

利用单传感器数据基于 GAF-CNN 的结构损伤识别*

骆勇鹏^{1,2}, 王林堃¹, 郭旭¹, 郑金铃¹, 廖飞宇¹, 刘景良¹

(1. 福建农林大学交通与土木工程学院 福州, 350108)

(2. 福建省结构工程与防灾重点实验室(华侨大学) 厦门, 361021)

摘要 为了减少损伤识别所需传感器数量,降低监测系统造价及海量数据的处理成本,提出了基于单传感器数据结合格拉姆角场(Gramian angular field, 简称 GAF)和卷积神经网络(convolutional neural networks, 简称 CNN)的结构损伤识别方法。采用 GAF 理论将原始振动信号分别转换为格拉姆角和场(Gramian angular summation field, 简称 GASF)和格拉姆角差场(Gramian angular difference field, 简称 GADF)二维图像,以转换后的 GASF 和 GADF 两类图像数据集为输入,基于 LeNet-5 结构下的浅层卷积神经网络模型,训练最优二维 CNN 模型用于结构损伤识别。以国际桥梁维护和安全协会提出的结构健康监测基准模型结构及一榀钢框架结构为例,研究振动信号转化为二维图像算法、卷积神经网络模型参数、传感器布置位置及测量噪声对识别结果的影响。结果表明:所提算法仅需单个传感器数据即可实现损伤识别的目的,数值模拟及模型试验的损伤识别准确率均为 100%,单条样本测试时间为 8.5 ms 左右,满足结构健康监测在线损伤识别的需求,且受传感器布置位置和噪声程度影响较小;GADF 图较 GASF 图收敛效率更高,震荡幅度更小,受局部最优值影响较小,在样本数量规模一致的状态下,更易训练生成最优二维 CNN 模型。

关键词 结构健康监测;损伤识别;振动响应;深度学习;卷积神经网络;传感器
中图分类号 U446.2; TU317

引言

损伤识别作为结构健康监测的核心技术,已取得一定的成果,特别是基于动力特性的结构损伤识别方法^[1-4]。现有的结构健康监测系统价格昂贵,其主要成本集中在大量的传感器上,在取得结构精细的响应数据的同时,也导致了数据的海量存储与自动处理的问题。在这样的背景下,如何使用少量传感器,降低成本,完成基本的健康监测任务有着非常重要的意义^[5]。

卷积神经网络作为实现深度学习理论的重要算法之一,在各类模式识别问题中均展现出了优异的性能^[6-7],其局部感知的特性使其相比于深度神经网络适应能力更强。相关研究亦证明,结合 CNN 进行结构损伤识别是可行的。Abdeljaber 等^[8]采用一维 CNN 模型成功识别了国际结构控制协会与美国土木工程学会提出的结构健康监测基准模型中的 9 种损伤工况,展现出了一维 CNN 良好的损伤识别效

果。Lin 等^[9]以信号小波能量作为特征向量输入到一维 CNN 模型中实现损伤诊断的目的。李雪松等^[10]使用卷积神经网络提取结构特征来识别损伤,并与小波包频带能量特征、前五阶本征模态函数能量特征做同分类器准确率对比,证明了卷积神经网络在自动提取特征方面的优势。李书进等^[11]以多层框架结构模型为例,从输入数据样本类别、训练时间、预测准确率、浅层与深层卷积神经网络以及对不同损伤程度的影响等方面对卷积神经网络在结构损伤诊断的应用进行了研究。相对于利用数据矩阵进行信息提取的二维 CNN 损伤识别方法,RGB 彩色图像可使二维 CNN 从多通道分析数据特征,相关学者在实现振动信号转换为 RGB 彩色图像的工作中已取得一定成效。何浩祥等^[12]将车载耦合振动下的原始结构响应信号经递归分析转化为递归图,采用二维 CNN 进行特征提取,实现对桥梁结构损伤程度和损伤定位的精准识别。

综上所述,一维时间序列和二维图像均可作为

* 国家自然科学基金资助项目(51808122);福建省自然科学基金面上资助项目(2020J01580);福建省结构工程与防灾重点实验室(华侨大学)开放研究课题资助项目(SEDPFJ-2018-01)

收稿日期:2021-02-03;修回日期:2021-05-19

值共享。该方式通过缩小矩阵尺寸来大幅降低计算所需参数,提升计算效率,在一定程度上解决了过拟合现象。

1.2.2 激活计算

激活函数作为 CNN 处理非线性映射的关键因素,在 CNN 基于所训练数据进行有监督学习时提供了不同效能的非线性建模能力。Krizhevsky 等^[14]通过测试,验证了 ReLU 函数相比 Sigmoid 函数和 tanh 函数具备更优性能,有效缓解了模型因为训练参数更新缓慢以及更新停滞造成梯度消失的现象。

