

DOI:10.3969/j.issn.1003-5060.2026.04.014

基于深度学习的桥梁健康监测数据异常诊断

张鸣祥^{1,2}, 钟其仁¹

(1. 合肥工业大学土木与水利工程学院, 安徽 合肥 230009; 2. 土木工程防灾减灾安徽省工程技术研究中心, 安徽 合肥 230009)

摘要:文章针对桥梁健康监测系统中存在部分监测数据异常问题, 将时频分析和深度学习相结合, 用于监测数据的异常诊断。首先根据异常类型对数据进行划分和标记, 利用时频分析法将一维桥梁加速度数据转换为时频图像, 制备用于构建和训练深度神经网络模型的图像数据库; 然后利用深度学习框架搭建基于卷积神经网络的数据异常诊断模型, 标记过的数据图像组成的训练集和验证集将被随机选择并输入至模型中, 通过反向传播机制和 Adam 优化算法更新和优化模型权重参数, 使用批标准化、数据增强等方法提高模型准确率和泛化能力; 最后对模型诊断结果进行统计并绘制出监测数据异常分布图。结果表明, 文章提出的模型对监测数据异常诊断准确率为 96.69%, 实现了桥梁监测数据异常快速定位, 与传统深度学习模型相比具有更好的稳定性和识别性能。该研究成果可用于桥梁健康监测系统的设计之中。

关键词:数据异常; 时频分析; 深度学习; 桥梁健康监测

中图分类号:U446.3 **文献标志码:**A **文章编号:**1003-5060(2026)04-0530-08

Anomaly diagnosis of bridge health monitoring data based on deep learning

ZHANG Mingxiang^{1,2}, ZHONG Qiren¹

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Civil Engineering Research Center for Disaster Prevention and Mitigation, Hefei 230009, China)

Abstract: Aiming at the problem of some abnormal monitoring data in the bridge health monitoring system, this paper combines time-frequency analysis and deep learning for anomaly diagnosis of monitoring data. Firstly, the data are divided and labelled according to the anomaly type, and the time-frequency analysis method is used to convert the one-dimensional bridge acceleration data into time-frequency images, and an image database is prepared for building and training deep neural network models. Then, the deep learning framework is used to build a data anomaly diagnosis model based on convolutional neural network(CNN), the training set and validation set composed of labelled data images are randomly selected and input into the model, the model weight parameters are updated and optimized through the backpropagation mechanism and Adam optimization algorithm, and batch normalization and data enhancement methods are used to improve the accuracy and generalization ability of the model. Finally, the model diagnosis results are statistically analyzed and the anomaly distribution map of the monitoring data is drawn. The results show that the proposed model has an accuracy rate of 96.69% for anomaly diagnosis of monitoring data, which realizes the rapid localization of abnormal monitoring data, and has better stability and recognition performance than the traditional deep learning model. The results of this paper can be used in the design of bridge health monitoring systems.

Key words: data anomaly; time-frequency analysis; deep learning; bridge health monitoring

0 引言

桥梁作为道路系统的关键组成部分, 对建设

完善的现代化路网系统、促进社会发展具有重要作用。为及时了解桥梁结构状态, 结构健康监测系统^[1-2]被广泛运用到各种桥梁的运营维护中, 由

收稿日期: 2023-10-16; 修回日期: 2023-11-21

基金项目: 国家自然科学基金资助项目(51878234)

作者简介: 张鸣祥(1980—), 男, 江苏镇江人, 博士, 合肥工业大学副教授, 硕士生导师, 通信作者, E-mail: zmx.zhang@163.com.

此也产生了大量监测数据。然而,由于工作环境恶劣、传感器故障、数据传输故障等原因,这些数据不可避免地存在各种类型的异常情况,严重影响数据分析结果,造成经济损失,增加事故发生概率。由于监测数据量巨大,而人工效率有限,开发出能够自动识别异常数据的技术对于结构健康监测系统数据的准确性和可靠性至关重要。

文献[3]基于特征的方法对桥梁健康监测数据进行研究,通过核主成分分析和超球面一类支持向量机方法将正常数据与异常数据进行分离;文献[4]建立传感器故障预测模型,利用广义似然比检验传感器的均值和方差是否改变实现传感器故障自诊断。基于物理模型构建和数据统计特性进行异常诊断是一种常用的方法,但对于复杂结构,这种方法的不确定性随之增加。

