

# 基于声发射和卷积神经网络的混凝土桥梁 损伤预测研究

袁明<sup>1</sup>, 王烁<sup>1</sup>, 颜东煌<sup>1</sup>, 刘昀<sup>1,2</sup>, 黄练<sup>1</sup>

(1. 长沙理工大学 土木工程学院, 湖南 长沙 410114; 2. 湖南交通职业技术学院 路桥工程学院, 湖南 长沙 410132)

**摘要:** 为了有效识别混凝土桥梁结构的损伤程度, 及时评估结构状态, 该文基于卷积神经网络开展部分预应力混凝土斜拉桥损伤模型试验, 通过试验梁不同损伤状态下的声发射波形信号, 利用卷积神经网络对试验梁的损伤程度进行识别与预测。首先搭建完成了由卷积层、池化层、全连接层和一个 SoftMax 层组成的卷积神经网络架构; 然后将试验梁分级加载至极限状态 3 次, 获得相同加载情况下的 3 组声发射波形信号, 将前 2 组声发射信号输入之前搭建的 CNN 模型并完成训练后, 得到卷积神经网络识别系统, 第 3 组声发射信号用于该识别系统预测试验梁的损伤状态, 以验证该识别方法的有效性。研究表明: 基于卷积神经网络与声发射技术成功预测出试验梁的损伤程度, 3 104 个声发射信号的综合准确率达 96.71%; 两层卷积层加上两层全连接层的网络架构的预测效果最优; 对比传统的 BP 神经网络, 卷积神经网络准确率高 5%~10%。

**关键词:** 混凝土桥梁; 声发射; 卷积神经网络; BP 神经网络; 损伤识别; 波形信号

**中图分类号:** U441+.4

**文献标志码:** A

桥梁因长期暴露在外部荷载和不利的环境因素下, 容易出现各种损伤和破坏<sup>[1-3]</sup>。桥梁裂缝宽度是评价混凝土桥梁损伤程度的重要观测参数。目前, 各种无损检测技术已被成功应用于检测和识别桥梁结构的裂缝<sup>[4]</sup>, 例如, 视觉检测、数字图像关联技术(DIC)<sup>[5]</sup>、带摄像头的无人机(UAV)<sup>[6]</sup>和声发射技术(AE)<sup>[7]</sup>。其中, 声发射技术是一种新型的动态无损检测技术, 可以接收结构内部释放的微弱应力波, 并将其转化为电信号进入系统进行处理。20 世纪 90 年代就有部分国外学者发现声发射可以应用于混凝土桥梁结构的监控<sup>[8-9]</sup>。随着声发射技术的发展和完善, 该技术的分析方法也在不断进步。此外, 由于声发射技术在被动检测和综合监测能力方面的优势, 它经常被用于实时损伤检测<sup>[10-11]</sup>。不少试验研究表明: 不同的材料在外界荷载作用下, 声发射信号会表现出不同的特征和趋势。因此, 如何准确分析声发射信号, 是研究声发射技术在桥梁损伤检测中的重要问题。目前常用的声发射信号分析方法包括特征参数分析法和时频分析法。Tonelli 等<sup>[12]</sup>分析了负载下退役桥梁的声发射信号参数的特点; 张艳博等<sup>[13]</sup>利用时频分析法研究了花

岗岩的破裂过程; 袁明等<sup>[14]</sup>提出了一种改进的损伤模型, 采用三次多项式模型建立声发射参数与应力水平之间的定量关系, 从而推导出混凝土梁的损伤演化方程, 并从试件与构件层次采用 3 种损伤模型对损伤量进行了计算。然而这些关系都是经验性的。到目前为止, 声发射事件数与混凝土的损伤程度还没有建立起一个基本的理论关系, 似乎这种关系并不存在<sup>[15]</sup>。在混凝土桥梁损伤识别的实际应用中, 信号存在噪音多、损伤状态复杂、数据量庞大等问题, 这些制约着声发射技术在实际工程中的应用。并且, 目前现有的声发射信号处理方法过分依赖于先验知识, 不同的材料和结构需要不同的先验知识才能完成损伤预测。