鉴于 ReLU 函数的优异计算效率,笔者将其加入各隐含层,使所构建的浅层二维卷积神经网络具备更强的非线性映射学习能力。该激活函数的表达式为

$$F_{\text{ReLU}}(x) = \begin{cases} x & (x \geq 0) \\ 0 & (x < 0) \end{cases} \quad (5)$$

其中: x 为卷积核内积运算后所获权重。

激活函数 ReLU 对输入权重矩阵中具体权重进行选择归 0,使该权重在后续隐含层中的激活函数计算值恒为 0,即使该处权重位置代表的神经元失活,减少模型参数数量,提高收敛速度。

1.2.3 搭建二维卷积神经网络

基于 LeNet-5 框架进行相关试验,图 2 为 LeNet-5 构筑图。其作为有监督学习的深度学习经典框架,需要对经人工标记的一定规模数据集进行监督学习,得到用于结构损伤识别的最优模型。同时,鉴于 LeNet-5 为双卷积层构成的浅层 CNN 模型,为满足模型输入端要求,将 GAF 转化的具有信号特征的图片进行压缩,以适配 LeNet-5 中 $32 \times 32 \times 3$ 的图像输入规格。

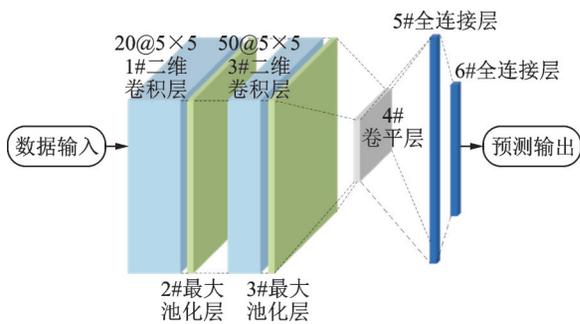


图 2 LeNet-5 构筑图

Fig.2 Construction diagram of LeNet-5

1.3 基于 GAF 和二维 CNN 的结构损伤识别流程

基于 GAF-CNN 的结构损伤识别流程如图 3 所

示。首先,采集结构某节点处的加速度响应数据;其次,以 GASF 和 GADF 两类转换方式为基础,对采集数据进行图像转换并进行人工标记,构建一定规模数据集,利用二维 CNN 获取图像数据的非线性映射能力,用于结构损伤识别的最优模型;最后,经由所得模型对 GAF 图像转换后的结构异常振动响应进行检测,实现结构损伤识别。

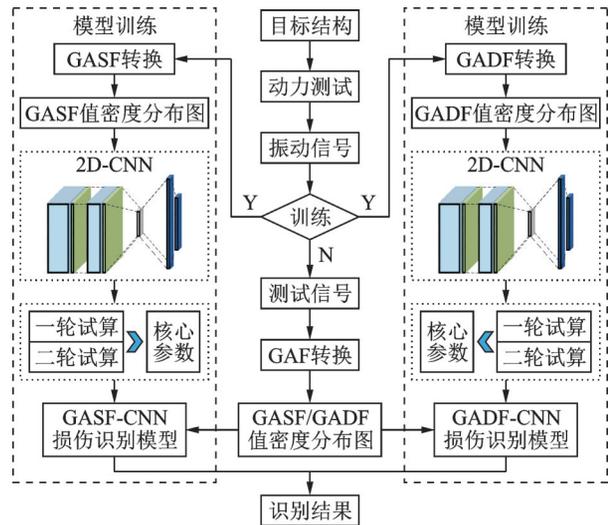


图 3 损伤识别流程图

Fig.3 The flow chart of the proposed damage identification method

2 桥梁结构健康监测基准结构验证

2.1 模型概况

以国际桥梁维护和安全协会提出的桥梁结构健康监测基准模型为例验证所提算法的可行性,图 4 为试验装置示意图。试验原型为两跨连续梁,结构参数如表 1 所示。结构各构件分别采用简支、较支、固定和半固定 4 种方式进行连接及约束,通过控制边界条件、支撑处弹性系数变化及放松连接板等模拟各类型损伤。损伤工况设置如表 2 所示。

