

引文格式:麻胜兰,钟建坤,刘昱昊,等.基于二维卷积神经网络的结构加速度数据异常检测研究[J].建筑科学与工程学报,2025,42(1):112-120.

MA Shenglan, ZHONG Jiankun, LIU Yuhao, et al. Structural acceleration data anomaly detection based on 2D convolutional neural network [J]. Journal of Architecture and Civil Engineering, 2025, 42(1): 112-120.

DOI:10.19815/j.jace.2023.06082

基于二维卷积神经网络的结构加速度数据异常检测研究

麻胜兰¹,钟建坤¹,刘昱昊¹,郑翔²

(1. 福建理工大学 福建省土木工程新技术与信息化重点实验室,福建 福州 350118;

2. 厦门第一建筑工程集团有限公司,福建 厦门 361004)

摘要:为提高结构加速度数据异常检测的效率和准确率,提出基于二维卷积神经网络(2D-CNN)的结构加速度数据异常检测方法。通过二维桁架数值模型验证了所提方法的有效性,并研究了 2D-CNN 卷积层数和加速度噪声水平对数据异常检测效果的影响。结果表明:提出的结构加速度数据异常检测方法能快速准确区分加速度数据异常类型,异常检测的准确率可达 97%以上;对于包含信息复杂、数据规模大的样本,采用 4 层以上的 2D-CNN 有助于提高加速度数据异常检测的准确率,采用 5 层卷积层的 2D-CNN 对数据异常辨识精度可达 98%;当加速度信噪比大于 1 时,数据异常检测准确率均在 90%以上,当加速度信噪比为 10 时,准确率在 97%以上,所提方法具有良好的容噪性和鲁棒性;采用 2D-CNN 的数据异常检测方法可为传感器网络的有效运行提供技术支持。

关键词:结构健康监测;二维卷积神经网络;桁架结构;深度学习;加速度;数据异常检测

中图分类号:TU317

文献标志码:A

文章编号:1673-2049(2025)01-0112-09

Structural acceleration data anomaly detection based on 2D convolutional neural network

MA Shenglan¹, ZHONG Jiankun¹, LIU Yuhao¹, ZHENG Xiang²

(1. Fujian Provincial Key Laboratory of Advanced Technology and Informatization in Civil Engineering,

Fujian University of Technology, Fuzhou 350118, Fujian, China; 2. Xiamen Yijian Group,

Xiamen 361004, Fujian, China)

Abstract: In order to improve the efficiency and accuracy of anomaly detection in structural acceleration data, a structural acceleration data anomaly detection method based on 2D convolutional neural network (2D-CNN) was proposed. The effectiveness of the proposed method was verified through a two-dimensional truss numerical model, and the effects of 2D-CNN convolution layers and acceleration noise levels on data anomaly detection were studied. The results show that the proposed structural acceleration data anomaly detection method can quickly and accurately distinguish the types of acceleration data anomalies, and the accuracy of anomaly detection can reach over 97%. For samples with complex information and large data scales, using

收稿日期:2023-09-21

基金项目:国家自然科学基金项目(51808119)

作者简介:麻胜兰(1986-),女,工学博士,副教授,E-mail:mashenglan@fjut.edu.cn。

2D-CNN with more than 4 layers can help improve the accuracy of acceleration data anomaly detection. Using 2D-CNN with 5 convolutional layers can achieve a data anomaly identification accuracy up to 98%. When the acceleration signal-to-noise ratio is greater than 1, the accuracy of data anomaly detection is above 90%. When the acceleration signal-to-noise ratio is 10, the accuracy is above 97%. The proposed method has good noise tolerance and robustness. The use of 2D-CNN data anomaly detection method can provide technical support for the effective operation of sensor networks.

Key words: structural health monitoring; 2D convolutional neural network; truss structure; deep learning; acceleration; data anomaly detection

Author resume: MA Shenglan(1986-), female, PhD, associate professor, E-mail: mashenglan@fjut.edu.cn.

0 引言

结构健康监测系统通过布设大量传感器获取结构响应数据,从而实现对结构的健康诊断。在结构使用寿命内,传感器故障的发生不可避免,由故障传感器采集到的异常数据容易引起后续分析的误判^[1],因此实时高效地识别出由传感器故障引起的监测数据异常类型,对于传感器网络的有效运行具有重要意义。目前结构响应异常数据检测方法主要分为基于统计学的方法和基于机器学习的方法。

基于统计学的方法主要是先选取某时间段监测数据,然后预先建立数据之间的相关模型,利用信号阈值识别异常数据。Yi 等^[2]利用单变量控制图解决结构健康监测数据中偏移的检测问题,但判断误差会随着监测数据偏移的增大而增加。Rao 等^[3]通过建立监测数据的 Hankel 矩阵并对其进行主成分分析,研究了偏置、漂移、增益和精度退化 4 种类型的传感器故障,取得较好检测效果,但由于计算时间较长难以应用于大型健康监测系统。本课题组利用最小均方差估计与广义极似然比检测结构响应异常,结合统计质量控制图判断结构响应异常来源^[4]。Li 等^[5]提出一种基于模型残差的传感器故障检测方法,该方法通过误差函数直接隔离故障传感器。然而基于统计学的方法往往由于计算工作量大,在实际应用中难以实现。

