文章编号:1674-2974(2025)08-0158-14 DOI:10.16339/j.cnki.hdxbzkb.2025293

基于结构多维特征构建图卷积神经网络的结构损伤识别方法

杨建辉†,赵清瑄 ,蒲脯林
(兰州交通大学 电子与信息工程学院,甘肃 兰州 730070)

摘 要:以数据为驱动的深度学习结构损伤识别(structural damage identification,SDI)效果受结构复杂程度、模型构建方法及数据规模等因素影响较大.本文引入图卷积神经网络(graph convolutional neural network,GCN)以整合结构节点间的属性特征,从图的视角挖掘节点间的复杂属性关系,为SDI提供多维度学习信息.为此,设计了一种融合结构多维特征的图卷积神经网络模型(graph convolutional neural network integrating multi-dimensional features of structure,S-GCN),基于结构振动数据构造损伤特征矩阵,并通过衍生图网络,以图的节点和边表征结构节点的连接关系,构建边索引矩阵,将结构损伤状态、振动数据及节点属性等多维特征信息输入GCN进行结构损伤特征提取及预测识别,探索结构多维特征信息驱动下的GCN在损伤预测中的应用效果.通过两个钢结构验证方法的可行性及有效性,结果表明,S-GCN能够整合结构多维特征信息,对两个结构对象均实现了较高的损伤预测准确性,并展现出良好的噪声鲁棒性.进一步的对比分析显示,相较于三种非GCN模型,S-GCN能够高效地依托节点间关系快速更新节点特征并预测节点损伤状态,其损伤识别准确率、计算效率及网络各层演进过程均优于对比模型,验证了在结构损伤识别中融合结构空间特征的有效性.

关键词:结构损伤识别;图卷积神经网络;结构多维特征融合;噪声鲁棒性;训练效率
中图分类号:TP391 **文献标志码**:A

Using Multi-dimensional Features of Structure to Construct Graph Convolutional Neural Network for Structural Damage Identification

YANG Jianhui†,ZHAO Qingxuan,PU Pulin
(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070,China)

Abstract: The effect of data-driven deep learning structural damage identification (SDI) is greatly affected by factors such as structural complexity, model construction method and data size, etc. We introduce graph convolutional neural network (GCN) to integrate the attribute features between structural nodes, explore the complex attribute relationships between nodes from a graph perspective, and provide multi-dimensional learning information for SDI. To this end, a graph convolutional neural network integrating multi-dimensional features of

* **收稿日期**:2024-11-13
基金项目:国家自然科学基金资助项目(62361034),National Natural Science Foundation of China(62361034);甘肃省科技计划项目(25JRRA184),Science and Technology Program of Gansu(25JRRA184)
作者简介:杨建辉(1987—),男,河北昌黎人,兰州交通大学副教授,博士
† 通信联系人,E-mail:yangjh@mail.lzjtu.cn

structure (S-GCN) model was designed, which integrates multidimensional structural features. Based on structural vibration data, a damage feature matrix was constructed, and through a derived graph network, the connection relationship between nodes and edges in the graph was represented. An edge index matrix was constructed, and multidimensional feature information such as structural damage status, vibration data, and node attributes was input into GCN for structural damage feature extraction and identification. The application effect of GCN in damage identification driven by multidimensional structural feature information was explored. The feasibility and effectiveness of two steel structure verification methods were verified, and the results showed that S-GCN can integrate multi-dimensional structural feature information, achieve high damage identification accuracy for both structural objects, and demonstrate good noise robustness. Further comparative analysis shows that S-GCN can efficiently update node features and predict node damage status based on inter-node relationships compared with the three non-GCN models. Its damage recognition accuracy, computational efficiency, and network layer evolution process are all better than the comparative models, verifying the effectiveness of integrating structural spatial features in structural damage recognition.

Key words: structural damage identification; graph convolutional neural network; structural multi-dimensional feature fusion; noise robustness, training efficiency

桥梁、场馆等工程结构在服役过程中常受到多种外部载荷的影响而发生结构损坏,由裂缝、剥落或构件损坏引起结构局部刚度降低,影响结构使用寿命,甚至危及人民健康财产安全.为了有效预测结构服役状态并进行及时维护,结构损伤识别(structural damage identification, SDI)变得日益重要.在众多SDI方法中,传统的依赖视觉及经验的损伤识别方法存在效率低、周期长、受人为影响较大等弊端[1-3],基于振动信号的损伤识别方法可通过结构动力方程、数学推理或损伤特征挖掘等机制预测结构的损伤状态,是智能结构健康监测领域的重要手段之一[4-7].

近年来,使用深度学习方法进行结构损伤识别是结构健康监测领域的一个新兴研究方向[8-10],其基本思路主要是直接或间接利用结构振动数据训练深度学习模型,使网络模型能够从监测数据中学习结构状态并进行损伤识别.卷积神经网络(convolutional neural networks, CNN)作为一种经典深度学习模型,在SDI领域的应用取得了许多成果,如骆勇鹏等[11]提出了一种基于一维卷积神经网络的结构损伤识别方法,采用数值模型进行验证,可以直接从原始振动信号中自主学习损伤特征,并准确、快速地识别结构的损伤位置和损伤程度.Yang等[12]设计了一个三维信号处理卷积神经网络(3DS-CNN),即使在振动信号受到严重噪声污染的情况下,也能得到较为理想的SDI结果.Truong等[13]提出了一种新的深度学习框架,使用自动编码器-卷积门控递归单元处理带有噪声的振动数据并进行SDI分析.诸如此类的研究成果取得了显著进展,但仍具有一定局限性,如数据集规模与模型训练效率之间存在矛盾,未考虑结构节点间可能存在的潜在关联关系等,这些潜在问题可能影响数据驱动的SDI效果及工程化应用.