近年来,人们将更多目光投向人工智能和深度学习领域,神经网络算法在计算机视觉^[5]和语音识别等诸多领域得到大量运用。此外,深度学习还大量应用于医疗健康分析、自动驾驶、工程材料检测、故障诊断等领域。文献[6]采用深度迁移学习的故障诊断方法,重构代价函数,利用测试数据及其他航天器运行数据对残差网络进行预训练和参数重调,实现航天器故障的快速诊断;文献[7]基于计算机视觉和深度学习,研究健康监测数据异常的检测方法,将时间序列数据转换为灰度图像用于训练深度神经网络,利用实测数据验证该方法的可行性和准确性;文献[8]基于斜拉桥结构特性,通过灰色关联度分析给定数据标签并验证标签正确性,结合多种异常检测算法对桥梁监测数据进行有效性分析;文献[9]将时间序列数据分别在频域和时域可视化并将其叠加成时域-频域双通道图像,用于构建和训练双通道输入的卷积神经网络(convolutional neural network, CNN),识别出异常监测数据。虽然深度学习在各领域故障诊断中的相关研究较丰富,但针对桥梁健康监测数据维度高、随机性大等特点,充分提取数据时域和频域联合特征的相关研究较少。

本文采用时频分析^[10]的方法将桥梁加速度


数据转变为时频图像,划分出数据异常类型,利用深度学习框架构建桥梁监测数据异常诊断模型,采用数据增强、批标准化等方式使模型过拟合风险降低,提升模型诊断准确率和泛化能力。将所提出的算法模型应用于某桥梁的监测数据异常诊断中,验证该模型的性能。最后对模型诊断结果进行统计分析,绘制异常数据时空分布统计图,实现异常数据在时间和传感器层面的双重定位。

1 数据集的制备

本文桥梁健康监测数据来源于国内某大跨度斜拉桥健康监测系统1个月共744 h收集到的桥梁加速度数据^[11],该桥梁拥有监测应变、加速度、温度等数据的健康监测系统。桥梁加速度数据被该系统中的38个传感器进行监测和记录,数据采集频率为20 Hz。本文将1个月内各加速度传感器采集到的数据进行分割,分割间隔为1 h,因此每条样本为单个加速度传感器1 h内采集到的数据,样本维度为 $1 \times 7\ 200$ 。根据文献[9]将各样本数据按波形进行划分并人工标注各样本数据标签,其中:数据和波形图像大部分或全部区域空白标记为缺失;数据幅值极小、波形图像呈锯齿状标记为次小值;数据和波形图像包含1个或多个突变标记为离群值;数据超过传感器量程、波形图像呈方形标记为超量程振荡;波形图像单调上升或下降标记为趋势;波形图像局部单调上升或下降交替出现,呈随机漂移状标记为漂移。样本类型及数量见表1所列,各类型样本数据波形如图1所示。

表1 数据类型及数量

序号	类型	数量/个
1	正常	13 575
2	缺失	2 942
3	次小值	1 775
4	离群值	527
5	超量程振荡	2 996
6	趋势	5 778
7	漂移	679






图 1 原始样本数据波形图

1.1 数据可视化

本文采用时频分析法提取数据时频联合特征并进行可视化处理,将一维加速度数据转变为二维时频图像,制备数据库用于模型的输入和训练。各时频图像按照日期小时段传感器序号命名,如利用第 32 个传感器 2012 年 1 月 12 日 14 时至 15 时采集到的数据转换而来的时频图像即命名为 2012-1-12-14-32,方便后续实现异常监测数据的准确定位。

时频分析法主要包括短时傅立叶变换、连续小波变换等。短时傅里叶变换的窗口函数尺寸影响特征提取效果,需根据信号具体特征选择合适的窗口大小。桥梁加速度信号为非平稳信号,短时傅里叶变换窗口尺寸固定,对非平稳信号适应性较差,对该数据集样本的特征提取效果并不理想。连续小波变换在保证窗口面积不变的同时根据信号特征变换窗口尺寸,对非平稳信号适应能力更强,分析效果更好,因此本文采用连续小波变换法对数据进行时频分析和特征提取。基于连续小波变换法得到的部分时频图像如图 2 所示。




图 2 部分样本时频图像

1.2 数据增强

文献[12]指出,各样本类别数量的不平衡可能对 CNN 模型的分类诊断效果造成影响,数据增强是解决样本过少、样本类别不平衡的有效方法。数据增强法通过对数据图像进行随机裁剪、随机旋转、色彩抖动等操作实现数据集的扩充。本文通过对离群值、漂移 2 类原始数据图像随机