基于机器学习的方法则通过数据驱动提取结构响应异常特征,从而实现结构响应异常检测,该方法具有无需建立相应机理模型的特点。范时泉等^[6]通过组合利用不同支持向量机的优势减少异常数据的漏报和误报。游颖等^[7]结合 BP 神经网络模型和粒子群优化算法,并将结合后的算法应用于结构异常数据监测中,实现了缺失数据重构。然而,传统的机

器学习方法数据前处理过程复杂,网络收敛速度慢且易出现过拟合的现象,还存在容噪性低等问题。

近年来由于深度学习具备实时处理海量数据和自动提取特征的能力,逐渐被应用于数据异常检测领域^[8-9]。二维卷积神经网络(2D-CNN)是具有代表性的深度学习框架之一,但 2D-CNN 参数对检测精度、抗噪性及计算效率的影响仍需进一步研究。本文在已有结构加速度响应异常模型研究基础上提出了基于 2D-CNN 的结构加速度数据异常检测方法,实现异常数据快速自动分类。将加速度数据转换成图像作为 2D-CNN 的输入值,并对 2D-CNN 进行训练和优化,从而建立适用于加速度数据异常检测的 2D-CNN。通过二维数值桁架模型验证方法的有效性和识别准确率,并讨论了 2D-CNN 的网络参数和加速度噪声水平对识别精度的影响。

1 基于二维卷积神经网络的结构加速度数据异常检测理论与方法

由于传感器故障的随机性和不确定性,如何从原始数据中找到区分异常的关键特征并准确识别异常样本,是数据异常检测的关键问题。在实际工程中采集到的加速度数据往往包含非平稳的噪声信号,而 2D-CNN 具有较好的容噪性和鲁棒性。相较于传统机器学习方法,2D-CNN 由于局部连接和权重共享的特点减少了大量网络训练参数,网络的特征提取能力和泛化性能得到增强^[10]。为此,本文利用 2D-CNN 自动提取图像特征的功能,提出基于 2D-CNN 的结构加速度数据异常检测方法,包括 3 个步骤:首先对原始数据进行预处理从而建立数据样本库,接着通过初步设计和反复训练提出适用于结构加速度数据异常检测的 2D-CNN 模型,最后根据该模型进行结构加速度数据异常检测。

1.1 结构加速度数据预处理

检测结构加速度数据异常的 2D-CNN 模型需要一定规模的深度学习数据集,本文将节点的加速度响应作为输入数据,为拓展样本库,将其按一定时间间隔划分成多个数据片段。同时为了保证图像的清晰度和考虑数据存储需求,本文将上述数据片段图像分辨率统一压缩为 100×100 。

为了消除颜色的关联性对数据异常检测精度的影响,本文对压缩后的图像进行灰度处理,即将分辨率为 100×100 的压缩后图像采用加权平均法进行图像灰度化处理,其表达式^[11]为

$$G'(i,j)=0.3R(i,j)+0.59G(i,j)+0.11B(i,j) \quad (1)$$

式中: $G'(i,j)$ 为图像第 i 行第 j 列像素的灰度级; $R(i,j)$ 、 $G(i,j)$ 、 $B(i,j)$ 分别为压缩成分辨率 100×100 的图像时红、绿、蓝色的亮度。

将结构加速度异常数据经片段划分、图像压缩、灰度处理后进行分类标记,本文参考 Yi 等^[12]的研究,将结构加速度数据分为正常、偏移、漂移、精度退化、增益、缺失、常数+噪声 7 种类型。最后将标记好的灰度图像作为 2D-CNN 的训练集和验证集,同时按一定比例随机抽取未标记过的灰度图像,作为 2D-CNN 模型的测试集。数据预处理流程如图 1 所示。




图 1 数据预处理流程

Fig. 1 Flow chart of data preprocessing

1.2 二维卷积神经网络基本结构

2D-CNN 的基本结构包括输入层、隐藏层和输出层,其中隐藏层包括卷积层、池化层和全连接层,层间采用堆叠结构形式,如图 2 所示。




图 2 典型卷积神经网络架构

Fig. 2 Typical structure of convolutional neural network

1.2.1 输入层

输入层即 2D-CNN 的数据导入层,本文输入数据为预处理后分辨率 100×100 的灰度图像。

1.2.2 卷积层

卷积层可以对输入图像进行特征提取,其内部有多个卷积核。卷积计算时,大小为 $m \times n$ 卷积核按规定步长 l 滑动,对当前输入部分的元素进行矩阵点乘求和并叠加偏置项,得到结果为单个输出像素值 x 。由于卷积运算是一个线性过程,为了解决线性模型表达能力不足的问题,还需要将卷积运算得到的特征矩阵 S 通过非线性函数激活,将特征矩阵 S 中各元素经过激活计算添加非线性特征得到矩阵 A 。整个卷积计算和激活过程可用式(2)^[13]表示。

$$A_I = K(\sum_{j=1}^n \sum_{i=1}^n x_{(i-m)/(l+1), (j-n)/(l+1)} k_{mm} + b) \quad (2)$$