综合考虑已有深度学习SDI方法的优势及尚存问题,有学者引入图神经网络(graph neural network, GNN)和图卷积神经网络(graph convolutional neural network, GCN)进行结构损伤识别[14].GCN是一种用于处理图结构数据的深度学习模型,与CNN专注于处理网格结构的数据(如图像)不同,GCN可以有效地处理非结构化数据,例如社交网络、蛋白质相互作用网络和分子结构等[15].Dang等[16]将GCN引入结构损伤识别,构建一种以GCN为基础的SDI框架,直接对振动数据处理并进行损伤识别,但未考虑结构节点特征属性及数据在噪声影响下的SDI效果.

本文基于深度学习SDI的已有成果,考虑结构对象的节点属性特征及GCN优势,提出了一种融合多维结构特征的图卷积神经网络模型(S-GCN),通过处理不规则结构数据及结构节点对应的振动数据,力争捕捉结构节点的复杂关系属性及其损伤特征,从结构节点属性特征及振动数据两个维度实现结构的损伤分类识别.

1 SDI问题描述及S-GCN构建

1.1 SDI问题描述

SDI旨在通过分析结构的振动数据等信息,利用信号处理、动力分析或深度学习等手段推断结构的损伤状态,从而实现结构的健康监测和维护[17-22].

当结构出现不同程度的损伤时,结构的固有特性随之发生变化,表现出不同的动力行为,进而导致不同的响应数据特性.将结构A在不同损伤下的响应表示为R_A,对应的结构动力特性映射表示为$F(\cdot)$,其关系可用式(1)来描述:

$$R_A = F(A) \tag{1}$$

基于振动数据的SDI问题,目的是利用响应数据R_A反演结构的损伤状态D_A,这是一个典型的反问题,可以用式(2)来描述:

$$D_A = L(R_A) \tag{2}$$

其中方程$L(\cdot)$表示逆问题映射模型,其被拟合得越精确,越能从响应数据更好地评估结构损伤状态.当前主流的研究手段有基于模型和数据驱动的映射模型拟合方法,其中以数据为驱动的SDI方法多以CNN及其拓展框架来拟合$L(\cdot)$,但是,该类框架仅依赖大量的结构振动数据,未考虑结构节点之间的特征属性及其可能存在的潜在关系.本文尝试引入GCN模型构建一种融合结构多维特征的图卷积神经网络模型(S-GCN)来拟合方程$L(\cdot)$,以期在挖掘结构损伤信号特征的同时并行考虑结构的节点属性关系,从结构振动特性及自身节点属性两个维度实现结构的损伤预测识别.综合上述分析,以数据为驱动的SDI问题可描述为图1.

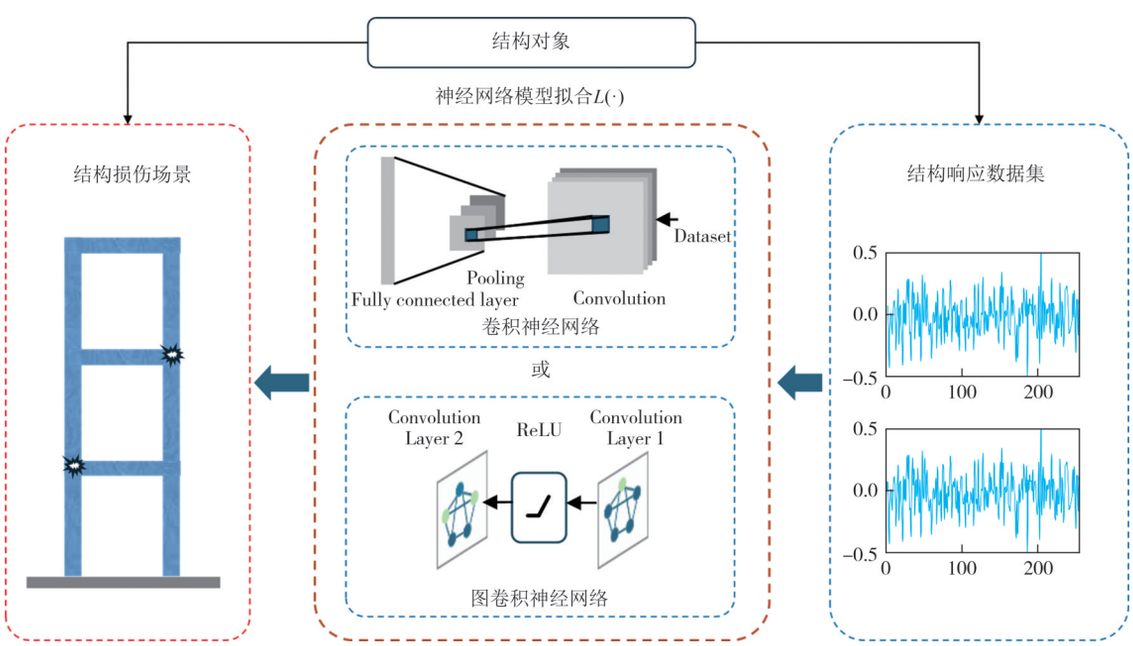

图1 SDI问题描述

Fig.1 SDI description

1.2 S-GCN的构建

GCN是一种用于处理图结构数据的深度学习模型,可以有效地对图数据进行特征学习和预测.本文构建一种S-GCN模型,通过将结构节点信息及振动数据以图结构数据的方式输入到GCN中,以更好地捕捉结构节点属性关系及节点损伤特征两个维度的特征信息.

1.2.1 输入层

S-GCN模型的输入层包含节点状态特征数据和表征结构节点关系的边索引矩阵.节点状态特征数据主要由节点处于某一损伤(含健康)状态下的一维振动信号组成;边索引矩阵主要通过结构节点间的属性关系表示.如果将某结构视为一个图,图的“节点”表示结构的不同部件,“边”表示这些部件之间的连接关系,即它们之间的关系属性,据此可构造邻接矩阵.某结构节点示意图及其邻接矩阵如图2所示.

