影响较大，其准确度下降明显。相比之下，以时频图为输入数据的模型 2 受到的噪声影响较小，即使在较高的噪声水平下，也能对损伤位置进行精确识别。但当噪声水平达到 30%时，模型 2 的损伤程度预测准确度下降到了 90%。

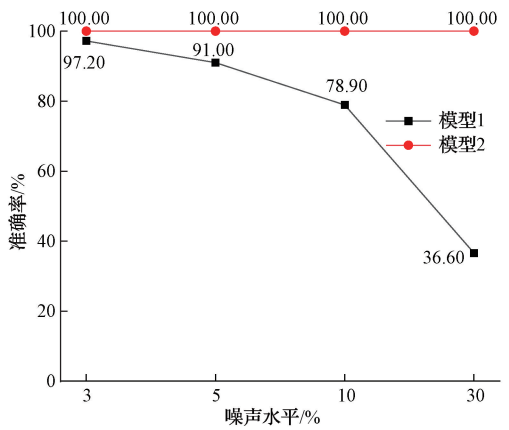

(a) 损伤位置识别结果
(a) Damage location identification results

(b) 损伤程度识别结果
(b) Damage degree identification results

图 10　不同水平噪声下损伤识别结果

Fig. 10　Damage identification results under different levels of noise

在实际应用中，模型 1 的方法更为直接，但受噪声影响较大，需要人工将噪声降到一个较低水平才能进行准确的识别；模型 2 受噪声影响较小，但需要对原始数据进行时频变换，并且处理大量数据时需要较高的算力作为支撑。

3.2　低损工况的影响

以往的研究表明，当单元的损伤程度较低时，损伤识别准确率往往会有所下降。然而，对于实际工程应用来说，如果能够在早期检测出较低程度的损伤，将会对桥梁的养护产生重要意义。本文通过设置较低程度的损伤工况来研究所提出的损伤识别方法的效果。在单个位置损伤工况下，加入了损伤程度为 0.1 的加速度响应数据，并将原数据集的规模从 6 400 条增加到了 8 000 条。

加入损伤程度为 10%的低损工况前后的损伤识别结果对比如图 11 所示。从图 11 可以看出，与模型 1 相比，

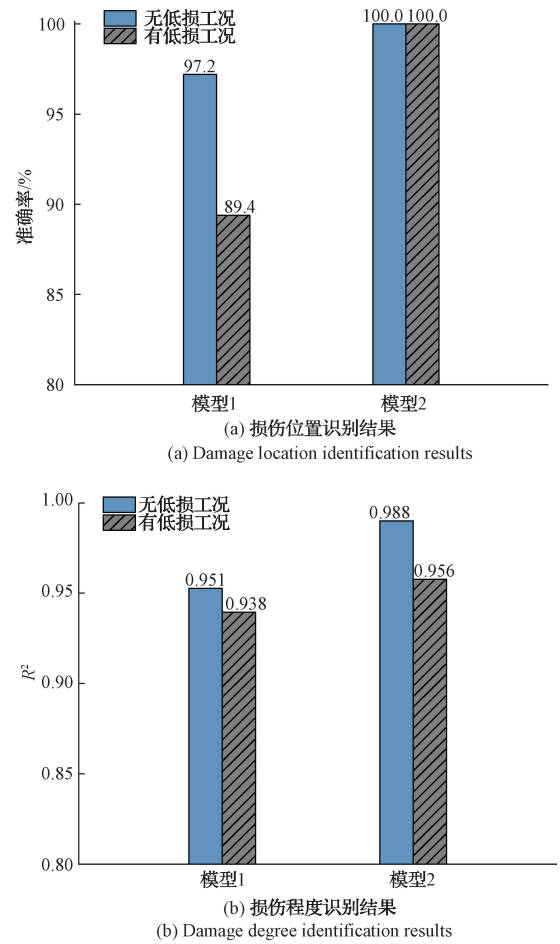

(a) 损伤位置识别结果
(a) Damage location identification results

(b) 损伤程度识别结果
(b) Damage degree identification results

图 11　有无低损工况损伤识别结果

Fig. 11　Identification results of the presence or absence of low-damage operating conditions