式中: A_I 为第 I 层卷积层输出值; K 为激活函数; $x_{(i-m)/(l+1), (j-n)/(l+1)}$ 为 $I-1$ 层卷积计算后的输出值,其输入为 $i \times j$ 矩阵; b 为偏置矩阵; k_{mm} 为尺寸 $m \times n$ 卷积核。

常用的激活函数有 ReLU、Sigmoid、TanH 等。使用 ReLU 函数激活不会出现“梯度消失”的问题^[14],同时为了提升 2D-CNN 的计算效率,本文的卷积层激活函数采用 ReLU 函数,其表达式为

$$K(x) = \max(0, x) \quad (3)$$

式中: x 为特征矩阵 S 中各元素值。

1.2.3 池化层

池化计算是一种聚合操作,池化层可以减少特征图尺寸,降低特征维数。池化方法由不同的池化函数决定,最大值池化有利于提取结构加速度图像的局部特征,因此本文采用最大值池化函数,其表达式为

$$B = \max\{a_{11}, a_{12}, \dots, a_{ij}\} \quad (4)$$

式中: B 为池化层输出矩阵; a_{ij} 为卷积层输出矩阵 A_I 中的元素值。

1.2.4 全连接层和输出层

全连接层通常作为最后几层设置在 2D-CNN 中,起到将卷积层和池化层提取到的特征信息映射到样本标记空间的作用。全连接层过程表达式^[15]如式(5)所示,其中激活函数 K 采用式(3)所示的 ReLU 函数。

$$C_I = K(\omega_{ij} x_{I-1} + b_i) \quad (5)$$

式中: C_I 为全连接层输出值; x_{I-1} 为第 $I-1$ 层的输出值; ω_{ij} 与 b_i 分别为第 I 层的权重参数与偏置参数。

输出层为 2D-CNN 的最后一层,为了预测输入图像所属数据异常类别的概率,本文采用 Softmax

回归来处理多分类问题,计算结果即为输入图像所属结构加速度数据异常类别的概率,其中各元素计算表达式为

$$P = \frac{\exp(x_i)}{\sum_{i=1}^q \exp(x_i)} \quad (6)$$

式中: P 为输出结果; x_i 为输出层变量; q 为输出个数。

1.2.5 损失函数

损失函数用于表征预测值与实际值的不一致程度。常用的损失函数有交叉熵损失函数、均方误差损失函数、Hinge 损失函数等,对于数据异常检测,隶属分类问题,常采用交叉熵损失函数,该函数能较好地描述样本真实概率分布与预测概率分布的差异,其表达式为

$$D = -\frac{1}{N} \sum_X [y \ln(P) + (1 - y) \ln(1 - P)] \quad (7)$$

式中: D 为损失值; X 为样本; y 为样本真实值; N 为样本总数。

1.3 二维卷积神经网络的训练与优化

首先将采集到的加速度数据按第 1.1 节方法进行预处理,接着输入到第 1.2 节所述的网络中进行训练。2D-CNN 的训练采用反向传播算法调整参数以提高网络的性能。

训练过程中需要根据验证集的准确率和损失值不断调整优化 2D-CNN 的网络层参数和超参数,当验证集的识别准确率稳定在 90% 以上或损失函数值收敛稳定在 1×10^{-3} 以下时完成训练,得到用于结构加速度数据异常检测的最优模型。