近年来, 人工智能算法(AI)和有限元建模(FEM)被广泛用于分析和预测结构损伤的形成和扩展<sup>[16-19]</sup>。王岩等<sup>[20]</sup>利用 BP 人工神经网络和声发射技术有效预测和识别了混凝土的损伤程度。然而, 传统的人工神经网络仍然需要先验知识, 例如需要知道哪些声发射特征参数是神经网络所敏感的。相比较于 BP 人工神经网络, 卷积神经网络(CNN)是一种更为有效的人工智能算法, 它能够学习更为复杂的输入和输出关系。

**收稿日期:** 2021-11-22(修改稿)

**基金项目:** 国家重点基础研究发展计划(“973”计划)项目(编号:2015CB057706); 国家自然科学基金资助项目(编号:51878074, 52078054, 51678068); 湖南省教育厅科学研究项目(编号:18B140); 湖南省交通科技项目(编号:201932)

**作者简介:** 袁明, 男, 博士, 副教授, E-mail: mingyuan@csust.edu.cn

张瑞程等<sup>[21]</sup>提出基于一维卷积神经网络的燃气管道故障诊断模型,提取了原始声发射信号特征参数,能有效诊断燃气管道故障;董靖川等<sup>[22]</sup>利用分布式的卷积神经网络对刀具的磨损程度进行预测,其提出的卷积神经网络以原始波形作为模型输入,相比较于传统的BP神经网络,性能提高了51.3%。卷积神经网络的输入由于可以是整个信号波形或者是它们的转换,而不是从信号中提取出某些特征参数,意味着卷积神经网络有着更强的映射能力。基于此,该文将结合声发射和卷积神经网络对混凝土结构损伤程度进行识别和预测,这对结构状态预警及结构服役安全具有重要意义。综上所述,该文旨在开发一种更有效的桥梁结构损伤预测方法,该方法是将声发射技术与卷积神经网络(CNN)算法相结合,并通过斜拉桥模型进行试验验证,以说明该方法的有效性。此外,该文还将具体讨论

卷积神经网络的架构设置,并与传统的BP神经网络性能进行对比。

1 损伤预测方法

图1为基于卷积神经网络与声发射技术的损伤预测方法的技术路线。首先利用声发射采集系统获取桥梁破坏过程的声发射信号,然后利用小波分解算法获取波形信号的二维时频域分解图,将分解完成的信号输入给已经完成训练的卷积神经网络并完成预测结果。该文采用王岩等<sup>[20]</sup>利用BP神经网络预测混凝土结构损伤程度中的分类方法,具体分类情况如下:轻度损伤对应0%~40%极限荷载;中度损伤对应40%~75%极限荷载;严重损伤对应75%~100%极限荷载。

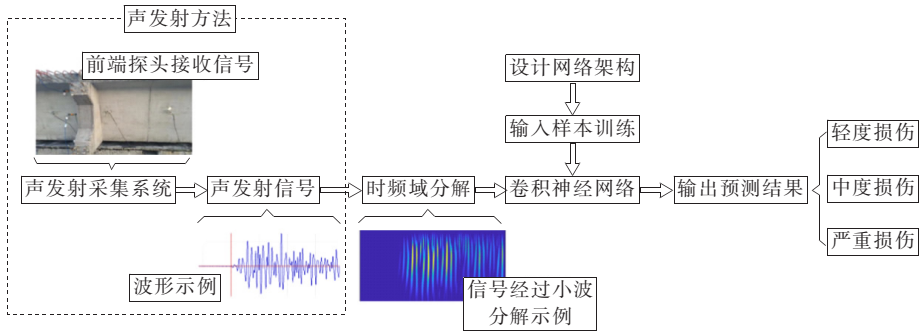


图1 基于卷积神经网络与声发射技术的损伤预测方法技术路线

1.1 声发射技术原理

基于声发射技术定位方法的原理如图2所示。损伤产生的微振动将以应力波的形式传播一段距离,然后到达材料表面,在材料表面引起位移。声发射传感器检测到该位移并将其转换成电信号。之后,该信号被前置放大器放大,然后被过滤器过滤,并被A/D转换器捕获。最后,它被传输到数据处理系统进行分析 and 处理。