1.2.2 特征提取层

特征提取层是图卷积神经网络的核心组成部分,它通过接收输入层的一维振动信号和邻接矩阵,并对输入的特征矩阵和边索引矩阵进行卷积操作来

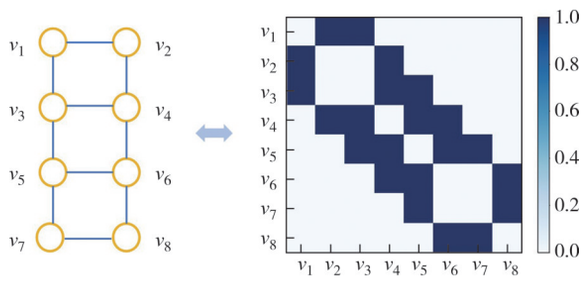

(a)邻接图　　(b)邻接矩阵

图 2　邻接图与邻接矩阵示例

Fig.2　Adjacency graph and adjacency matrix example

提取结构的损伤特征,进一步通过 ReLU(rectified linear unit)激活函数对卷积层的输出进行处理.本文所设计的 S-GCN 模型特征提取层主要由两层图卷积、ReLU 和全连接层组成.

①图卷积.在 S-GCN 中,将特征矩阵和边索引矩阵作为输入后执行图卷积操作,从而对结构的每个节点特征进行信息聚合和信息汇总.假设图结构表示为 $G=(V, E)$,其中 V 是节点集合,E 是边集合,对于每个节点 v_i,其初始特征表示为 x_0^i,图卷积中的特征聚合和特征更新过程为:

a.特征聚合:每个节点聚合其相邻节点的信息,并将聚合后的信息与自身的特征信息进行组合,完成信息传递,其数学表达式为:

$$m_{(i\to j)} = M(x_i^l, x_j^l, e_{ij}) \tag{3}$$

式中:M 是信息聚合函数,通常是一个可学习的函数;$m_{(i\to j)}$ 表示节点 v_i 向节点 v_j 传递的消息;x_i^l 和 x_j^l 分别是节点 v_i 和 v_j 在第 l 层的特征表示;e_{ij} 是节点 v_i 和节点 v_j 的边的联系.

b.特征更新:每个节点汇总其收到的相邻节点信息以更新自身的特征信息,其数学表达式为:

$$x_i^{(l+1)} = U(x_i^l, \{m_{(k\to i)}\} k \in N(i)) \tag{4}$$

式中:U 是信息更新函数,通常也是一个可学习的函数;$\{m_{(k\to i)}\} k \in N(i)$ 表示节点 v_i 收到的来自邻居节点的信息集合;$N(i)$ 表示节点 v_i 的邻居节点集合.经过系列信息更新操作,每个节点可以逐步更新其特征信息,从而学习到图中其他节点所反映的结构对象在空间及属性上的多维复杂特征,以推断自身节点状态.特征聚合和更新操作如图 3 所示.

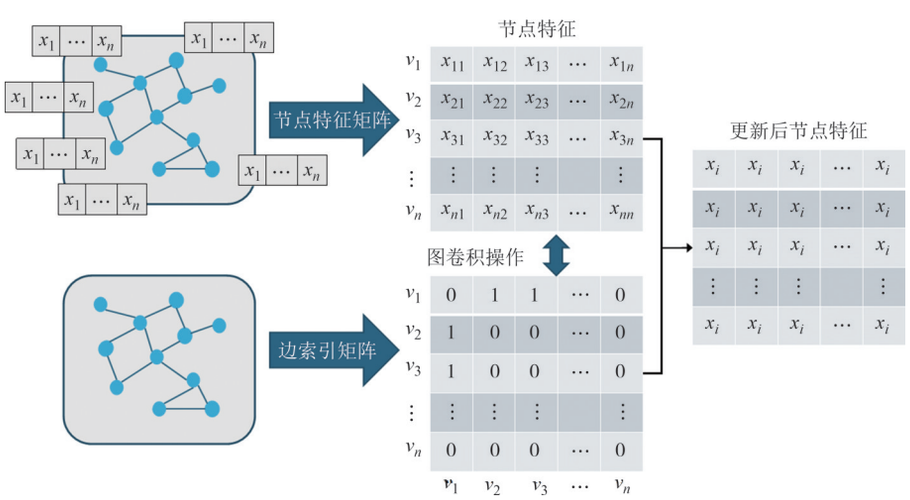

图 3　特征聚合和更新操作

Fig.3　Feature aggregation and update operations

通过图卷积层的特征聚合对相邻节点信息进行聚合,并汇总收到的信息以更新节点特征,使得 S-GCN 模型能够更好地理解结构中的空间节点特征及损伤信息,进而从结构振动数据和节点关系中提取出与损伤相关的关键特征,实现结构损伤的分类及识别.

②ReLU 激活函数.激活函数可对图卷积操作后的节点特征进行非线性变换,是 S-GCN 架构实现结构损伤特征提取的重要组成部分.本文选取一种常用的 ReLU 激活函数完成该关键特征处理,其数学表达式为:

$$f(a) = \max(0, a) \tag{5}$$

其中 a 是经过一层图卷积后更新得到的特征图.

③全连接层.全连接层位于最后一个图卷积层之后,其主要特点是层中的每个神经元与前一层的所有神经元完全连接,通过学习权重将高维的图特征映射成最终的结构损伤预测结果,其数学表达式为:

$$\boldsymbol{D} = \boldsymbol{w} \cdot \boldsymbol{g} + \boldsymbol{k} \tag{6}$$

式中:$\boldsymbol{D}$ 代表损伤类别的输出;$\boldsymbol{w}$ 代表权重矩阵;$\boldsymbol{g}$ 代表输入;$\boldsymbol{k}$ 代表偏置向量.