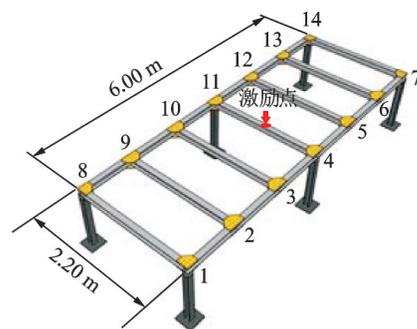


图 4 试验装置示意图

Fig.4 The diagram of test device

表1 结构参数

Tab.1 Structural parameter

部位	长/m	宽/cm	高/cm	厚/cm	单位质量/(kg·m ⁻¹)
主梁	5.49	5.92	8.57	0.43	14.67
次梁	1.83	5.92	7.62	0.43	13.99
桥墩	1.07	16.48	31.04	0.58	63.81

表2 损伤工况

Tab.2 Damage cases

工况	损伤模型	损伤类型
1	健康	—
2	释放3号点主矩	主次梁 连接损伤
3	释放3号点主矩及节点连接板	
4	释放2号和10号点主矩及节点连接板	
5	10号点铰结变为固结	主梁与桥墩
6	9号和10号铰结变为固结	连接损伤
7	支撑处弹簧系数降低10%	桥墩冲刷 损伤
8	支撑处弹簧系数降低20%	
9	支撑处弹簧系数降低30%	
10	3种损伤类别随机组合	—

利用Caicedo等^[15]基于Matlab软件开发建立的数值仿真模型进行动力测试。在结构跨中位置施加垂直方向瞬时激励,分别采集不同工况下节点1,4,7,8,11和14处的竖向加速度数据,采样频率为512 Hz。

此外,为探讨该损伤识别方法在环境噪声下的识别能力,在加速度数据中添加噪声水平分别为5%~35%的高斯白噪声用于构造模型训练及测试的数据集。数据集按6:2:2的比例划分为训练集、验证集及验证集。加速度时程曲线片段及转换结果如图5所示。

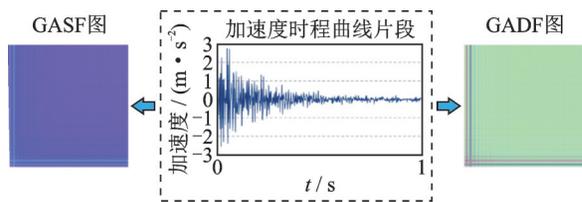


图5 加速度时程曲线片段及转换结果

Fig.5 Fragments of acceleration time history curves and conversion results

2.2 模型参数对识别精度的影响

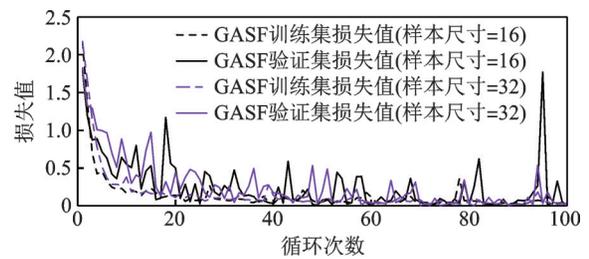
利用TensorFlow框架,基于Python语言构建LeNet-5模型。为保证识别准确率和运算速率,在模型基本结构不变的前提下针对影响模型收敛速度的学习率、迭代样本尺寸及循环次数3个核心参数进行对比分析。采用Adam默认学习率0.001,循环次数

分别为25,50和100,迭代样本尺寸分别为16,32,64为例对节点1处采集的噪声5%水平数据集进行首次试算,提取各状态下模型交叉验证准确率进行对比试验,如表3所示。模型验证集准确率可以在试算过程中初步反应模型泛化能力,而通过观察模型收敛过程中所获得的Loss值是否持续下降可以判断该模型是否还在持续学习或收敛完毕。由表3可知,当基于LeNet-5的浅层网络结构进行训练时,整体模型收敛速度快,在循环100批次状态下,模型准确率基本趋于稳定。同时,由于受迭代样本尺寸过小的影响,模型在收敛过程中产生一定震荡,导致模型易受局部最优点影响,模型训练过程参数变化如图6所示。通过对比可知,经一轮试算初步确定循环次数为100,迭代样本尺寸为32。