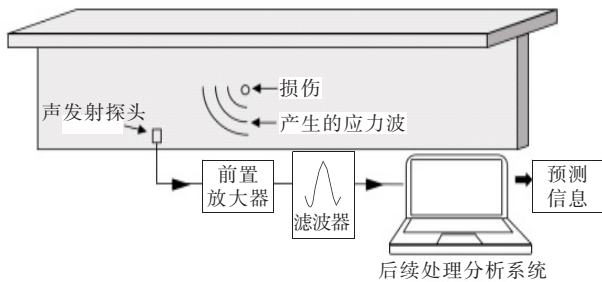


图2 声发射技术原理简图

1.2 卷积神经网络架构

图3为卷积神经网络的训练过程。首先,需要搭建适合于损伤预测任务的卷积神经网络模型,该文采用的CNN由卷积层、池化层、全连接层和一个Soft-Max层组成。图3简单描述了该文所使用的卷积神经网络架构,其超参数设置如下:卷积层的核大小为3×3,步长为2,池化层的池大小为2,激活函数使用ReLU函数,优化器为Adam优化器,学习率为0.0001。后文即是基于这种典型的CNN结构。每个特征图由多个神经元组成,每层的特征图作为下一层的输入。卷积层的特征图与上一层的特征图相关。为了保持主要特征并减少下一层的神经元数量,应用了池化层。

1.2.1 卷积神经网络输入模式

为了捕捉声发射信号的多模态和色散特性以及混响特性,在连续小波变换的基础上进行了时频分析,并将其作为卷积神经网络的输入。 $f(t)$ 为声发射波形。




图3 卷积神经网络架构

$L^2(R)$ 空间中的  $f(t)$  函数在小波基下被展开,这种展开被称为连续小波变换。连续小波变换的定义为<sup>[26-27]</sup>:

$$WT_f(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^* \left( \frac{t-b}{a} \right) dt \quad (1)$$

式中:  $a$  为比例因子;  $b$  为位移因子。在该文中,比例因子为频率参数,位移因子为时间参数,所以一维的声发射信号一经连续小波变换,就意味着将一个时间函数投影到二维的时间-频率相平面上。此外,  $\psi^*(t)$  为母小波;  $*$  为复数共轭。

该文使用的母小波是 Morlet 小波,其表达式为高斯包络下的单频复数正弦函数:

$$\psi(t) = C e^{-\frac{t^2}{2}} \cos(5x) \quad (2)$$

式中:  $C$  为重构中的归一化常数:

$$C = \frac{1}{\int_{-\infty}^{+\infty} \|\psi(t)\|_2 dt} \quad (3)$$

数据格式为  $1 \times 1\,024$  的波形信号经过连续小波变换后变换成二维的  $256 \times 256$  的二维矩阵,随后送入卷积神经网络进行训练。

### 1.2.2 卷积神经网络卷积层设置

卷积层中每个神经元的输入来自上一层特征图的固定区域的神经元,其大小由卷积核的大小决定。卷积使用权重矩阵  $\omega_{u,v}$  进行计算,通常被称为核,其通过反向传播算法训练。卷积层的数学表达式如下:

$$y_{i,j}^{(l)} = f \left[ \sum_{u=0}^{n-1} \sum_{v=0}^{n-1} \omega_{u,v} y_{(i+u),(j+v)}^{(l-1)} + b_{u,v}^{(l)} \right] \quad (4)$$

式中:  $y_{i,j}^{(l)}$  为卷积层的每个神经元输出;  $l$  为当前的层数;  $f$  为 ReLU 激活函数;  $\omega_{u,v}$  为卷积核;  $n$  为卷积核大小,在该文中,统一使用  $3 \times 3$  的卷积核;  $y_{(i+u),(j+v)}^{(l-1)}$  为上一层特征图中固定区域的神经元,这个神经元是通过索引  $i, j$  和平移  $u, v$  得到的;  $b_{u,v}^{(l)}$  为神经元在卷