1.2.3 损失函数

交叉熵损失函数是用于多分类任务的一种常用损失函数,能够缩小模型预测结果与真实结果之间的差异,并通过最小化损失函数来优化学习模型,其数学表达式为:

$$\mathrm{Loss}=\frac{1}{b}\sum_{i=1}^{b}\sum_{j=1}^{c}w_j p(x_{ij})\log q(x_{ij}) \tag{7}$$

式中:b、c分别代表了损伤分类数和信号的个数;w_j为第j个损伤标签的权重;$p(x_{ij})$、$q(x_{ij})$分别为损伤类别j的第i个样本数据的预测值和真实值.

经过S-GCN模型的特征提取层操作,逐步实现对输入数据的节点特征关系挖掘及振动数据损伤特征信息提取,实现节点损伤分类,最终输出结构损伤预测结果.上述过程从节点属性关系及振动数据两个维度实现结构损伤的快速分类及识别,以期实现更良好的SDI效果.

1.3 基于S-GCN的结构损伤识别流程

综上,基于S-GCN的结构损伤识别执行过程可以总结为图4所示流程.具体步骤为:

1) 图的表示:将结构视为一个图,其中图的节点表示结构部件,边表示这些结构部件之间的物理连接关系.

2) 融合图结构的数据准备:根据结构节点关系和邻接矩阵对振动数据进行标记,使得数据标签与构造的图结构相对应,依此构建损伤特征矩阵及边索引矩阵.

3) 基于S-GCN的损伤特征提取:将损伤特征矩阵和边索引矩阵输入S-GCN,通过结构多维特征传递聚合、信息汇总更新等操作完成节点的损伤特征提取.

4) 结构损伤预测输出:根据S-GCN模型得到的损伤特征输出相应损伤预测结果.

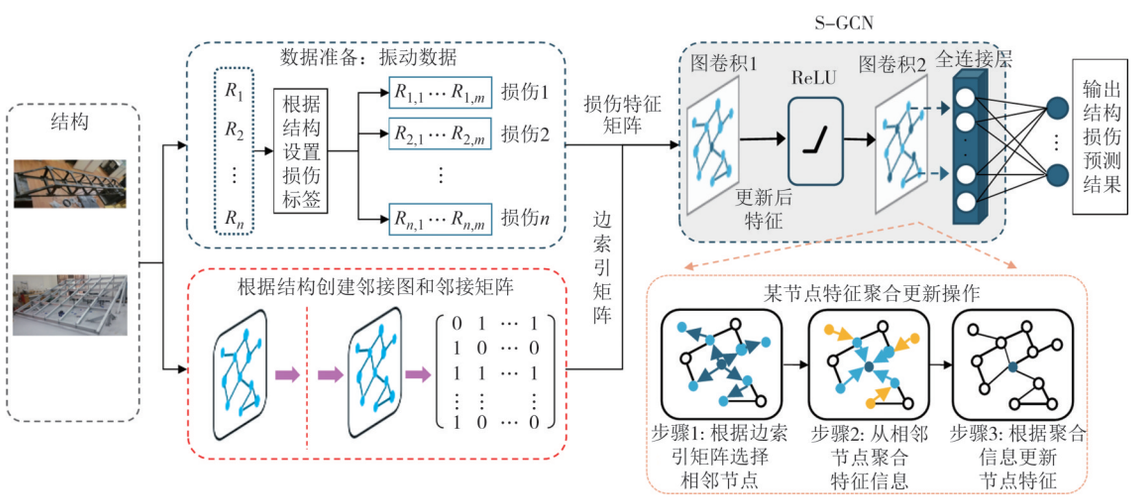

图4 基于S-GCN的SDI过程

Fig.4 SDI process based on S-GCN

2 试验分析

为了验证文中所提方法的有效性,采用两个不同的钢结构进行试验分析,其结构损伤均通过连接节点处的螺栓松动或脱落模拟,同时给出了与其他3种网络模型的对比分析结果.

2.1 案例1:桥式钢桁架结构

2.1.1 结构对象及数据采集

以某桥式钢桁架结构为例进行试验分析,结构尺寸为2 800 mm×390 mm×270 mm,材料密度为7 800 kg/m^3,弹性模量为190 GPa.为简化试验过程,主要以钢桁架上层结构的12个节点为对象进行分析.

在试验过程中,考虑采集设备DASPV11-INV3062C的通道限制(支持8通道数据),布置4个加速度传感器(编号s1~s4)采集结构在不同损伤情况下的振动特性,其中单向传感器s1~s3各占1路通道,三向传感器s4占3路通道.传感器布置原则以尽可能采集到结构上所关注节点的振动数据为准(详细布置原则见文献[12]),力锤激励点尽量靠近结构中心.采集设备基本参数配置及通道连接情况如表1所示,试验场景、激励点及传感器布置情况如图5所示.

2.1.2 损伤场景及数据集构建

由于钢桁架各节点主要以螺丝加固,对结构上层12个节点,以松动螺丝(彻底松动)模拟节点的损

表 1　数据采集设备信息和通道连接详细信息

Tab.1　Data collection equipment information and channel connection details

参数名称	通道采样率	采样信号点数	CH1	CH2−CH4	CH5	CH6	CH7
设置/连接	2 kHz	1 024	力锤	s1~s3	s4_X	s4_Y	s4_Z