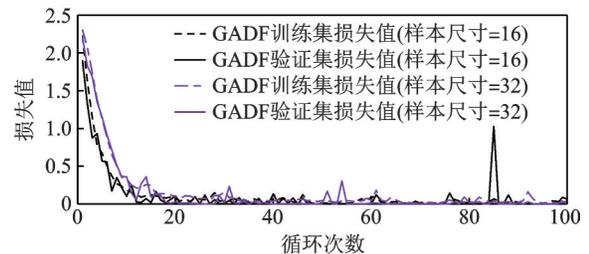
表3 参数对比试验

Tab.3 The contrastive test of parameter

循环次数	样本尺寸	GASF		GADF	
		验证集准确率/%	训练时间/s	验证集准确率/%	训练时间/s
25	16	91.25	19.96	97.50	14.23
25	32	78.75	14.27	90.00	14.50
25	64	89.50	13.50	100.00	13.38
50	16	99.25	27.11	100.00	27.67
50	32	81.50	28.10	98.00	28.41
50	64	99.75	25.87	100.00	26.07
100	16	99.75	55.68	97.75	55.69
100	32	100.00	55.98	100.00	54.96
100	64	97.00	51.40	100.00	51.63



(a) 损失值变化图(GASF)
(a) Variation diagram of loss (GASF)



(b) 损失值变化图(GADF)
(b) Variation diagram of loss (GADF)

图6 模型训练过程参数变化情况

Fig.6 Parameter variation in the training process of the model

以一轮试算所确定的参数为基础,设立 0.01, 0.001, 0.000 1 这三个数量级的学习率并进行二轮试算,学习率对比试验结果如表 4 所示。

模型训练收敛过程中相关参数变化情况如图 7

表 4 学习率对比试验结果

Tab.4 The contrast test of learning rate

循环次数	学习率	GASF		GADF	
		验证集 准确率/%	训练 时间/s	验证集 准确率/%	训练 时间/s
100	0.010 0	10.00	57.38	10.00	53.52
100	0.001 0	100.00	55.98	100.00	54.96
100	0.000 1	89.75	55.06	100.00	55.01
200	0.000 1	98.00	113.13	100.00	111.74

所示,由图 7(a),(b)可知,在学习率为 0.001 时,训练所得模型在收敛后其交叉验证集仍出现较大震荡。鉴于所建训练数据集本身规模较小,因此通过继续减小学习率来加强模型特征拾取能力。在学习率为 0.000 1 时,模型训练震荡减小,但在循环次数为 100 时, Loss 值仍缓慢下降,故增大循环次数至 200 获取最终识别模型。通过对比图 7(c),(d),判断其训练过程震荡减小且保持较好的准确率。综上,选取循环次数为 200、迭代样本尺寸为 32 及学习率为 0.000 1 用于本次损伤识别任务的模型参数。此外,通过对比发现 GADF 图较 GASF 图收敛效率更高,震荡幅度更小,受局部最优值影响较小,在样本数量规模一致的状态下,更易训练生成最优二维 CNN 模型。