添加少量噪声,实现样本类别相对平衡。

1.3 数据归一化

神经网络底层权重参数的更新会改变高层的输入分布,采用批量归一化方法使得各输入服从均值为 0、方差为 1 的分布,加快网络收敛速度。归一化数学表达式为:

$$x_{i+1} = (x_i - \mu) / \sigma \quad (1)$$

其中: x_i 为原始数据; x_{i+1} 为经过归一化操作后的输出; μ 为原始数据均值; σ 为原始数据标准差。

1.4 数据集划分

将经过预处理后得到的时频图像数据库随机划分为训练集、验证集和测试集,各部分比例为 6:2:2。使用训练集和验证集训练和评估网络模型,并利用反向传播算法^[13]优化模型权重参数;未被使用的测试集数据样本将用于检验完成训练后模型的准确率和泛化能力。

2 数据异常诊断模型设计

深度学习通过构建和训练深度神经网络来模拟人脑的神经结构和功能,从输入数据中自动学习并抽取高级抽象的特征表示。常见的深度学习模型主要有 CNN、循环神经网络(recurrent neural networks, RNN)、生成对抗网络(generative adversarial networks, GAN)等。本文将一维桥梁监测数据转变为二维时频图像用于模型的输入和训练,因此选择图像特征提取能力更强的 CNN 作为基础模型结构。

CNN 是一种以卷积运算为主、具有深度结构的前馈神经网络,采用局部连接和权值共享机制减少参数数量,降低模型复杂度,使得模型更易于优化,降低过拟合风险。模型基本结构主要由卷积层、池化层、全连接层和 Softmax 层组成,如图 3 所示。

本文以经典卷积神经网络模型为框架,将 GoogLeNet 网络^[14]的 Inception 模块与 ResNet 网络^[15]的残差模块相结合,构建桥梁健康监测数据异常诊断模型。




图 3 卷积神经网络模型结构图

2.1 Inception 模块与残差网络

2.1.1 Inception 模块

GoogLeNet 是一种含并行连结的网络结构,其中 Inception 模块是该模型的核心,模块示意图如图 4 所示。为抽取不同层面信息,Inception 模块共建立 4 条路径,使用多种窗口大小不同的卷积核(1×1、3×3 和 5×5),各路径最终在输出通道合并,且保证输出特征图高宽与输入特征图相等。其中,尺寸大小为 1 的卷积核可以降低通道数,从而减少计算参数。Inception 模块增加了网络的深度和宽度,对不同特征的学习能力更强,同时减少参数使模型更易于优化。

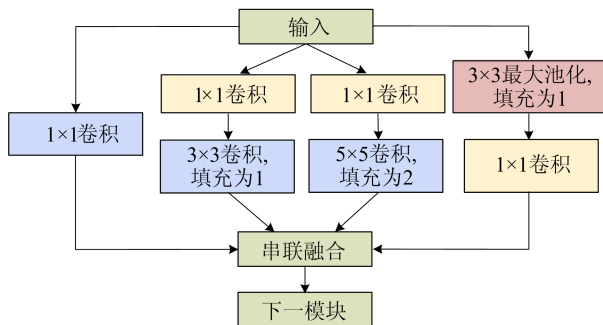


图 4 Inception 模块示意图

2.1.2 残差模块

加深网络层数可以提取不同层次特征,是提高模型精度和学习能力最直接的方法。然而网络层数过多不仅会增加模型计算量,还可能会导致梯度消失、爆炸和网络退化,使得模型表达能力降低。为解决这些问题,文献[15]提出了 ResNet 网络,普通模块和残差模块示意图如图 5 所示。

图 5b 中: x 为输入; $H(x)$ 为理想映射; $F(x)$ 为残差映射;残差模块加入恒等映射使得网络模型由拟合 $H(x)$ 转变为拟合 $F(x)$,降低模型拟合复杂度,加快模型收敛速度。