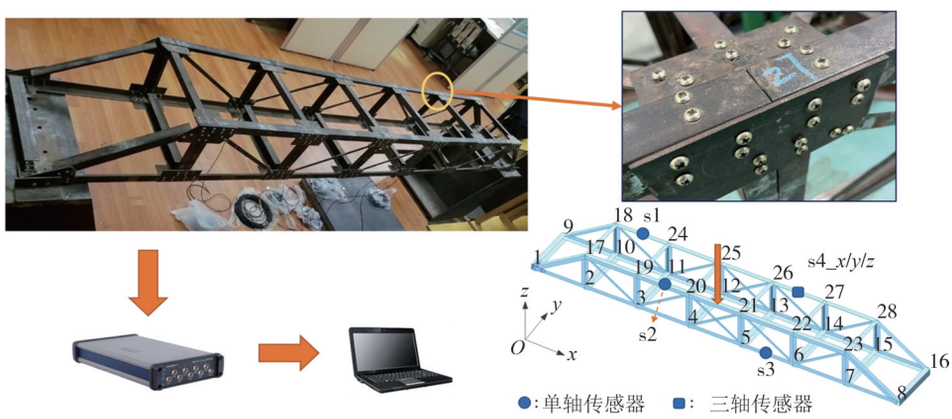

图 5　试验场景和传感器位置

Fig.5　Experimental scenario and sensor location

伤场景,将其标定为 1~12,加之结构无损伤状态(标定为 0),本试验共有 13 种结构状态,桥式钢桁架结构损伤情况及标签分类如表 2 所示.在每种结构状态下分别采集 200 组加速度数据,结合图 2 所示邻接矩阵构建数据集,其中 80% 用于模型训练,20% 用于模型测试.

表 2　桥式钢桁架结构损伤情况及标签分类

Tab.2　Damage situation and label classification of steel truss structures

损伤节点	无损伤	17	18	19	20	21	22	23	24	25	26	27	28
损伤标签	0	1	2	3	4	5	6	7	8	9	10	11	12

2.1.3　试验结果和分析

本文构建模型及编程平台为 PyCharm2023.2.5,基于 PyTorch 框架编程.深度学习工作站配置为 12th Gen Intel(R) Core (TM)i7−12700H, RAM: 15.6 GB, GPU: GeForce RTX4060, CUDA: 8.0 GB.基于整体数据规模,考虑现有硬件配置和时效性,经多次试错分析得到最佳的 S−GCN 初始参数如表 3 所示.为消除单次运行结果的不稳定性,重复训练 10 次 S−GCN 模型得到训练/测试准确率及损失值如图 6 所示,平均统计结果如表 4 所示.

由图 6 可知,S−GCN 对桥式钢结构损伤识别的训练/测试准确率均随着迭代轮数的增加而提高,且单次识别的损伤准确率均高达 98%.此外,模型训练过程中损失值逐渐降低,虽然个别轮次结果产生波动,但整体损失值最终接近 0.表明 S−GCN 模型能够基于图结构准确、高效地捕捉结构损伤特征信息,不

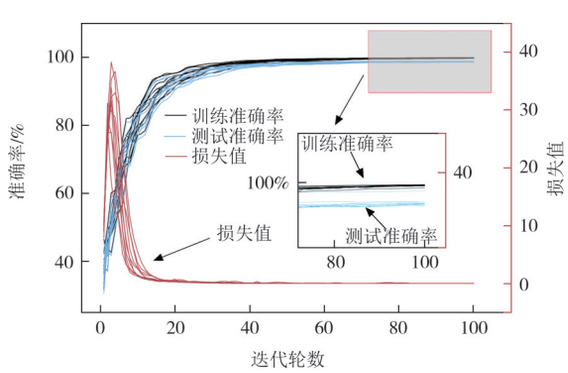

图 6　S−GCN 训练/测试准确率及损失值迭代曲线

Fig.6　S−GCN training/testing accuracy and loss value iteration curve

表 3　S−GCN 初始化设置

Tab.3　S−GCN initialization settings

序号	名称	参数	序号	名称	参数
1	输入层	1 024	5	优化器	Adam
2	隐藏层	310	6	训练集	80%
3	输出	13	7	测试集	20%
4	学习率	0.01	8	Epoch	100

表 4　重复训练 10 次 S−GCN 所得平均准确率和损失值

Tab.4　The average accuracy and loss value obtained from 10 repetitions of S−GCN training

指标	训练准确率/%	测试准确率/%	损失值
数值	99.80	98.68	0

断优化自身参数,尤其在训练前期即得到了较高的准确率,呈现优异的收敛速度,且训练和测试准确率相差不大,S-GCN 表现出良好的损伤识别泛化能力.

进一步统计训练结果的精确率P(precision),召回率R(recall)和F_1分值(F_1 Score)以分析S-GCN模型对桥式钢结构的损伤识别性能.上述损伤预测过程属于多分类问题,将当前损伤视为"阳",其他损伤视为"阴",精确率可评价S-GCN预测某数据为正例的查准率,召回率评估真实正例的查全率,F_1分值可综合权衡精确率和召回率,尤其对于不平衡的数据集或类别,F_1分值能够更好地反映模型的综合性能.三者的计算方法如下所示:

$$P = \frac{1}{b}\sum_{i=1}^{b}\frac{\mathrm{TP}_i}{\mathrm{TP}_i + \mathrm{FP}_i} \tag{8}$$

$$R = \frac{1}{b}\sum_{i=1}^{b}\frac{\mathrm{TP}_i}{\mathrm{TP}_i + \mathrm{FN}_i} \tag{9}$$

$$F_1 = \frac{2 \times R \times P}{R + P} \tag{10}$$

式中:TP为正样本正确预测数量;FP为负样本错误预测数量;FN为正样本错误预测数量;b为损伤分类数.

对上述训练过程仍重复计算10次,得到各损伤状态下的精确率P、召回率R、F_1分值及平均指标情况,如表5及图7所示.

由表5及图7可知,S-GCN对桥式钢结构各类损伤的正判能力较强,各损伤类别的平均精确率、平均召回率及平均F_1分值几乎都能达到98%以上.表明该模型对各类损伤数据的差异特征捕捉十分敏感,能够较为精确地对监测数据进行相应的损伤类型映射.