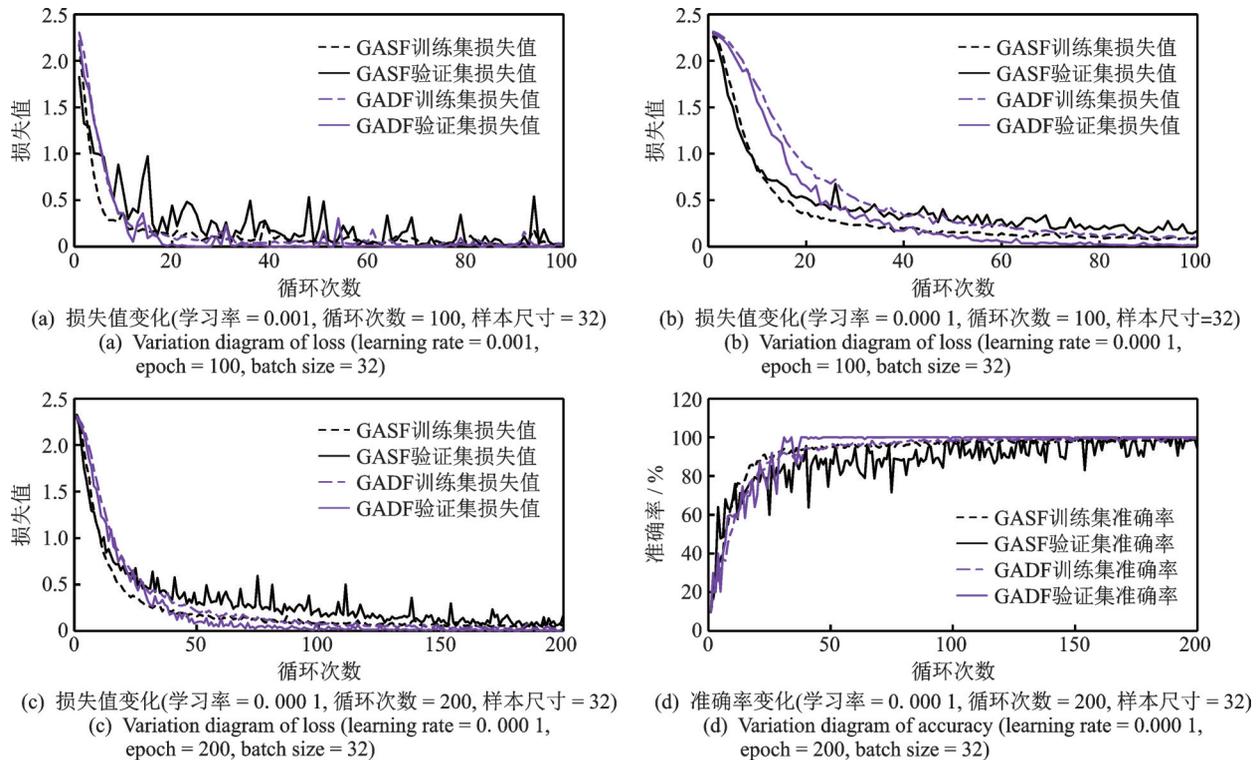


图 7 模型训练过程的参数变化情况

Fig.7 Parameter variation in the training process of the model

2.3 传感器布置位置对损伤识别结果的影响

在噪声水平为 5% 情况下,分别以节点 1, 4, 7, 8, 11 和 14 处的竖向加速度数据作为输入进行损伤识别,各传感器处模型识别准确率变化如图 8 所示。从图 8 可以看出,随着训练批次的增加,验证集准确率逐步提高,模型逐渐收敛,但各传感器处下模型收敛能力不同且振荡情况有所变化。由于 GADF 及 GASF 的编码方式差异造成图像输出角度及边界均

有所不同,因此两者在 CNN 输入端分别提供了不同的信息粒度并导致了收敛效率差异。由图 8 可发现,结合 GADF 图进行训练仍维持较快的收敛速度,循环次数为 50 后,交叉验证准确率趋于 100%,且与 GASF 图相比,模型收敛后的验证集准确率波动更小。

为验证所训练模型对于未知样本的识别能力,采集各点位 400 张图像分辨率为 512×512 的 GASF 图及 GADF 图作为测试集对训练完成的损伤识别

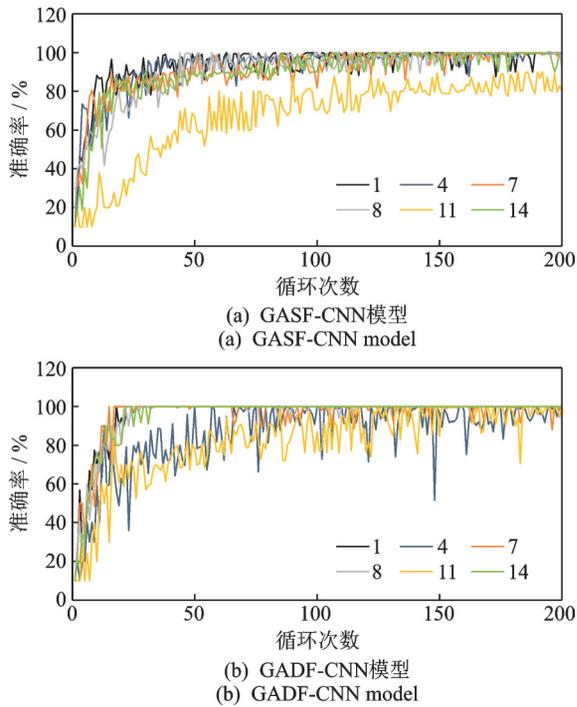


图 8 各传感器处模型识别准确率变化
Fig.8 Variation of model accuracy at each sensor

模型进行测试,结果表明,测试集准确率均达到100%。图9为各传感器处模型测试速率。从图9可知,模型在测试速率上基本保持一致,其中单条测试样本速率为5.250~8.000 ms,在具备精准识别能力的同时仍有较好的损伤识别速率。综上可知,采用单传感器数据基于GAF-CNN的损伤识别不易受传感器位置影响。