积层的特征图上的偏置。

### 1.2.3 卷积神经网络池化层设置

池化层模拟了复杂的细胞过程,将初级视觉特征过滤和组合成更高级、更抽象的视觉特征,该功能在网络中通过采样实现。池化层采样后,输出特征图的数量不变,数据格式大小变小,有利于降低计算复杂性和抵抗小位移变化的作用。该文所采用的池化层的最大采样尺寸为  $2 \times 2$ ,即把输入的特征图分成一个个  $2 \times 2$  大小的矩阵,不重叠。每个矩形取最大值,这样输出特征图的长度和宽度就是输入特征图的一半。在该文中,池化层的数学表达式为:

$$y_{i,j}^{(l)} = \text{down}[y_{i,j}^{(l-1)}] \quad (5)$$

式中:  $\text{down}$  为取样最大值的函数;  $y_{i,j}^{(l-1)}$  和  $y_{i,j}^{(l)}$  分别为上一层输入的特征图和该池化层的输出。

### 1.2.4 卷积神经网络全连接层设置

为了增强网络的非线性映射能力,同时限制网络的大小,在卷积层中提取特征后,网络被插入全连接层中。该层中的每个神经元都与前一层的所有神经元相互连接。其数学表达式为:

$$o_j^{(l)} = f \left( \sum_{i=1}^n x_i^{(l-1)} \omega_{i,j}^{(l)} + b_j^{(l)} \right) \quad (6)$$

式中:  $n$  为前一层的神经元数量;  $l$  为当前层;  $\omega_{i,j}^{(l)}$  为该层的神经元与前一层的神经元之间的连接权重;  $b_j^{(l)}$  为该层神经元的偏置;  $f$  为 ReLU 激活函数。

## 2 部分预应力混凝土斜拉桥损伤模型试验

### 2.1 声发射参数设置

试验使用声学物理公司(PAC)的 Micro-2 Samous 数字声发射系统仪器。该损伤试验中声发射仪器设置参数如下:阈值为 45 dB,测试的采样频率为



1 MHz。波长采样长度为 1 k(1 024)，前置放大器增益为 40 dB，峰值识别时间被设定为 250  $\mu$ s，冲击识别时间被设定为 500  $\mu$ s。该声发射仪器通过附着在试验梁上的传感器来捕捉损伤产生的波形信号，然后通过自编写的 LabVIEW 程序输出各个波形信号。每次构件振动产生的声发射信号(1 $\times$ 1 024)经过小波分解(256 $\times$ 256)后送入编译好的卷积神经网络架构训练，最终给出训练完成的卷积神经网络模型。在该文中，为了捕获混凝土损伤信号的多模态和色散特性以及混响特性，将波形信号进行小波变换<sup>[23-25]</sup>作为卷积神经网络的二维时频域输入。