表5 P、R及F_1平均值

Tab.5 Average P, R and F_1 score %

指标	P	R	F_1
结果	99.20	99.19	99.19

2.1.4 噪声鲁棒性分析

在采集传感器信号过程中,因环境、设备、人为等因素的影响,实际采集信号不可避免地受噪声干扰.由电子元件热噪声、量化误差等因素导致的噪声常表现为高斯噪声,长期环境载荷作用下的结构响应可能呈现布朗噪声特性,由多种干扰叠加产生的噪声表现为混合噪声.为此,下文各选一种典型的噪声类型进行鲁棒性分析,其中原传感器信号添加高斯噪声、布朗噪声、混合噪声,可根据式(11)~式(13)模拟:

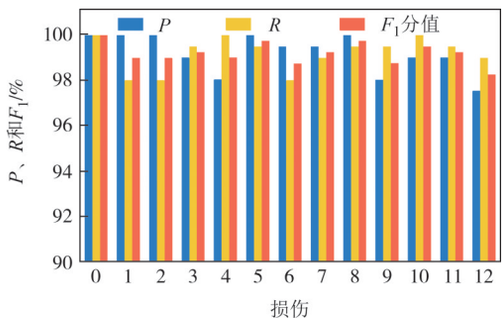

图7 S-GCN模型识别桥式钢结构各类损伤的P、R和F_1分值

Fig.7 P, R and F_1 for each classification of steel truss structures under S-GCN training

$$\dot{x}_{\mathrm{Gaussian}}(n) = x(n) + \beta \times \max \times r(n) \tag{11}$$

$$\dot{x}_{\mathrm{Browian}}(n) = x(n) + \beta \times b(n) \tag{12}$$

$$\dot{x}_{\mathrm{mixnoise}}(n) = x + \beta \times (\max \times r(x) + b(n)) \tag{13}$$

式中:$\dot{x}$表示加噪信号;$x(n)$表示原加速度信号;β为噪声系数,取值为0~100%;max为当前信号最大值;$r(n)$和$b(n)$分别为与$x(n)$同维的高斯白噪声和布朗噪声序列.实验发现:当β取60%时,原信号已严重失真,因此在进行S-GCN鲁棒性分析时,将β取值为[10%,60%],各噪声系数下的损伤识别准确率如表6所示.进一步单独分析了三种噪声系数均为60%时S-GCN对各损伤状态的预测情况,对应的精确率P、召回率R、F_1分值和混淆矩阵如图8和图9所示.

表6 S-GCN在不同噪声干扰下的损伤识别准确率

Tab.6 The accuracy of damage identification in S-GCN under different noise interferences %

噪声类型	噪声系数					
	10	20	30	40	50	60
高斯白噪声	97.02	96.65	96.08	89.65	79.92	70.08
布朗噪声	97.54	96.08	95.38	91.50	88.35	70.38
混合噪声	97.23	97.12	93.31	85.19	83.73	77.58

由表6可知,S-GCN模型在各类噪声低干扰环境下表现较为出色,能够对各损伤场景进行准确预测,随着各类噪声类型中噪声系数不断增强,其损伤识别准确率显著下降,说明噪声干扰对模型的损伤识别效果有直接影响,但噪声干扰达60%时仍能获得可观的损伤识别效果,尤其在混合噪声干扰时,S-GCN表现出良好的噪声鲁棒性.