增加模型层数的前提是保证更深层的网络模型表达能力不低于浅层网络,残差模块通过引入恒等映射的方法实现这个功能,即经过恒等映射

的输入与输出相等。

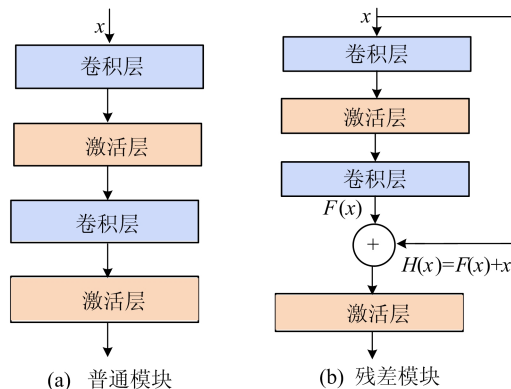


图 5 普通模块和残差模块示意图

2.2 Mini-Batch 与 Adam 优化算法

深度学习有 2 种参数更新方式:① 遍历所有样本后计算损失、更新梯度;② 对每个样本计算损失和梯度。前者计算量大、速度慢,后者收敛性能差、震荡剧烈。

文献[9]采用的 Mini-Batch 法将数据集划分为若干批子数据集,每一批量数据随机产生,通过对批量数据计算损失并反向传播实现参数更新,即小批量随机梯度下降法(mini-batch gradient descent, MBGD)。选择大小合适的学习率对 MBGD 法而言至关重要,过小的学习率会导致模型收敛速度降低,而较高的学习率则可能导致在极值点附近振荡。为此,深度学习领域引入动量法^[16],减少振荡过程,使网络收敛更加稳定。Adam 算法是一种引入动量法的自适应优化算法,结合众多优化算法的优点,在深度学习领域中应用广泛。

2.3 模型结构

本文将常规 CNN 模型、Inception 模块和残差模块相结合,构建监测数据异常诊断模型,模型结构如图 6 所示。

由图 6 可知,时频图像首先经过大小为 7×7 的卷积层迅速降低特征图尺寸,经正则化和激活操作后,使用大小为 3×3 池化层抽取输入图像中最突出的特征,降低数据维度;之后输入图像再次卷积、激活和池化操作后被输入至具有 4 个不同路径的 Inception 模块进行特征提取;Inception 模块输出的特征图再经一次卷积、激活和池化操作后被输入至 2 层残差模块;最后经自适应平均池化和全连接层后得到 Softmax 层的输入,利用 Softmax 层计算出样本属于各类别的概率值,其

表达式为:

$$\begin{cases} s_i = \frac{\exp(o_i)}{\sum_{i=1}^n \exp(o_i)}, \\ \sum_{i=1}^n s_i = 1 \end{cases} \quad (2)$$

其中: o_i 为模型输出; s_i 为归属于各类别的概率。

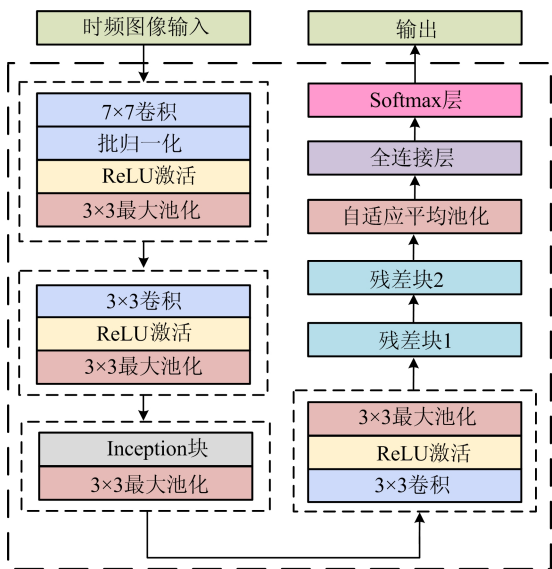


图 6 数据异常诊断模型结构

利用损失函数计算模型实际输出与期望输出之间的误差并进行反向传播,实现网络模型各权重参数的更新和优化,反向传播计算公式为:

$$\begin{cases} W = W - \alpha \frac{\partial L}{\partial W}, \\ b = b - \alpha \frac{\partial L}{\partial b} \end{cases} \quad (3)$$

其中: W 为卷积权重; b 为偏置项; L 为损失值; α 为学习率。

3 实验及结果分析

3.1 数据异常诊断流程

本文基于 Python 环境下 PyTorch 深度学习框架实现数据处理、模型构建、结果分析和可视化等工作,桥梁健康监测数据异常诊断步骤为:① 对获取的桥梁健康监测数据进行读取、命名、可视化、数据增强、归一化等预处理操作;② 制备图像数据库,按比例将预处理后得到的数据库划分为训练集、验证集和测试集;③ 设计模型,利用深度学习框架建立模型并对其进行参数初始化;④ 进行模型训练,利用反向传播算法更新和优化模型参数,利用验证集验证模型诊断准确率是否达到要求,满足要求则进入下一步骤,未达到要求返回步骤③,