最终,将待识别的测试集数据输入训练好的网络模型中即可得到数据异常检测结果。图 3 为基于 2D-CNN 的结构加速度数据异常检测流程图。

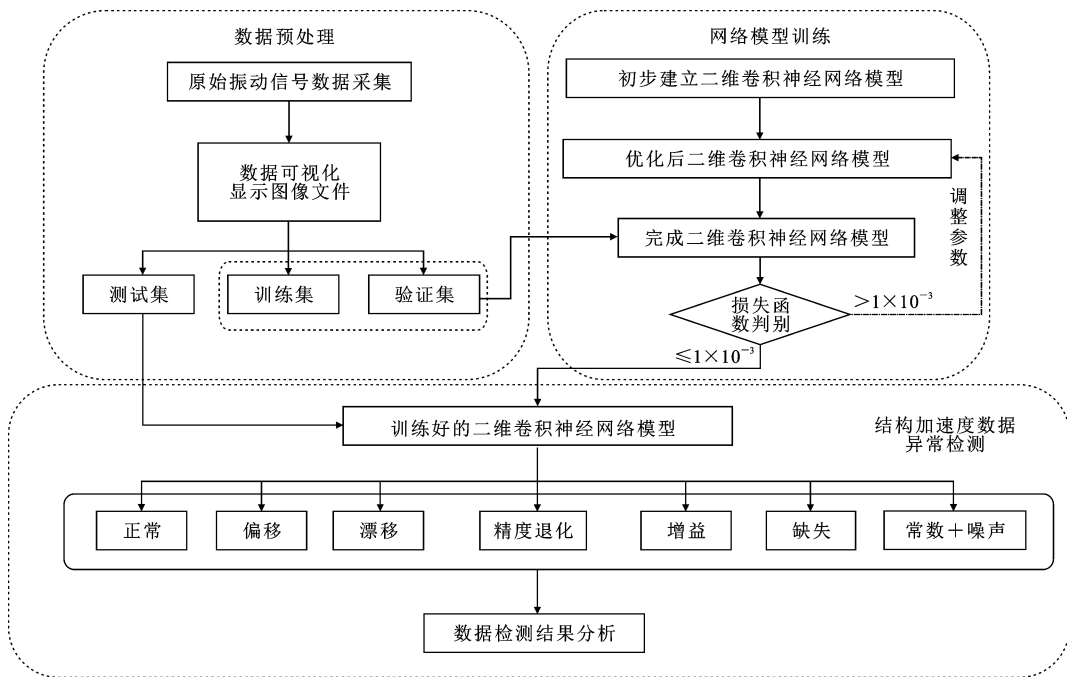


图 3 基于 2D-CNN 的结构加速度数据异常检测流程图

Fig. 3 Flow chart of structural acceleration data anomaly detection based on 2D-CNN

2 二维桁架数值模型验证

2.1 桁架模型概况

以一桁架结构数值模型为例验证方法的有效性,具体尺寸如图 4 所示。该桁架由 10 个节点和 21 根杆件构成,跨度 4 m,高 1 m,桁架结构模型参数为:各杆件的截面面积 $A=1 \times 10^{-4} \text{ m}^2$,弹性模量 $E=2.1 \times 10^5 \text{ MPa}$,材料密度 $\rho=7\,300 \text{ kg} \cdot \text{m}^{-3}$ 。节点 4 竖直方向上作用有白噪声随机激励力,激励




图 4 桁架有限元模型

Fig. 4 Finite element model of truss

的功率谱密度为 $0.1\text{ (m}\cdot\text{s}^{-2})^2\cdot\text{Hz}$, 激振频率带宽 $5\sim1\,000\text{ Hz}$ 。采用 Newmark 积分法^[16] 计算结构的加速度响应, 其中参数 $\gamma=0.5, \beta=0.25$, 以 6 号节点竖直方向上的加速度响应为例, 采样时长为 $2\,000\text{ s}$, 采样频率为 $1\,000\text{ Hz}$ 。

2.2 结构响应异常数据准备

由于本文采集到的结构加速度响应与文献[17]中的加速度响应数据特征较为相似, 因此考虑采用文献中所归纳的结构加速度异常数据模型, 对 6 种常见的结构加速度异常数据进行构造。其中, 每个数据被分别标记为正常数据或者 6 种异常数据之一, 每种数据类型的构造方法如表 1 所示。

表 1 结构加速度异常数据模型

数据异常类型	公式
正常	$y_i = y_i^a + w(t)$
偏移	$y_i = A + y_i^a + w(t)$
漂移	$y_i = A + Ct + y_i^a + w(t)$
精度退化	$y_i = y_i^a + \eta + w(t)$
增益	$y_i = E[y_i^a + w(t)]$
缺失	$y_i = A$
常数+噪声	$y_i = A + w(t)$

注: A, C, E 为随机数; η 为 $[0, 1]$ 之间的随机数; $w(t)$ 为含一定高斯噪声比例的时间序列。

本文通过在原始信号中添加高斯白噪声来模拟环境噪声[式(8)], 根据信噪比 R_{SNR} [式(9)] 评价所添加噪声的强度。

$$y_i^a = y_i(1 + \epsilon R)$$

(8)

$$R_{\text{SNR}} = 10\lg\left[\frac{f_{\text{RMS}}(y_i)}{f_{\text{RMS}}(y_i^a - y_i)}\right]$$

(9)

式中: y_i, y_i^a 分别为原始加速度数据和噪声污染后的

加速度数据; R 为均值为 0、偏差为 1 的正态分布随机数; ϵ 为噪声水平; f_{RMS} 为均方根。

采样时长 $2\,000\text{ s}$ 的数据可平均划分为 $2\,000$ 个片段, 7 种数据类型共得到 $14\,000$ 张分辨率为 100×100 的灰度图像样本。从中分别随机选择 $60\%、20\%、20\%$ 的样本构成训练集、验证集和测试集, 数据集划分后的数量和占比情况如表 2 所示。

表 2 训练集、验证集和测试集的数量

Table 2 Number of training sets, validation sets and test sets

样本	训练集	验证集	测试集
数量/个	8 400	2 800	2 800
比例/%	60	20	20

表 3 为不同类型的加速度数据灰度图像, 其中典型图像 1~5 为随机选取。本文对表 3 所示的灰度图像采用标签进行分类, 以便提升 2D-CNN 的检测效果, 即对训练集和验证集的图像按不同类型分别标记为 1~7 的数字标签, 并将标记好的训练集和验证集输入到 2D-CNN 模型中训练。

2.3 二维卷积神经网络模型训练与优化

本次模型训练所用试验平台配置如下: 试验系统为 Window10; 硬件配置为 CPU 为 Intel Core i5-1050、系统内存 16G; 试验框架为 MATLAB2020 版 Deep Learning Toolbox。