模型2在损伤位置和损伤程度的识别准确率以及相关系数R^2均更高。在加入低损工况前，模型1能够对损伤位置进行97.2%的准确预测，损伤程度的预测相关系数R^2为0.951。然而，加入低损工况后，模型1的损伤位置预测准确率下降到了89.4%，损伤程度预测相关系数R^2也下降到了0.938。相比之下，无论有无低损工况的影响，模型2均能对损伤位置进行准确预测；加入低损工况后，模型2的损伤程度预测相关系数R^2下降到了0.956，但仍然保持较高的识别准确率。

4 结 论

本文基于深度学习的架构，搭建用于桥梁损伤识别的1D-CNN和2D-CNN，分析不同网络参数对单损工况识别效果的影响，并完成网络结构的优化，研究结果表明2D-CNN对桥梁结构的损伤识别准确率和训练效率要优于1D-CNN。当噪声水平提高时，1D-CNN的识别准确率下降幅度较大，2D-CNN的损伤位置识别准确率受噪声影响较小。低损工况加入后两种模型识别效果均有不同程度的小幅下降，2D-CNN的识别精度比1D-CNN的下降幅度小。

综上所述，1D-CNN实现了端对端智能损伤识别，2D-CNN在识别准确率和对外界因素的鲁棒性上表现更好，但其需要经过时频变换，且训练时间较长。

参 考 文 献

[1] 赵一男，公茂盛，杨游. 结构损伤识别方法研究综述[J]. 世界地震工程，2020，36(2)：73-84.
ZHAO Y N，GONG M SH，YANG Y. A review of structural damage identification methods [J]. World Earthquake Engineering，2020，36(2)：73-84.

[2] 邓吉禄，罗德康，汤凯菱，等. 桥梁健康监测系统综述[J]. 土木工程学报，2022，11(12)：1289-1296.
DENG J L，LUO D K，TANG K L，et al. Review of bridge health monitoring system [J]. Journal of Civil Engineering，2022，11(12)：1289-1296.

[3] 周宇，王雪忠，赵青，等. 基于影响线多源信息融合的悬索桥损伤识别[J]. 科学技术与工程，2022，22(1)：313-323.
ZHOU Y，WANG X ZH，ZHAO Q，et al. Damage identification of suspension bridges based on multi-source information fusion of influence lines [J]. Science，Technology and Engineering，2022，22(1)：313-323.

[4] 郭旭，骆勇鹏，王林堃，等. 基于CNN与DCGAN的结构振动监测 传感器故障诊断及监测数据恢复[J]. 铁道科学与工程学报，2022，19(11)：3383-3395.
GUO X，LUO Y P，WANG L K，et al. Structural vibration monitoring sensor fault diagnosis and monitoring data recovery based on CNN and DCGAN [J]. Journal of Railway Science and Engineering，2022，19(11)：3383-3395.

[5] 翁顺，朱宏平. 基于有限元模型修正的土木结构损伤识别方法[J]. 工程力学，2021，38(3)：1-16.
WENG SH，ZHU H P. Damage identification method of civil structures based on finite element model updating [J]. Engineering Mechanics，2021，38(3)：1-16.

[6] 阳洋，陈熠昕，凌园，等. 基于统计矩理论的模型修正损伤识别方法研究[J]. 仪器仪表学报，2020，41(12)：217-226.
YANG Y，CHEN Y X，LING Y，et al. Research on model updating damage identification method based on statistical moment theory [J]. Chinese Journal of Scientific Instrument，2020，41(12)：217-226.

[7] 李子奇，蒋柱虎，王力，等. 基于深度学习的工程结构损伤识别研究进展[J]. 中国安全生产科学技术，2022，18(12)：43-48.
LI Z Q，JIANG ZH H，WANG L，et al. Research progress of engineering structure damage identification based on deep learning [J]. China Safety Production Science and Technology，2022，18(12)：43-48.