直至模型训练结果达到要求后保存诊断效果相对最佳的模型;⑤ 将最佳模型应用于桥梁监测数据异常诊断中,得出分类结果并对其进行统计分析和可视化。数据异常诊断流程图如图 7 所示。

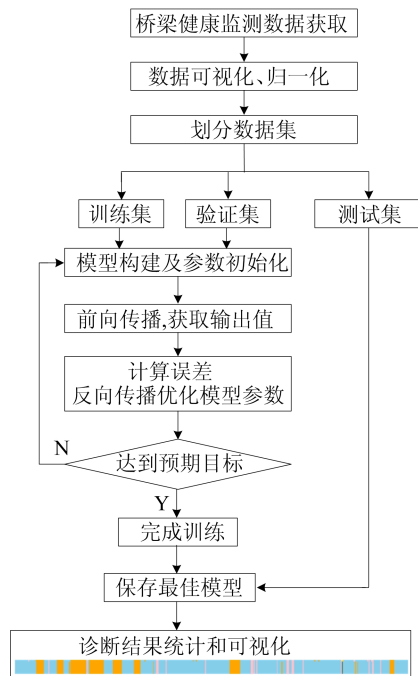


图 7 模型诊断流程图

3.2 模型训练参数设置

参数的设置对神经网络模型的诊断效果具有重要影响,可设置的模型参数主要包括激活函数、优化算法、学习率等。本文经过多次实验,选择 ReLU 作为模型的激活函数:

$$f(x) = \max(0, x) \quad (4)$$

使用 Mini-Batch 法进行训练,模型学习率设置为 0.000 1,训练轮数为 200,批量大小为 64。

选取 Adam 为模型优化算法,选择交叉熵函数^[17]为模型损失函数,其数学表达式为:

$$L(y, \hat{y}) = - \sum_{i=1}^m [y \lg \hat{y} + (1 - y) \lg(1 - \hat{y})] \quad (5)$$

其中: m 为样本数量; y 为样本标签; \hat{y} 为模型输出结果。

3.3 训练结果及对比分析

为验证本文提出的模型比传统深度学习模型更具优越性,实验中增加了经典深度学习模型 AlexNet 作为对比实验,模型各项参数设置均与本文所提模型保持一致。

计算模型参数数量可以看出,本文所构建的模型参数数量为 35.04×10^6 ,远低于 AlexNet 模

型的参数数量 46.78×10^6 , 运算量更小、运行速度更快。2 个模型训练过程中损失和诊断准确率对比如图 8 所示。

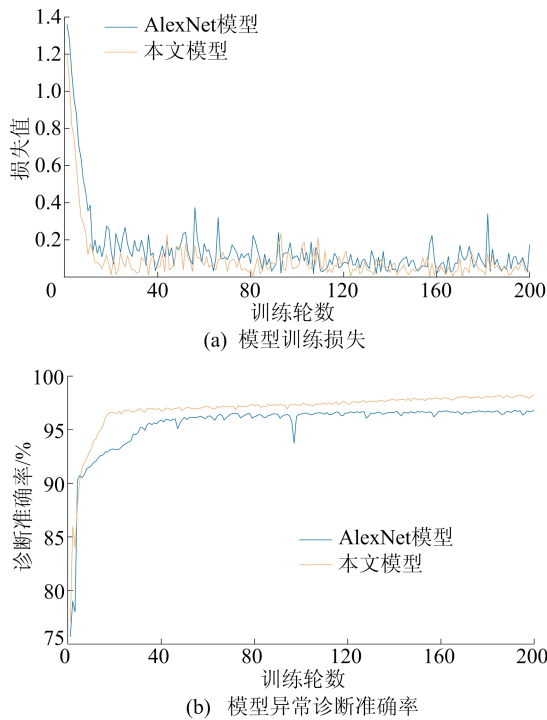


图 8 模型训练过程损失和诊断准确率

从图 8a 可以看出,随着训练轮数的增加,2 个模型训练损失在前期迅速降低,本文所提模型较 AlexNet 模型而言损失值更小,损失变化曲线更稳定。从图 8b 可以看出,本文所提对各类型桥梁健康监测数据诊断准确率在经过约 20 轮训练后迅速达到 95% 以上,随后缓慢爬升至 98% 左右并保持稳定,相较于 AlexNet 模型具有更高的诊断准确率和更强的稳定性。