首先初步建立一个含有 4 个卷积层、4 个池化层和 1 个全连接层的 2D-CNN 模型, 具体模型架构如图 5 所示。其中输入层的输入大小为分辨率 100×100 的 1 通道灰度图像。第 1 个卷积层使用 8 个 3×3 的卷积核, 按步长为 3 个像素对输入层进行卷积运算, 对卷积结果使用 ReLU 激活函数。然后对激

表 3 加速度数据异常典型图像特征

Table 3 Typical image features of acceleration anomaly data

数据异常类型	数字标签	典型图像 1	典型图像 2	典型图像 3	典型图像 4	典型图像 5
正常	1					
偏移	2					
漂移	3					
精度退化	4					
增益	5					
缺失	6					
常数+噪声	7					




图 5 2D-CNN 架构图

Fig. 5 Construction diagram of 2D-CNN

活结果使用窗口为 2×2 、步长为 2 个像素的最大池化操作。第 2、3、4 个卷积层分别使用 16、32、64 个 3×3 的卷积核,其他参数和步骤与第 1 个卷积层相同。此外,每两个卷积层之间设置一层大小为 2×2 的最大池化层。

输出向量经过全连接层对上一层的池化结果进行全连接处理,接着对全连接处理结果使用 Softmax 回归分类器,得到分类结果。最后一层是含 7 类的最大输出层,用来产生一个含有 7 类结构加速度数据异常的标签分布。

训练过程中除了调整网络层参数之外,还需要不断优化 2D-CNN 超参数。经过大量试算,本文将学习速率设置为 0.001,迭代训练次数 Max_Epoch 等于 290,验证频率 ValidationFrequency 等于 10,即训练过程中每隔 10 次循环就将验证集输入网络,对比验证网络预测的准确率。

将经过分类标记好的训练集输入 2D-CNN 中训练,经过一系列的特征自动提取整合操作,最终生成含 16 135 个参数的权值矩阵。网络中各层输出尺寸和参数量情况如表 4 所示。

表 4 2D-CNN 参数

Table 4 Parameters of 2D-CNN

结构层次	输出尺寸	参数量
输入层	$100 \times 100 \times 1$	
卷积层 1	$100 \times 100 \times 8$	80
最大池化层 1	$50 \times 50 \times 8$	
卷积层 2	$50 \times 50 \times 16$	1 168
最大池化层 2	$25 \times 25 \times 16$	
卷积层 3	$25 \times 25 \times 32$	4 640
最大池化层 3	$12 \times 12 \times 32$	
卷积层 4	$6 \times 6 \times 32$	18 496
最大池化层 4	$6 \times 6 \times 64$	
展开层	$6 \times 6 \times 64$	
全连接层	$1 \times 1 \times 7$	16 135
输出层	7	

以 $R_{\text{SNR}}=10$ 为例,2D-CNN 的迭代训练过程如图 6 所示。由图 6 可知:经过 290 次迭代训练,验证




图 6 $R_{\text{SNR}}=10$ 的 2D-CNN 模型训练过程

Fig. 6 Training process of 2D-CNN with $R_{\text{SNR}}=10$

集的准确率和损失值经过一定波动后基本趋于稳定,2D-CNN 的收敛速度较快,训练迭代至 100 次时损失值已接近 0,随后损失曲线始终维持在 0.1 以下;准确率曲线从第 100 次迭代开始维持在 97%并逐渐上升,表明 2D-CNN 能快速稳定地学习到结构加速度数据中的异常特征,并将不同加速度数据异常类型识别出来。其中,针对 8 400 张训练集样本,由 Deep Learning Toolbox 记录训练 290 次得到最优模型所需时间为 490 s,当训练至 100 次左右时模型基本收敛,训练时间约为 130 s。

2.4 结构加速度数据异常检测结果分析

在训练并优化得到可快速准确检测结构加速度数据异常的 2D-CNN 模型后,将未标记过的待测试数据输入到模型中,发现当 $R_{\text{SNR}}=10$ 时的测试集与验证集结构加速度数据异常检测准确率基本相同,测试集的输出结果统计如表 5 所示。由表 5 可知,对于正常、漂移、精度退化、增益和缺失的数据预测准确率保持较高的水准,准确率都超过了 99%,甚至有些数据类型的预测精度可以达到 100%。对于标签值为偏移和常数+噪声的数据而言,精度有所下降,但都在 97%以上。

表 5 2D-CNN 模型输出结果统计

Table 5 Statistics of 2D-CNN model output results

数据类型	正常	偏移	漂移	精度退化
准确率/%	100	97	100	100
数据类型	增益	缺失	常数+噪声	
准确率/%	99.3	99.5	97.5	

总体来看,本文提出的模型对于样本数据预测的准确率达到 97% 以上,充分说明所提方法能够有效检测结构加速度数据异常。对于常数+噪声与偏移这两类数据预测准确率有所下降,这可能是因为这两种类型数据在图像特征上相似,尤其是常数加上较高信噪比的噪声后,与偏移阈值相似,所以 2D-CNN 对这两类的视觉特征较不敏感。图 7 所示为各个异常数据类型的混淆矩阵,可以看到异常数据的具体分布,其中主要是偏移和常数加噪声被相互错误预测,进一步佐证了上述分析。