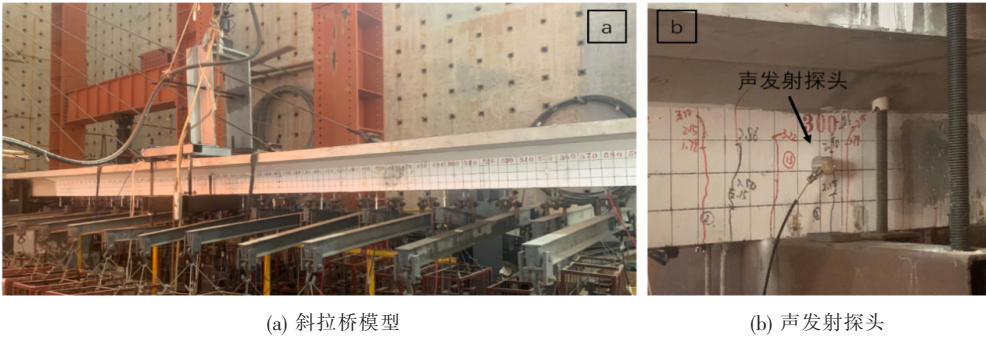


图 4 PC 斜拉桥模型静载试验

表 1 分级加载试验方案				
级数	活载倍数/倍	均布荷载/N	集中力/kN	损伤程度划分
1	0	0	0	轻度
2	1.08	150	11.7	轻度
3	2.15	300	23.2	轻度
4	3.22	450	34.8	中度
5	4.28	600	46.3	中度
6	5.35	750	57.9	中度
7	6.07	850	65.7	严重
8	6.78	950	73.4	严重
9	7.49	1 050	81.0	严重
7	6.07	850	65.7	
5	4.28	600	46.3	
3	2.15	300	23.2	
1	0	0	0	

由图 5 可知：第 1 次加载试验后的残余变形达到 7.63 mm，说明构件已经进入塑性工作阶段。为了确保试验安全，并没有继续加大荷载至完全破坏，而是将 7.49 倍活载作为构件正常使用的极限荷载。

2.2 试验模型及数据集划分

以某 PC 斜拉桥为工程研究背景<sup>[28]</sup>，并根据相似性原理，确定了 1：7.42 的斜拉桥缩尺比例。如图 4(a)所示搭建斜拉桥模型，通过布置在斜拉桥模型跨中腹板上的声发射探头[图 4(b)]采集损伤过程中产生的声发射信号。试验采用车道荷载对试验梁加载，标准车道荷载包含均布荷载和一个集中荷载。表 1 为分级加载试验方案<sup>[29-30]</sup>。分级加载试验重复进行 3 次，均加载至 7.49 倍活载，并实测出试验梁最大裂缝宽度为 0.53 mm。图 5 为 3 次加载试验的跨中位移的滞回曲线，其中跨中位移已经消除了支座位移的影响。




图 5 3 次加载试验的滞回曲线

表 2 为 3 次试验采集的样本数量。3 次试验所采集的数据分别编号为 C1~C3，其中 C1、C2 组数据将用于卷积神经网络的训练，C3 组数据用于评价该方法的性能。

表 2 声发射信号样本数量				
样本编号	不同损伤程度样本数量/个			任务
	轻度	中度	严重	
C1	455	1 024	1 545	训练
C2	526	786	1 254	训练
C3	872	1 245	987	测试

3 试验结果及分析

3.1 预测准确率

在利用 C1、C2 组试验数据完成对卷积神经网络的训练后,将 C3 组试验数据作为测试样本送入训练好的卷积神经网络,让其对每个信号所处的损伤程度进行预测分类,并将其与真实的损伤程度分类进行对比,将正确预测的样本量除以总测试样本量得到该方法的预测准确率。表 3 为 C3 组数据中不同损伤阶段信号的预测准确率,轻度、中度和严重的预测准确率分别达到了 95.18%、97.99%和 96.45%。值得注意的是,卷积神经网络仅学习了 C1、C2 组试验数据,在预测 C3 组时便能将误差控制在 5%以内,说明该方法可以用于该部分预应力混凝土斜拉桥模型损伤试验的损伤程度预测。

表 3 预测 C3 组信号损伤程度的准确率

损伤程度	荷载水平/ %	样本数量/ 个	预测准确率/ %
轻度	0~40	872	95.18
中度	40~75	1 245	97.99
严重	75~100	987	96.45
综合		3 104	96.71

尽管该方法的损伤预测非常准确,但不可避免会将极小一部分的信号误判成与实际情况不相符的损伤阶段。分析产生“误预测”的原因主要有:① 现有的深度学习算法都存在性能上限,其根本原因在于训练样本与测试样本做不到完全的“一致”,C1、C2 与 C3 组声发射样本数据并不是在完全相同的工况下获取的,尽管加载工况是一致的,每一次加载试验梁损伤会得到积累,而且加载进程会存在一定程度的随机性。因此这种原因带来的误差不可避免;② 各种损伤阶段的划分是一种人为手段,但是混凝土的损伤开裂实际上是一种连续演变的过程,处在两种损伤阶段界限附近的信号会有极大概率会被卷积神经网络误判成“相邻”的损伤阶段。