3.4 实桥监测数据异常诊断

3.4.1 模型诊断性能评估

选择诊断准确率和泛化能力最佳的模型在测试集上进行诊断,训练好的模型对监测数据异常诊断准确率为 96.69%, 高于文献[9]所提方法 94.2% 的准确率。结果表明,将含并行连接的 Inception 模块与残差网络相结合,所构建的模型对桥梁健康监测数据具有良好的异常诊断性能。

为更有效地评估本文所提模型的准确性,本文使用精确率和召回率 2 种评价指标对该模型诊断性能进行评估。其中:精确率是指模型预测为某种类别的样本中预测正确的数量;召回率是指某种类别的样本中被模型正确预测的数量。精确率和召回率的数学表达式为:

$$\begin{cases} A = (T_P + T_N)/(T_P + F_P + F_N + T_N), \\ P = T_P/(T_P + F_P), \\ R = T_P/(T_P + F_N), \\ F_1 = 2PR/(P + R) \end{cases} \quad (6)$$

其中: A 为准确率; P 为精确率; R 为召回率; F_1 为精确率和召回率的调和均值; T_P 为预测为研究类别且被正确预测的样本数量; T_N 为属于其他类别且被正确预测的样本数量; F_P 为预测为研究类别且预测错误的样本数量; F_N 为属于研究类别且预测错误的样本数量。将模型预测结果按式(6)计算,结果见表 2 所列。

表 2 模型诊断结果评估

数据类型	A	P	R	F_1
正常	0.98	0.98	0.99	0.98
缺失	1.00	1.00	1.00	1.00
次小值	0.95	0.94	0.89	0.91
离群值	0.95	0.93	0.87	0.90
超量程振荡	1.00	1.00	0.99	1.00
趋势	0.97	0.95	0.98	0.96
漂移	0.52	0.79	0.54	0.64

3.4.2 传感器数据质量分析

为更加明确地了解各传感器工作状态,利用数据分析库 openpyxl 和 pandas 将训练、验证和测试结果进行汇总,各传感器监测数据类型占比诊断结果与实际标签统计结果如图 9 所示。

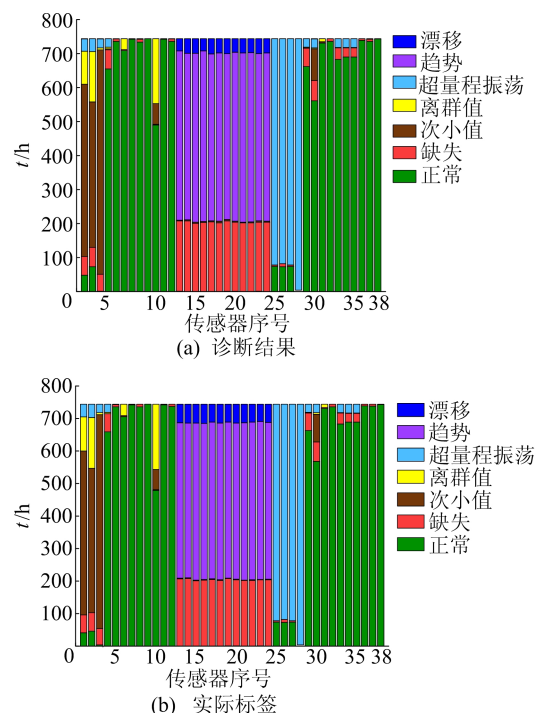


图 9 各传感器监测数据类型占比统计

图 9 中,各柱状图柱高为 744,表示 1 个月共 744 h 的数据采集时间,使用 7 种颜色分别表示 7 种类别的监测数据。

结果显示实际数据中异常数据占比为 51.98%,与诊断结果 51.87% 相差 0.11%;各传感器监测数据类型占比诊断结果与实际情况基本相同。由图 9 可知:4 到 12 号传感器和 29 到 38 号传感器中除 10 号、30 号传感器外,正常数据累计时间均超过 650 h,工作状况良好;13 到 24 号传感器数据质量差,正常数据占比极少,数据异常类型主要为缺失、趋势和漂

移;25 到 28 号传感器数据异常类型较为单一,数据超量程振荡累计时间均超过 600 h;1 到 3 号传感器数据异常类型多且比重大,异常数据类型主要为次小值和离群值。