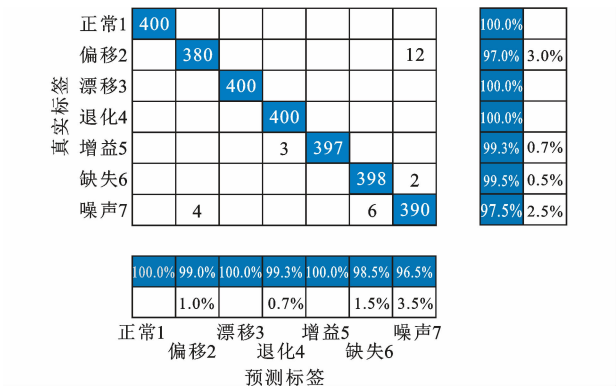


图 7 $R_{\text{SNR}}=10$ 数据检测结果混淆矩阵

Fig. 7 Confusion matrix for data detection result with $R_{\text{SNR}}=10$

3 卷积层数与信噪比因素的影响

3.1 不同卷积层数的影响

为了对比不同卷积层数对结构加速度数据异常检测结果的影响,设计了卷积层数为 1~5 的对比试验,其他网络参数同第 2.3 节。将 R_{SNR} 均为 10 的训练集数据输入到相应模型中训练,迭代训练过程中准确率和损失值的变化情况如图 8 所示。

由图 8(a)可知,验证集的准确率随着迭代次数的增加逐步上升,在迭代 100 次后逐渐趋于平稳,准确率稳定在 95% 以上。由图 8(b)可知,损失值随着迭代次数的增加逐步下降,在迭代 100 次后逐渐趋于平稳,数值维持在 0.1 以下。说明即使是浅层 2D-CNN 模型在迭代过程中也表现出较好的性能和稳定性,基本达到拟合状态。

表 6 为不同卷积层数下 2D-CNN 迭代训练 290 次的时长。可以发现,随着网络深度的增加,训练时长的增长速度逐渐变缓,总体都在 540 s 以内。

表 7 为不同卷积层数下的 2D-CNN 模型在测试集上的识别精度。可以发现对于相同信噪比的训练数据而言,2D-CNN 模型随着卷积层数的增加识

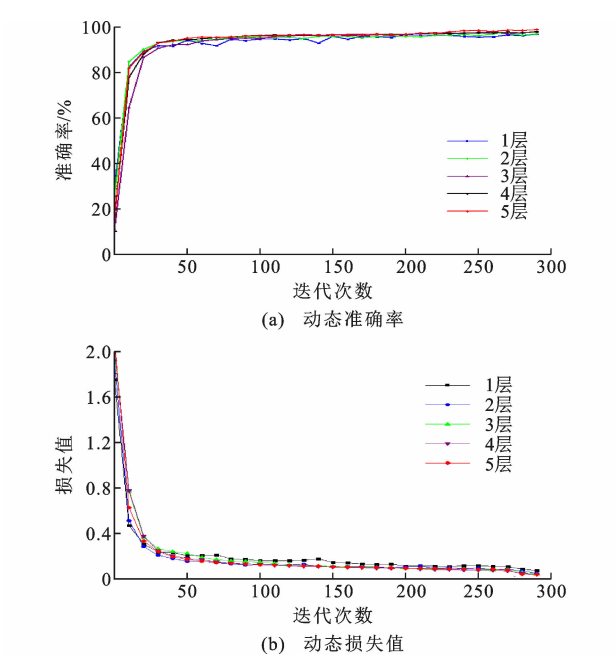


图 8 不同卷积层数 2D-CNN 训练过程

Fig. 8 Training process of 2D-CNN with different convolution layers

表 6 不同卷积层数下 2D-CNN 的训练时长

Table 6 Training time of 2D-CNN with different convolution layers

卷积层数	1	2	3	4	5
训练时长/s	256	408	486	490	537

表 7 不同卷积层数下的识别准确率

Table 7 Recognition accuracy with different convolution layers

测试集	识别准确率				
	1 层	2 层	3 层	4 层	5 层
无噪声	0.968	0.975	0.981	0.984	0.985
$R_{\text{SNR}}=15$	0.964	0.976	0.984	0.989	0.989
$R_{\text{SNR}}=10$	0.963	0.981	0.983	0.990	0.986
$R_{\text{SNR}}=5$	0.963	0.976	0.983	0.988	0.985
$R_{\text{SNR}}=1$	0.971	0.965	0.969	0.973	0.983

别精度逐渐提升。识别精度最高的工况是具有 5 层卷积层的 2D-CNN,对不同信噪比的测试集识别精度均在 98% 以上。结果进一步验证了随着卷积层数的增加,模型的识别准确率会逐步上升,但训练时长也会有所增加。总体而言,对于包含信息复杂、数据规模大的样本,选择 4 层以上的 2D-CNN 有助于提高结构加速度数据异常检测准确率。