3.2 卷积神经网络架构对损伤程度预测结果的影响

针对不同的应用,卷积神经网络的架构是影响其预测准确率的一个重要因素,它们之间主要的区别在于卷积层与全连接层的数量多少。不同卷积神经网络下的预测准确率如图 6 所示,图中 C 和 D 分别为卷积层和全连接层数,例如 2C—2D 代表两层卷积层加上

两层全连接层。

由图 6 可知:在 3 种不同的损伤阶段中,2C—2D 的卷积神经网络架构的准确率更高,表明其更适用于该应用。在所有参与测试的架构中,构造最复杂的 5C—5D 网络架构比准确率最高的 2C—2D 网络架构低 6%~8%,而简单的 1C—1D 架构的准确率仅比 2C—2D 低 1%~2%。4C—4D 的网络架构虽然对中度和严重损伤阶段信号的识别率较高,但是对数据量较少的轻度损伤信号识别较差,其综合性能不如 2C—2D 的网络架构。主要原因可能是不均匀的数据集划分对特定的网络架构的训练结果产生不利影响。另外,卷积神经网络的权值和阈值的初始值是随机产生的,因此网络架构的性能存在一定的随机性。总体上可以发现越复杂的网络架构往往性能越差,而最简单的 1C—1D 的网络架构也有非常良好的识别准确率。




图 6 不同卷积神经网络架构下损伤程度预测的准确率变化

在卷积神经网络的架构中,网络层数越多,网络的表现力就越强,即越能拟合复杂函数。然而,随着网络拟合能力的提高,该模型也容易出现“过拟合”,即在训练样本上表现较好,但在测试样本上表现较差。该文所描述的应用中,并不是更复杂的网络架构性能表现更好,更复杂的架构意味着网络本身更容易“过拟合”。对于简单的损伤分类任务,浅层的卷积神经网络往往性能优异,并且节省训练的时间成本。

3.3 BP 神经网络预测损伤程度结果对比

已有研究表明<sup>[31]</sup>:幅值、振铃数、持续时间、能量、绝对能量及信号强度 6 个参数能够较好地体现混凝土损伤过程的阶段性特征,并且适用于 BP 神经网络来预测混凝土的损伤程度,所以该节采用 BP 神经网络的输入取这 6 个参数进行分析。BP 神经网络的隐含层节点数是影响神经网络性能的关键,为了确定最佳的 BP 神经网络性能,对比了不同隐含层节点数下的 BP 神经网络性能,得到综合识别准确率分布如图 7 所示。当隐含层节点数为 22 时,BP 神经网络的三阶段

损伤程度综合识别准确率最高,为 89.01%。表 4 为最优的 BP 神经网络(22 节点数)与最优卷积神经网络(2C-2D)的具体预测损伤结果对比。结果表明:卷积神经网络的性能明显优于 BP 神经网络。其根本原因在于 BP 神经网络的输入仅有  $1\times 6$  的向量,卷积神经网络能够对  $256\times 256$  的二维矩阵进行训练学习,其带来的信息量的提升是非常巨大的。对于声发射信号而言,提取其特征参数尽管能够节省分析成本,但也意味着忽略掉了许多信号本身重要的信息,从而导致 BP 神经网络对损伤程度预测结果比卷积神经网络有所不足。




图 7 不同隐藏节点数下的 BP 神经网络的准确率分布

表 4 卷积神经网络与 BP 神经网络的性能对比

损伤识别方法	网络输入	隐藏层	不同损伤程度预测准确率/%		
			轻度	中度	严重
BP 神经网络	6 个特征参数(1×6)	22 个节点	90.83	89.96	86.22
卷积神经网络	二维小波分解后的波形(256×256)	2C-2D	95.18	97.99	96.45