3.4.3 异常数据时空分布情况统计

为更加直观地了解各异常数据时空分布情况,本文利用数据分析库 openpyxl、pandas 和图像绘制库 matplotlib 绘制异常数据时空分布统计图,实现各异常数据在时间和传感器层面的双重定位。各类型数据时空分布诊断结果和实际标签时空分布统计结果如图 10 所示。

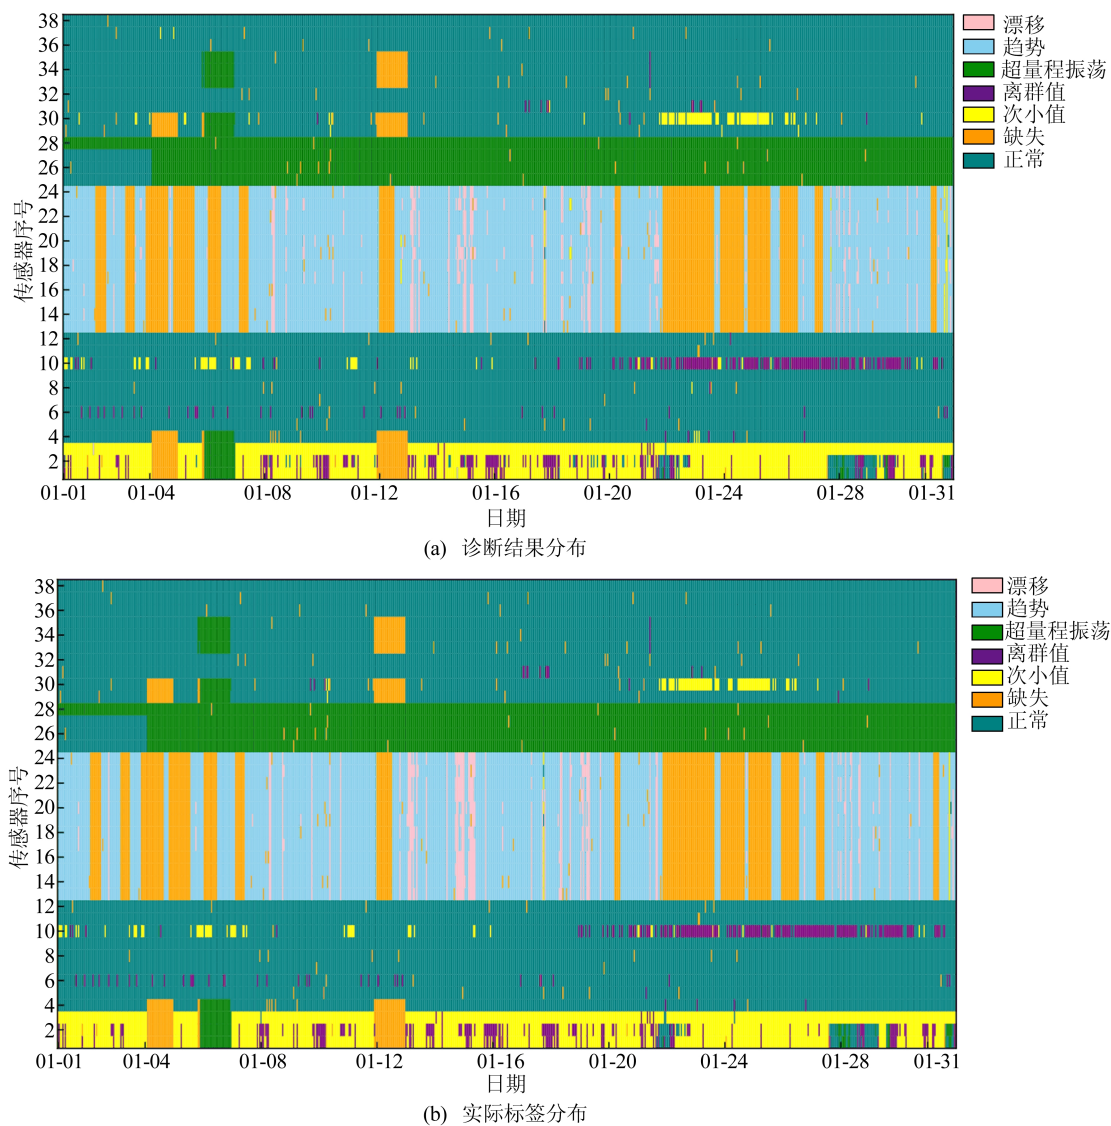


图 10 监测数据时空分布统计

为充分验证本文方法可靠性,人工标记 1 个月内的数据,将实际标签分布图和本文所提模型得到的诊断结果分布统计图进行对比,结果表明二者基本一致。由图 10 可知:1 到 3 号传感器整