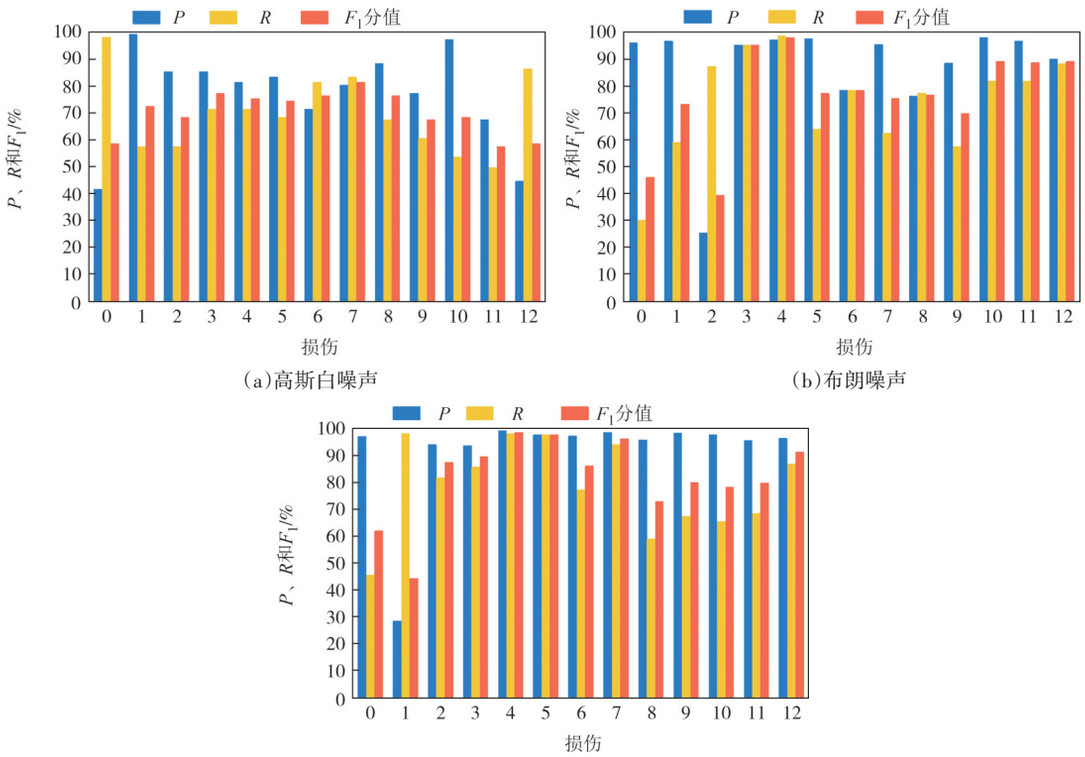

(a)高斯白噪声　　(b)布朗噪声

(c)混合噪声

图 8　S-GCN 在 60% 噪声时对各损伤预测的 P、R 和 F_1 分值

Fig.8　P, R and F_1 of S-GCN for predicting various damages at 60% noise level

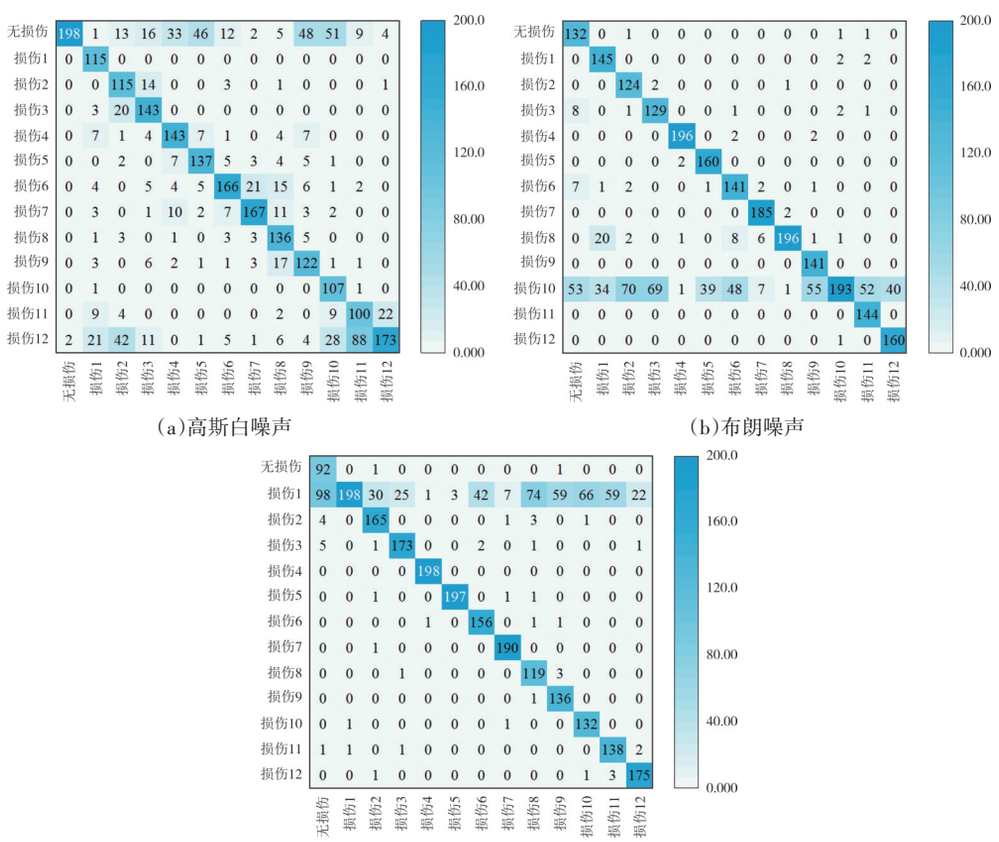

(a)高斯白噪声　　(b)布朗噪声

(c)混合噪声

图 9　S-GCN 在 60% 噪声时损伤预测混淆矩阵

Fig.9　S-GCN damage prediction confusion matrix at 60% noise

图8和图9的结果表明,在各类噪声干扰系数达到60%时,S-GCN模型对各损伤类别预测结果略有差异,表明不同损伤场景下的振动信号呈现一定差异,且对应的损伤特征易受噪声类型影响而发生变化.尽管如此,S-GCN模型整体仍能对各损伤进行有效分类,展现出良好的噪声鲁棒性.

2.2 案例2:QUGS

2.2.1 结构对象

为充分验证本文所提方法的有效性,进一步以卡塔尔大学看台模拟器结构(Qatar university grandstand simulator,QUGS)及公开数据集[23-28]进行试验分析.该结构占地面积为4.2 m×4.2 m,由8根大梁和25根填充梁组成,支撑在4根柱子上,8根大梁长4.6 m,悬臂部分的5根填充梁长约1 m,其余20根填充梁长77 cm,所有梁通过螺栓链接,共包含30个关键连接点,结构试验场景及节点编号如图10所示.

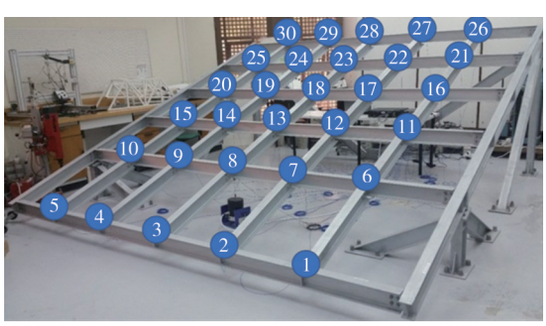

图10 QUGS结构及关键节点编号[23-28]

Fig.10 QUGS structure and key node numbers [23-28]

2.2.2 损伤场景及数据集构建

QUGS结构主要通过螺栓链接钢架梁固定,通过松动结构30个节点连接处的螺栓模拟不同的损伤场景,同时考虑结构无损伤状态,构造如表7所示的结构损伤场景及损伤标定关系.

表7 QUGS损伤情况及标签分类

Tab.7 QUGS damage situation and label classification

损伤节点	无损伤	1	2	…	29	30
损伤标签	0	1	2	…	29	30

试验过程中,通过模态激振器对结构进行周期性激励,通过30个加速度传感器采集结构在31种损伤状态下的加速度数据,采样频率为1 024 Hz,每种损伤场景共采集256 s,每种损伤信号共包含262 144个采样点.结构某节点的螺栓松动及加速度传感器安装情况如图11所示.基于QUGS公开数据及图2所示邻接矩阵构建数据集,所采集数据的80%用于模型训练,20%用于模型测试.