4 结论

针对采用声发射方法监测混凝土构件损伤程度的问题,搭建并训练适用于该应用的卷积神经网络,通过部分预应力混凝土斜拉桥模型损伤试验中轻度、中度和严重 3 类损伤信号验证了该方法的有效性。研究表明:

(1) 基于卷积神经网络与声发射技术可以很好地预测出混凝土的损伤,识别结构损伤程度,3 104 个声发射信号的综合准确率达 96.71%。该方法能够在完全不需要先验知识的情况下完成损伤程度的有效识别,具有很强的泛化能力,并且有效提高了对混凝土构件安全性能的预警能力和综合判断能力。

(2) 在混凝土损伤程度预测应用中,预测效果最好的卷积神经网络是两层卷积层加上两层全连接层的网络架构(2C-2D),相比较于 5C-5D 的网络,其准确率提高 5%。说明浅层的卷积神经网络的性能更加优异,多层的卷积神经网络反而训练时间更长,损伤预测准确率下降。

(3) 在相同的数据集训练与验证情况下,对比传统的 BP 神经网络,卷积神经网络准确率高出 5%~10%,并且能够对多维数的波形信号进行训练和识别,并不依赖于声发射信号特征参数的提取。

参考文献:

[1] YUAN Ming, YAN Donghuang, ZHONG Hao, et al. Experimental Investigation of High-Cycle Fatigue Behavior for Prestressed Concrete Box-Girders[J]. Construction and Building Materials, 2017, 157: 424-437.

[2] PENG Jianxin, HU Shouwang, ZHANG Jianren, et al. Influence of Cracks on Chloride Diffusivity in Concrete: A Five-Phase Mesoscale Model Approach[J]. Construction and Building Materials, 2019, 197: 587-596.

[3] LUCA Bertolini. Steel Corrosion and Service Life of Reinforced Concrete Structures[J]. Structure and Infrastructure Engineering, 2008, 4(2): 123-137.

[4] MAYUNGA Selassie David, BAKAONE M. Dynamic Deformation Monitoring of Lotsane Bridge Using Global Positioning Systems (GPS) and Linear Variable Differential Transducers (LVDT)[J]. Journal of Data Analysis and Information Processing, 2021, 9(1): 30-50.

[5] HAYDER Al-Salih, MARY Juno, WILLIAM Collins, et al. Evaluation of a Digital Image Correlation Bridge Inspection Methodology on Complex Distortion-Induced Fatigue Cracking[J]. Procedia Structural Integrity, 2019, 17: 682-689.

[6] CHEN Gongfa, LIANG Qiang, ZHONG Wentao, et al. Homography-Based Measurement of Bridge Vibration Using UAV and DIC Method[J]. Measurement, 2021, 170.

[7] RAFAL Anay, ABRAM Lane, DAVID V, et al. On-Site Acoustic-Emission Monitoring for a Prestressed Concrete BT-54 AASHTO Girder Bridge[J]. Journal of Perform-