[8] 李雪松，马宏伟，林逸洲. 基于卷积神经网络的结构损伤识别[J]. 振动与冲击，2019，38(1)：159-167.
LI X S，MA H W，LIN Y ZH. Structural damage identification based on convolutional neural network [J]. Vibration and Impact，2019，38(1)：159-167.

[9] BILOTTA A，MORASSI A，TURCO E. Damage identification for steel-concrete composite beams through convolutional neural networks[J]. Journal of Vibration and Control，2024，30(3-4)：876-889.

[10] HE X H，ZHENG C J，LIAO C L，et al. Damage identification based on convolutional neural network and recurrence graph for beam bridge[J]. Structural Health Monitoring，2020，20(4)：1392-1408.

[11] RESENDE L，FINOTTI R，BARBOSA F，et al. Damage identification using convolutional neural networks from instantaneous displacement measurements via image processing [J]. Structural Health Monitoring，2024，23(3)：1627-1640.

[12] ZHANG Y，MIYAMORI Y，MIKAMI S，et al. Vibration-based structural state identification by a 1-dimensional convolutional neural network [J]. Computer-Aided Civil and Infrastructure Engineering，2019，34(9)：822-839.

[13] 韩宇,李剑,马慧宇,等.基于CNN-LSTM的桥梁结构损伤诊断方法[J].国外电子测量技术,2021,40(7):1-6.
HAN Y, LI J, MA H Y, et al. The damage diagnosis method of bridge structure based on CNN-LSTM [J]. Foreign Electronic Measurement Technology, 2021,40(7):1-6.

[14] 马来景. 汽车桥梁耦合振动模型试验研究[D]. 郑州:郑州大学, 2020.
MA L J. Model test study on coupled vibration of automobile bridge [D]. Zhengzhou: Zhengzhou University, 2020.

[15] CHAMANGARD M, GHODRATI AMIRI G, DARVISHAN E, et al. Transfer learning for CNN-based damage detection in civil structures with insufficient data [J]. Shock and Vibration, 2022, 2022.

[16] 张庆铼. 基于卷积神经网络的浮置板轨道钢弹簧损伤检测方法研究[D]. 成都:西南交通大学, 2021.
ZHANG Q L. Research on damage detection method of floating slab track steel spring based on convolutional neural network [D]. Chengdu: Southwest Jiaotong University,2021.

[17] 杨建喜,张利凯,李韧,等.联合卷积与长短记忆神经网络的桥梁结构损伤识别研究[J].铁道科学与工程学报,2020,17(8):1893-1902.
YANG J X, ZHANG L K, LI R, et al. Research on damage identification of bridge structures based on convolutional and long-short memory neural networks [J]. Chinese Journal of Railway Science and Engineering, 2020,17(8): 1893-1902.

[18] 张国臣.大跨度自锚式悬索桥车桥耦合振动分析[D].郑州:郑州大学,2021.
ZHANG G CH. Vehicle-bridge coupling vibration analysis of long-span self-anchored suspension bridge [D]. Zhengzhou: Zhengzhou University, 2021.

作 者 简 介

李整,博士,讲师,主要研究方向为桥梁结构分析及桥涵水文计算。
E-mail:lizhengcdh@zzu.edu.cn

李奥利,硕士研究生,主要研究方向为桥梁结构及有限元分析。
E-mail:liaoli@gs.zzu.edu.cn

陈代海,博士,副教授,主要研究方向为桥梁振动与稳定、车桥共振、桥梁抗震等。
E-mail:chendaihai1982@163.com

许世展,博士,教授,主要研究方向为复杂桥梁结构理论及力学行为,在役桥梁维护加固与安全评价。
E-mail:xushizhan@zzu.edu.cn

张宇,本科,高级工程师,主要研究方向为高速公路建设与养护管理工作。
E-mail:121905898@qq.com