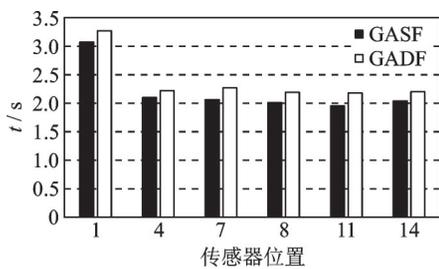


图 9 各传感器处模型测试速率
Fig.9 Test rate of the model at each sensor

2.4 噪声对损伤识别结果的影响

所提卷积神经网络模型受节点变化影响较小,故利用假定节点1处传感器所采集的5%,15%,25%和35%4种噪声水平下振动信号进行抗噪试验。各噪声水平下信号转码如图10所示。可见,同工况振动信号经转码的图片未因噪声干扰产生明显区别。利用卷积可视化工作对输入图片进行信息提取,各网络层输出结果如图11所示。从图11可知,

图像分辨率为 32×32 的输入样本经2次卷积分别生成 16×16 及 8×8 规格的特征图,各卷积层通过利用多个卷积核对输入图片进行感知并从多角度进行图片特征描述。同时,网络将自主提取并连接图片特征输出预测结果,后经网络训练循环比较预测结果优劣得到最终模型。

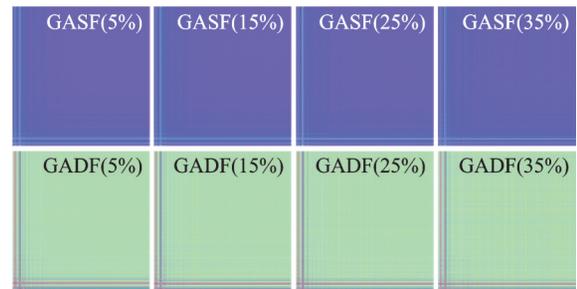


图 10 各噪声水平下信号转码图
Fig.10 Transcoding diagram of the signal at different noise levels

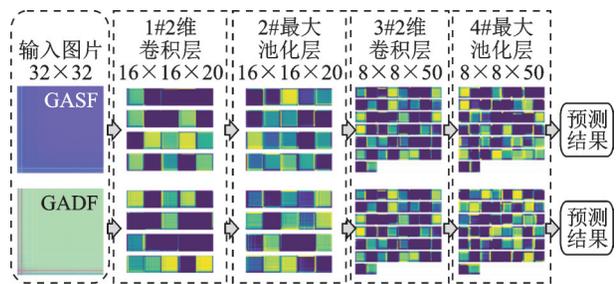


图 11 各网络层输出结果
Fig.11 The output of each network layer

当训练完成各噪声环境下的识别模型,建立与训练集比例为3:1的测试集并带入测试。经统计,识别模型在测试集中准确率均达到100%,各噪声下模型测试速率如图12所示。可见,GASF单条测试样本延迟时间为5.250~7.725 ms,GADF单条测试样本延迟时间为5.750~8.000 ms,具备收敛快、识别精确度高及良好的抗噪能力等特点。综上可知,所提方法识别结果受噪声干扰较小、具有较强的鲁棒性,对于结构损伤类型能做到准确预测和及时反馈。

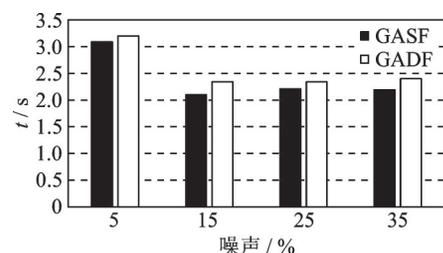


图 12 各噪声下模型测试速率
Fig.12 Test rate of model measurement under various noises

3 一榀钢框架结构损伤识别试验

该试验框架由 6 根柱子和 3 根横梁通过角钢及螺栓连接构成。其中,横梁尺寸为 350 mm×30 mm×8 mm,6 根纵梁尺寸为 250 mm×30 mm×8 mm,钢材型号为 Q235,质量密度 $\rho=7\ 850\text{ kg/m}^3$,弹性模量 $E=210\text{ GPa}$ 。框架结构试验照片如图 13 所示。

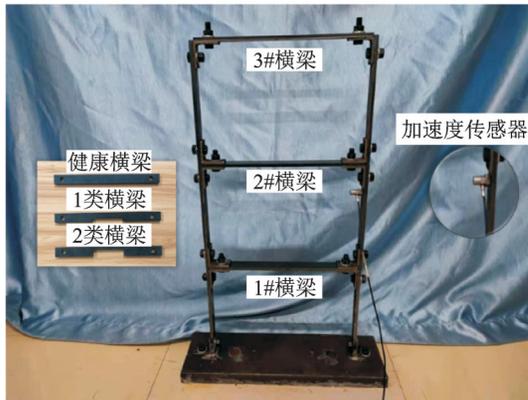


图 13 框架结构试验照片

Fig.13 Photographs of frame structure tests

试验设计带切口横梁作为损伤构件,经健康及损伤横梁位置组合构成 6 类损伤工况,工况设置如表 5 所示。在环境激励下,通过加速度传感器获取 2#横梁与纵梁连接处附近的结构横向加速度数据。其中:采样频率为 500 Hz;各工况下记录时间均为 6 s。