- ance of Constructed Facilities, 2020, 34(3).
- [8] ROYLES R. Acoustic Emission Monitoring of Masonry Arch Bridges British[J]. Journal of Non-Destructive Testing, 1991, 33(7): 339—343.
- [9] HICK H, WILIER I F, Winter E, et al. Acoustic Emission Measurements on Bridges [J]. Journal of Acoustic Emission, 1992, 10(3—4): 67—70.
- [10] AMIR Nasrollahi, DENG Wen, MA Zhaoyun, et al. Multimodal Structural Health Monitoring Based on Active and Passive Sensing[J]. Structural Health Monitoring, 2018, 17(2): 395—409.
- [11] KIM Yong Min, HAN Gyeol, KIM Hyunwoo, et al. An Integrated Approach to Real-Time Acoustic Emission Damage Source Localization in Piled Raft Foundations [J]. Applied Sciences, 2020, 10(23): 8 727.
- [12] TONELLI Daniel, LUCHETTA Michele, ROSSI Francesco, et al. Structural Health Monitoring Based on Acoustic Emissions: Validation on a Prestressed Concrete Bridge Tested to Failure[J]. Sensors (Basel, Switzerland), 2020, 20(24): 7 272.
- [13] 张艳博, 张行, 梁鹏, 等. 花岗岩破裂过程声发射横、纵波时频特征实验研究[J]. 岩石力学与工程学报, 2019, 38(S2): 3 554—3 564.
- [14] 袁明, 黄练, 彭卓, 等. 基于声发射技术的混凝土梁桥弯剪受力状态下损伤试验[J]. 长安大学学报(自然科学版), 2019, 39(2): 73—81.
- [15] 陈兵, 姚武, 吴科如. 声发射技术在混凝土研究中的应用[J]. 无损检测, 2000, 22(1): 387—391.
- [16] LIEBOLD F, MAAS H G. Strategy for Crack Width Measurement of Multiple Crack Patterns in Civil Engineering Material Testing Using a Monocular Image Sequence Analysis[J]. PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science, 2020, 88(3—4): 1—20.
- [17] CASTORENA González J H, MARTIN U, GAONA Tiburcio C, et al. Modeling Steel Corrosion Failure in Reinforced Concrete by Cover Crack Width 3D FEM Analysis[J]. Frontiers in Materials, 2020, 7.
- [18] ALEJANDRO Nogales, ALBERT de la Fuente. Crack Width Design Approach for Fibre Reinforced Concrete Tunnel Segments for TBM Thrust Loads[J]. Tunnelling and Underground Space Technology Incorporating Trenchless Technology Research, 2020, 98: 103 342.
- [19] ISLAM A. B. M. Saiful. Computer Aided Failure Prediction of Reinforced Concrete Beam [J]. Computers and Concrete, 2020, 25(1): 67—73.
- [20] 王岩, 张友桃, 胡鸿翔, 等. 基于声发射和人工神经网络的混凝土损伤程度识别[J]. 建筑材料学报, 2014, 17(4): 672—676.
- [21] 张瑞程, 王新颖, 胡磊磊, 等. 基于一维卷积神经网络的燃气管道泄漏声发射信号识别[J]. 中国安全生产科学技术, 2021, 17(2): 104—109.
- [22] 董靖川, 徐明达, 王太勇, 等. 分布式卷积神经网络在刀具磨损量预测中的应用[J]. 机械科学与技术, 2020, 39(3): 329—335.
- [23] SARRAFI Aral, ZHU Mao, NIEZRECKI Christopher, et al. Vibration-Based Damage Detection in Wind Turbine Blades Using Phase-Based Motion Estimation and Motion Magnification[J]. Journal of Sound and Vibration, 2018, 421(1): 300—318.
- [24] SARRAFI Aral, ZHU Mao. Structural Operating Deflection Shape Estimation via a Hybrid Computer-Vision Algorithm[P]. Smart Structures and Materials + Non-destructive Evaluation and Health Monitoring, 2018.
- [25] MOHAMMADI-GHAZI Reza, MARZOUK Youssef M, BÜYÜKÖZTÜRK Oral. Conditional Classifiers and Boosted Conditional Gaussian Mixture Model for Novelty Detection [J]. Pattern Recognition, 2018, 81: 601—614.
- [26] GRIFFEL D H. Ten Lectures on Wavelets [J]. The Mathematical Gazette, 1995, 79(484): 224—227.
- [27] DAVID F. Walnut. An Introduction to Wavelet Analysis [M]. Birkhäuser, Boston, MA, 2004.
- [28] 卢绍鸿. 广州南二环李家沙大桥设计[J]. 公路工程, 2013, 38(4): 137—139, 182.
- [29] 刘昀, 颜东煌. 部分预应力混凝土斜拉桥设计的合理性分析[J]. 中外公路, 2015, 35(2): 83—86.
- [30] 颜东煌, 邹恺为, 袁明, 等. 采用 PPC 设计的斜拉桥模型疲劳试验研究[J]. 中外公路, 2021, 41(1): 59—63.
- [31] 吴胜兴, 王岩, 李佳, 等. 混凝土静态轴拉声发射试验相关参数研究[J]. 振动与冲击, 2011, 30(5): 196—204.