月监测数据异常类型以次小值为主,而 28 号传感器则主要表现为整月数据超量程振荡;10 号传感器监测数据自 1 月 20 日起连续出现离群值,至 1 月 30 日结束;13 到 24 号传感器整月监测数据

主要表现为缺失和趋势 2 种异常类型;25 到 27 号传感器前期表现正常,自 1 月 4 日起直至月底持续出现监测数据超量程振荡;4 到 12 号传感器中除 10 号传感器、29 到 38 号传感器则总体表现相对正常。各类型数据时空分布统计图分析结果与各传感器监测数据类型占比统计图一致。

4 结 论

本文将深度学习与时频分析法相结合,构建深度神经网络模型对桥梁健康监测数据异常进行诊断,得出如下结论:

1) 对本文所提模型进行训练和评估,将各类型桥梁健康监测数据用完成训练的模型进行诊断。结果表明,实际数据中异常数据占比为 51.98%,与诊断结果 51.87%相差 0.11%,模型对监测数据异常诊断准确率为 96.69%,与传统深度学习模型相比具有更好的诊断性能。

2) 利用数据分析库汇总并统计诊断结果,绘制各传感器监测数据类型占比统计图,实现了对传感器工作状态的直观判断。

3) 利用数据分析库和图像绘制库绘制异常数据时空分布统计图,实现了各异常数据在时间和传感器层面的双重定位。

4) 将各传感器监测数据类型占比诊断结果统计图、各类型数据时空分布诊断结果统计图分别与对应的实际标签统计图对比,验证了本文所提模型的可靠性。

[参 考 文 献]

- [1] 王凌波,王秋玲,朱钊,等. 桥梁健康监测技术研究现状及展[J]. 中国公路学报,2021,34(12):25-45.
- [2] SUN L, SHANG Z, XIA Y, et al. Review of bridge structural health monitoring aided by big data and artificial intelligence: from condition assessment to damage detection[J]. Engineering Structures, 2020, 146(5):04020073.
- [3] 袁慎芳,梁栋,高宁,等. 基于结构健康监测系统的桥梁数据异常诊断研究[J]. 电子科技大学学报,2013,42(1):69-74.
- [4] 罗浩恩. 桥梁结构健康监测传感器自诊断方法研究[D]. 重庆:重庆大学,2016.
- [5] 卢宏涛,罗沐昆. 基于深度学习的计算机视觉研究新进展[J]. 数据采集与处理,2022,37(2):247-278.
- [6] 唐艺璠,窦立谦,季春惠,等. 基于深度迁移学习的航天器故障诊断[J]. 空间控制技术与应用,2021,47(3):57-63.
- [7] 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.
- [8] 梁宗保,柴洁,纳守勇,等. 基于深度学习的桥梁健康监测数据有效性分析[J]. 重庆交通大学学报(自然科学版),2021,40(3):78-83.
- [9] 唐志一. 基于深度学习的结构健康监测异常数据诊断与重构[D]. 哈尔滨:哈尔滨工业大学,2021.
- [10] 翁泽文,力宁,袁俊马,等. 基于声发射时频分析与卷积神经网络的液膜密封摩擦状态识别[J]. 润滑与密封,2023,48(1):136-141.
- [11] BAO Y Q, LI J, NAGAYAMA T, et al. The 1st international project competition for structural health monitoring (IPC-SHM, 2020): a summary and benchmark problem[J]. Structural Health Monitoring, 2021, 20(4):2229-2239.
- [12] 王德志,梁俊艳. 不平衡数据集文本多分类深度学习算法[J]. 计算机工程与设计,2021,42(9):2501-2508.
- [13] 王卓鑫,赵海涛,谢月涵,等. 反向传播神经网络联合遗传算法对复合材料模量的预测[J]. 上海交通大学学报,2022,56(10):1341-1348.
- [14] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston; IEEE, 2015:1-9.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas; IEEE, 2016:770-778.
- [16] 宫宁生,钱春阳,张媛. 一种 BP 网的学习速率与动量自适应算法[J]. 小型微型计算机系统,2013,34(8):1872-1876.
- [17] 周非,李阳,范馨月. 图像分类卷积神经网络的反馈损失计算方法改进[J]. 小型微型计算机系统,2019,40(7):1532-1537.

(责任编辑 吴 亮)