表 5 损伤工况
Tab.5 damage cases

工况号	损伤单元	损伤程度
1	—	健康横梁
2	1#横梁	2类横梁
3	1#横梁,2#横梁	2类横梁,2类横梁
4	2#横梁	2类横梁
5	2#横梁	1类横梁
6	1#横梁	1类横梁

为模拟现场测试等因素的影响,对该传感器采集数据进行随机切割后获取 2 994 条长度为 500 的加速度片段,结合 GAF 理论进行 GASF 及 GADF 图像转码,得到图像分辨率为 500×500 的 GADF 和 GASF 值密度分布图。所得图片经由索引标记后生成比例为 6:2:2 的训练集、验证集及测试集。将训练集及验证集代入 LeNet-5 网络基本模型,经二轮试算得到用于该实际框架的损伤识别模型网络参数,确定模型在循环次数为 50 时已收敛完毕。

根据训练过程可以发现,6 种工况在未代入模型训练时归类状态混乱复杂,经 50 次循环迭代后,各工况均得到较好的识别效果,GAF-CNN 模型归类过程如图 14 所示。此外,当采用 GASF 和 GADF 两种类型转码图像作为卷积神经网络模型输入时,模型在训练收敛及结构损伤识别效率方面均有较好结果,训练时间分别为 41.60 s 和 41.47 s。基于所训练的 GASF-CNN 及 GADF-CNN 模型对数量为 599 的陌生测试样本进行识别性能测试,测试准确率均达到 100%,测试时间分别为 4.23 s 和 5.13 s,单条测试样本延迟时间分别为 8.477 ms 和 8.564 ms。

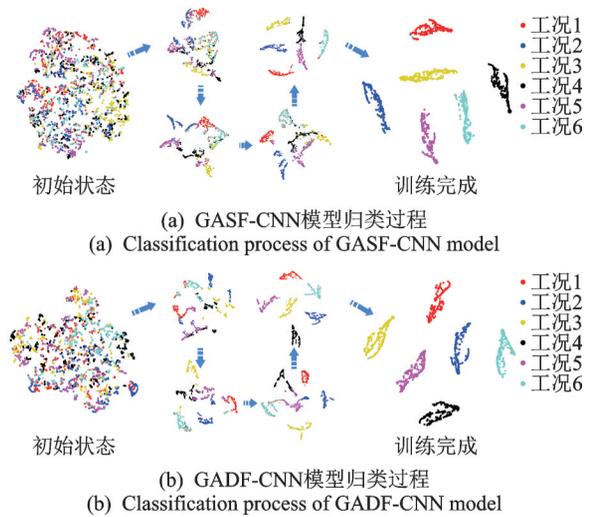


图 14 GAF-CNN 模型归类过程

Fig.14 Classification process of GAF-CNN model

4 结 论

1) 所提算法仅需单个传感器数据即可完成损伤识别,具备良好的抗噪性能。此外,传感器布设位置对损伤识别精度影响较小。

2) CNN 模型在 GASF 及 GADF 两种编码方式下具备快速收敛能力和计算速率,数值模拟算例及试验算例的训练收敛时间分别在 114 s 和 42 s 以内,单条样本测试时间在 10 ms 以内,满足结构健康监测在线损伤识别的需求。

3) 基于 GASF 及 GADF 作为输入的 CNN 模型均有较好的损伤识别精度,但基于 GADF 的 CNN 模型拥有更强的非线性拟合能力,在有限数据所构成的数据集下,训练受样本局部最优值影响小,更易生成用于结构损伤识别模型。