3.2 不同信噪比的影响

实际工程检测中传感器采集到的结构响应信噪比在 5~17 db 之间^[18]。为了对比不同信噪比对结构加速度数据异常检测结果的影响,设计了信噪比

为无噪声、 $R_{\text{SNR}}=15$ 、 $R_{\text{SNR}}=10$ 、 $R_{\text{SNR}}=5$ 、 $R_{\text{SNR}}=1$ 的对比试验,其他网络参数取值同第 2.3 节。将不同信噪比下的训练集数据输入到相应模型中训练,迭代训练过程中准确率和损失值的变化情况如图 9 所示。

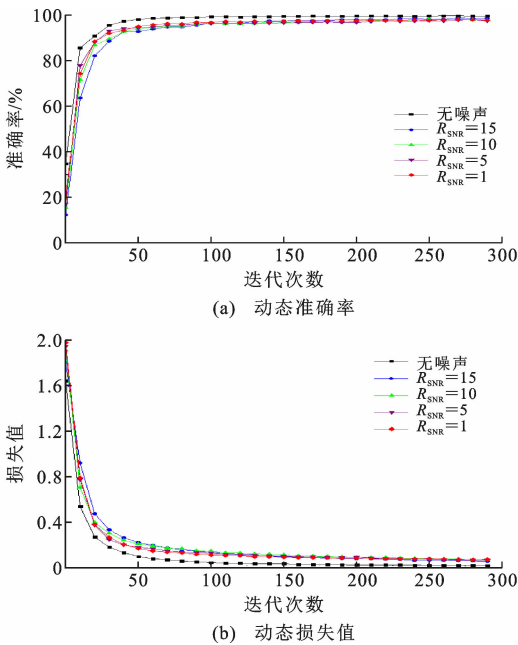


图 9 不同 R_{SNR} 的 2D-CNN 训练过程

Fig. 9 Training process of 2D-CNN with different R_{SNR}

由图 9(a)可知,验证集的准确率随着迭代次数的增加逐步上升,在迭代 100 次后逐渐趋于平稳,准确率稳定在 95% 以上。由图 9(b)可知,损失值随着迭代次数的增加逐步下降,在迭代 100 次后逐渐趋于平稳,数值维持在 0.1 以下。说明对于 $R_{\text{SNR}}=1$ 的结构响应数据,即使噪声水平较高,模型在训练迭代过程中仍表现出较好的性能和稳定性,基本达到拟合状态。

表 8 为不同信噪比下 2D-CNN 的训练时长。由表 8 可知,不同信噪比下的模型训练时长随着信噪比的减小而逐渐增加,但总体都在 520 s 以内。

表 8 不同 R_{SNR} 的 2D-CNN 训练时长

Table 8 Training time of 2D-CNN with different R_{SNR}					
信噪比	无噪声	15	10	5	1
训练时长/s	480	482	486	490	518

表 9 为不同信噪比下的 2D-CNN 模型在测试集上的识别准确率。可以发现对于相同信噪比的训练数据而言,输入 2D-CNN 的测试集信噪比与训练集越接近,识别精度越高。说明模型具有较高的识别准确率,以及对噪声引起的数据扰动有一定的鲁棒性。当 $R_{\text{SNR}} > 1$ 时,数据异常检测准确率均在

表 9 不同 R_{SNR} 的识别准确率

Table 9 Recognition accuracy with different R_{SNR}

训练集	测试集	准确率	训练集	测试集	准确率
无噪声	无噪声	0.996	$R_{\text{SNR}}=15$	无噪声	0.986
	$R_{\text{SNR}}=15$	0.977		$R_{\text{SNR}}=15$	0.987
	$R_{\text{SNR}}=10$	0.974		$R_{\text{SNR}}=10$	0.974
	$R_{\text{SNR}}=5$	0.971		$R_{\text{SNR}}=5$	0.963
	$R_{\text{SNR}}=1$	0.955		$R_{\text{SNR}}=1$	0.955
$R_{\text{SNR}}=10$	无噪声	0.984	$R_{\text{SNR}}=5$	无噪声	0.968
	$R_{\text{SNR}}=15$	0.989		$R_{\text{SNR}}=15$	0.966
	$R_{\text{SNR}}=10$	0.990		$R_{\text{SNR}}=10$	0.970
	$R_{\text{SNR}}=5$	0.988		$R_{\text{SNR}}=5$	0.979
	$R_{\text{SNR}}=1$	0.973		$R_{\text{SNR}}=1$	0.976
$R_{\text{SNR}}=1$	无噪声	0.917			
	$R_{\text{SNR}}=15$	0.915			
	$R_{\text{SNR}}=10$	0.928			
	$R_{\text{SNR}}=5$	0.956			
	$R_{\text{SNR}}=1$	0.963			

90% 以上。识别精度最高的工况是 $R_{\text{SNR}}=10$ 的数据训练的 2D-CNN,精度均在 97% 以上。总体而言,本文提出的 2D-CNN 具有较好的容噪性。

4 结 语

(1)本文建立的 2D-CNN 模型训练时间短,硬件适配要求较低。当加速度数据 $R_{\text{SNR}}=10$ 、2D-CNN 采用 4 层卷积层时,异常检测的准确率可达 97% 以上。