参 考 文 献

[1] 朱宏平,余璟,张俊兵.结构损伤动力检测与健康监

- 测研究现状与展望[J]. 工程力学, 2011, 28(2): 1-11.
- ZHU Hongping, YU Jing, ZHANG Junbing. A summary review and advantages of vibration-based damage identification methods in structural health monitoring [J]. Engineering Mechanics, 2011, 28(2): 1-11. (in Chinese)
- [2] 张家滨, 唐催, 王磊, 等. 基于频率变化率的结构刚度非均匀退化识别[J]. 振动、测试与诊断, 2018, 38(3): 486-493.
- ZHANG Jiabin, TANG Cui, WANG Lei, et al. Identification of non-uniform stiffness degradation in structure based on the change rate of frequency[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(3): 486-493. (in Chinese)
- [3] 刘景良, 高源, 廖飞宇, 等. 移动荷载作用下时变简支钢桥损伤识别[J]. 振动、测试与诊断, 2020, 40(1): 12-19.
- LIU Jinliang, GAO Yuan, LIAO Feiyu, et al. Damage detection of a time-varying simply supported steel bridge under moving load [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(1): 12-19. (in Chinese)
- [4] 孙增寿, 李晓鹏, 韩培琰, 等. 基于小波包样本熵的连续梁桥损伤识别[J]. 振动、测试与诊断, 2018, 38(5): 916-921.
- SUN Zengshou, LI Xiaopeng, HAN Peiyan, et al. Damage identification for continuous girder bridge based on wavelet packet sample entropy[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(5): 916-921. (in Chinese)
- [5] 马宏伟, 林逸洲, 聂振华. 利用少量传感器信息与人工智能的桥梁结构安全监测新方法[J]. 建筑科学与工程学报, 2018, 35(5): 9-23.
- MA Hongwei, LIN Yizhou, NIE Zhenhua. New methods of structural health monitoring based on small amount of sensor information and artificial intelligence [J]. Journal of Architecture and Civil Engineering, 2018, 35(5): 9-23. (in Chinese)
- [6] KARPATY A, TODERICI G, SHETTY S, et al. Large-scale video classification with convolutional neural networks [C] //Computer Vision & Pattern Recognition. Columbus, OH, USA: IEEE, 2014: 1725-1732.
- [7] OULLETTE R, BROWNE M, HIRASAWA K. Genetic algorithm optimization of a convolutional neural network for autonomous crack detection[C]//Congress on Evolutionary Computation. Portland, OR, USA: IEEE, 2004: 516-521.
- [8] ABDELJABER O, AVCI O, KIRANYAZ M S, et al. 1-D CNNs for structural damage detection: verification on a structural health monitoring benchmark data[J]. Neurocomputing, 2017, 275: 1308-1317.
- [9] LIN Y Z, NIE Z H, MA H W. Structural damage detection with automatic feature-extraction through deep learning [J]. Computer-Aided Civil & Infrastructure Engineering, 2017, 32(12): 1025-1046.
- [10] 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): 167-175.
- LI Xuesong, MA Hongwei, LIN Yizhou. Structural damage identification based on convolution neural network [J]. Journal of Vibration and Shock, 2019, 38(1): 167-175. (in Chinese)
- [11] 李书进, 赵源, 孔凡, 等. 卷积神经网络在结构损伤诊断中的应用[J]. 建筑科学与工程学报, 2020, 37(6): 29-37.
- LI Shujin, ZHAO Yuan, KONG Fan, et al. Application of convolutional neural network in structural damage identification [J]. Journal of Architecture and Civil Engineering, 2020, 37(6): 29-37. (in Chinese)
- [12] 何浩祥, 王玮, 黄磊. 基于卷积神经网络和递归图的桥梁损伤智能识别[J]. 应用基础与工程科学学报, 2020, 28(4): 966-980.
- HE Haoxiang, WANG Wei, HUANG Lei. Intelligent damage detection for bridge based on convolution neural network and recurrence plot[J]. Journal of Basic Science and Engineering, 2020, 28(4): 966-980. (in Chinese)
- [13] WANG Z, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks [C] //Workshops at the 29th Aai Conference on Artificial Intelligence. Austin, TX, USA: Association for the Advance of Artificial Intelligence, 2015: 40-46.
- [14] KRIZHEVSKY A, SUTSKEVER I E, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [15] CAICEDO J M, CATBAS F N, GUL M, et al. Phase 1 of the Benchmark problem for bridge health monitoring: numerical data[C]//Engineering Mechanics Division Conference of the American Society of Civil Engineers. Blacksburg, VA, USA: American Society of Civil Engineers, 2007: 3-6.



第一作者简介: 骆勇鹏, 男, 1989年2月生, 博士、讲师、硕士生导师。主要研究方向为结构健康监测。曾发表《自助法的改进及在结构参数不确定性量化和传递分析中的应用》(《振动工程学报》2020年第33卷第4期)等论文。
E-mail: yongpengluo@fafu.edu.cn