(2)当加速度数据 $R_{\text{SNR}}=10$ 时,随着 2D-CNN 卷积层数增加,模型识别精度逐渐提升,具有 5 层卷积层的结构加速度数据异常辨别精度在 98% 以上。对于包含信息复杂、数据规模大的样本,选择 4 层以上的 2D-CNN 有助于提高结构加速度数据异常检测准确率。

(3)当 2D-CNN 卷积层数为 4 层,加速度数据 $R_{\text{SNR}} > 1$ 时,数据异常检测准确率均在 90% 以上,表明所提方法具有良好的容噪性和鲁棒性。

(4)考虑到实验室中无法采集到所有类型的异常结构加速度数据,因此本文通过桁架数值模型验证所提方法的可行性和有效性,但仍需要更多的工程实践来进一步检验。

参考文献:

References:

[1] 鞠翰文,邓 扬,李爱群. 基于 GRU 神经网络的结构异常监测数据修复方法[J]. 振动与冲击, 2023, 42(9):328-338.

- JU Hanwen, DENG Yang, LI Aiqun. Restoring method of structural abnormal monitoring data based on GRU neural network[J]. Journal of Vibration and Shock, 2023, 42(9): 328-338.
- [2] YI T H, LI H N, SONG G B, et al. Detection of shifts in GPS measurements for a long-span bridge using CUSUM chart [J]. International Journal of Structural Stability and Dynamics, 2016, 16(4): 1640024.
- [3] RAO A R M, KASIREDDY V, GOPALAKRISHNAN N, et al. Sensor fault detection in structural health monitoring using null subspace-based approach [J]. Journal of Intelligent Material Systems and Structures, 2015, 26(2): 172-185.
- [4] MA S L, JIANG S F, LI J. Structural damage detection considering sensor performance degradation and measurement noise effect[J]. Measurement, 2019, 131: 431-442.
- [5] LI Z L, KOH B H, NAGARAJIAH S. Detecting sensor failure via decoupled error function and inverse input-output model[J]. Journal of Engineering Mechanics, 2007, 133(11): 1222-1228.
- [6] 范时泉, 张金辉, 张其林. 结构健康监测系统的异常识别[J]. 计算机辅助工程, 2016, 25(5): 60-65.
- FAN Shixiao, ZHANG Jinhui, ZHANG Qilin. Abnormal data recognition in structural health monitoring system[J]. Computer Aided Engineering, 2016, 25(5): 60-65.
- [7] 游颖, 王建, 刘学刚, 等. 改进 BP 神经网络的钢结构应力缺失数据重构[J]. 建筑科学与工程学报, 2022, 39(4): 166-173.
- YOU Ying, WANG Jian, LIU Xuegang, et al. Reconstruction of missing stress data for steel structure based on improved BP neural network[J]. Journal of Architecture and Civil Engineering, 2022, 39(4): 166-173.
- [8] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [9] BAO Y Q, TANG Z Y, LI H, et al. Computer vision and deep learning-based data anomaly detection method for structural health monitoring[J]. Structural Health Monitoring, 2019, 18(2): 401-421.
- [10] 潘成龙, 应雨龙. 基于二维卷积神经网络的滚动轴承变工况故障诊断方法[J]. 上海电力大学学报, 2022, 38(1): 29-34.
- PAN Chenglong, YING Yulong. A fault diagnosis method for rolling bearings under variable condition based on two-dimensional convolutional neural network[J]. Journal of Shanghai University of Electric Power, 2022, 38(1): 29-34.
- [11] 顾梅花, 苏彬彬, 王苗苗, 等. 彩色图像灰度化算法综述[J]. 计算机应用研究, 2019, 36(5): 1286-1292.
- GU Meihua, SU Binbin, WANG Miaomiao, et al. Survey on decolorization methods [J]. Application Research of Computers, 2019, 36(5): 1286-1292.
- [12] YI T H, HUANG H B, LI H N. Development of sensor validation methodologies for structural health monitoring: a comprehensive review [J]. Measurement, 2017, 109: 200-214.
- [13] 梁振隆. 基于递归图和卷积神经网络的结构损伤识别研究[D]. 合肥: 合肥工业大学, 2020.
- LIANG Zhenlong. Structural damage identification based on recurrence plot and convolutional neural network[D]. Hefei: Hefei University of Technology, 2020.
- [14] CHOPRA S, HADSELL R, LECUN Y. Learning a similarity metric discriminatively, with application to face verification [C]//IEEE. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego: IEEE, 2005: 539-546.
- [15] 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.
- [16] 麻胜兰, 翁柳青, 姜绍飞. 传感器性能退化与结构损伤响应异常区分研究[J]. 西南交通大学学报, 2013, 48(6): 1024-1030.
- MA Shenglan, WENG Liuqing, JIANG Shaofei. Distinguishing between sensor deterioration and structural damage[J]. Journal of Southwest Jiaotong University, 2013, 48(6): 1024-1030.
- [17] KULLAA J. Detection, identification, and quantification of sensor fault in a sensor network[J]. Mechanical Systems and Signal Processing, 2013, 40(1): 208-221.
- [18] HUANG H B, YI T H, LI H N. Bayesian combination of weighted principal-component analysis for diagnosing sensor faults in structural monitoring systems[J]. Journal of Engineering Mechanics, 2017, 143(9): 04017088.