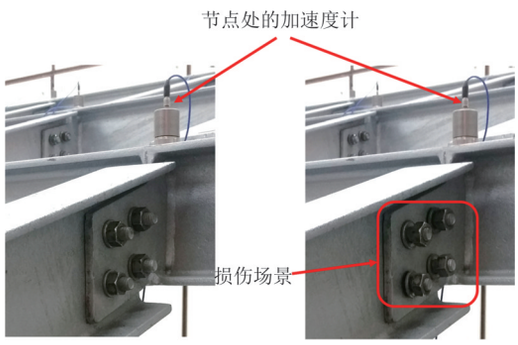

图11 QUGS某节点损伤场景及加速度计

Fig.11 Damage scenario and accelerometer of a certain node in QUGS

2.2.3 试验结果和分析

试验过程所用深度学习工作站同案例1,考虑QUGS数据集规模增大,经多次试错分析,将S-GCN结构隐藏层调整为710,S-GCN网络输出为31,其余参数同表3.

为消除单次运行结果的不稳定性,对S-GCN模型重复计算10次得到训练/测试准确率和损失值迭代曲线如图12所示,10次平均统计结果如表8所示.

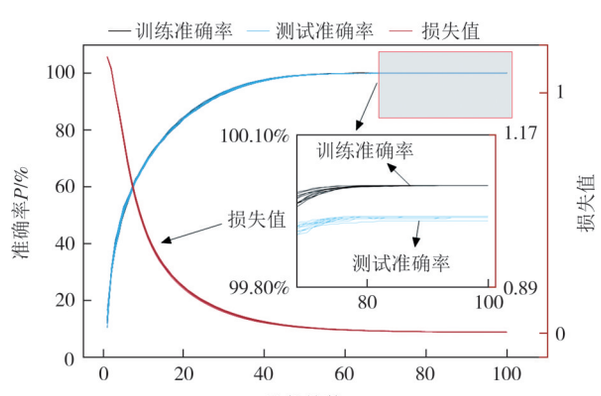

图12 S-GCN训练/测试准确率及损失值迭代曲线(QUGS)

Fig.12 S-GCN training/testing accuracy and loss iteration curve (QUGS)

表8 重复训练10次S-GCN所得平均准确率和损失值(QUGS)

Tab.8 Average accuracy and loss obtained from 10 repetitions of S-GCN training (QUGS)

指标	训练准确率/%	测试准确率/%	损失值
数值	100	99.93	0

由图 12 可知,随着迭代增加,训练准确率和测试准确率都趋近于 100%,且损失值逐渐减小,直至接近 0.同时,迭代结束前训练准确率和测试准确率差距较小,收敛速度较快,表明 S-GCN 在基于图结构数据下拥有高效的损伤数据特征挖掘能力及优秀的损伤识别泛化能力.

进一步统计 S-GCN 模型对 QUGS 结构数据进行损伤识别过程的精确率 P、召回率 R 和 F_1 分值,如图 13 所示,三项指标的平均统计情况如表 9 所示.

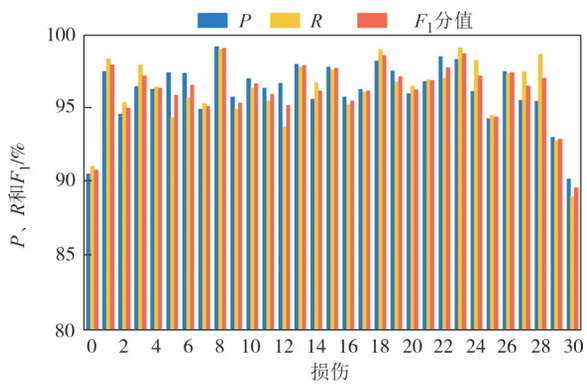

图 13　S-GCN 模型识别 QUGS 结构各类损伤的 P、R 和 F_1 分值

Fig.13　P, R and F_1 of S-GCN for identifying various types of damage in QUGS structures

表 9　P、R 及 F_1 平均值(QUGS)

Tab.9　Average P, R and F_1 (QUGS)　　%

指标	P	R	F_1
结果	94.19	95.05	96.18

由图 13 及表 9 可知,S-GCN 对所有损伤的识别精确率及召回率达 90%,个别损伤识别结果超过 95%,平均精确率及召回率分别为 94.19%、95.05%.表明 S-GCN 能够有效捕捉损伤样本信息且准确识别不同损伤的样本数据特征;多数损伤下的 F_1 分值超过 90%,平均 F_1 分值达 96.18%,表明 S-GCN 能够敏锐捕捉到各类损伤数据的微小差异,实现从监测数据到损伤场景的精确映射.

2.2.4　噪声鲁棒性分析

类似案例 1,采用相同方式对 QUGS 数据注入三种噪声以测试 S-GCN 模型对 QUGS 损伤识别的噪声鲁棒性,其统计结果如表 10 所示;各噪声干扰系数为 60% 时,模型对损伤识别结果精确率 P、召回率 R、F_1 分值和混淆矩阵如图 14 和图 15 所示.

由表 10 可知,S-GCN 模型在不同类型噪声干扰下仍能保持相对稳定的损伤识别准确率,当噪声干扰达 60% 时,其损伤识别准确率仍能维持在 76% 以

表 10　S-GCN 在不同噪声干扰下的损伤识别准确率(QUGS)

Tab.10　The accuracy of damage identification in S-GCN under different noise interferences　　%

噪声类型	噪声系数					
	10	20	30	40	50	60
高斯白噪声	98.89	98.10	96.02	92.85	89.09	85.26
布朗噪声	93.01	92.45	89.96	86.92	82.03	77.47
混合噪声	92.33	90.65	88.30	85.13	83.64	76.85

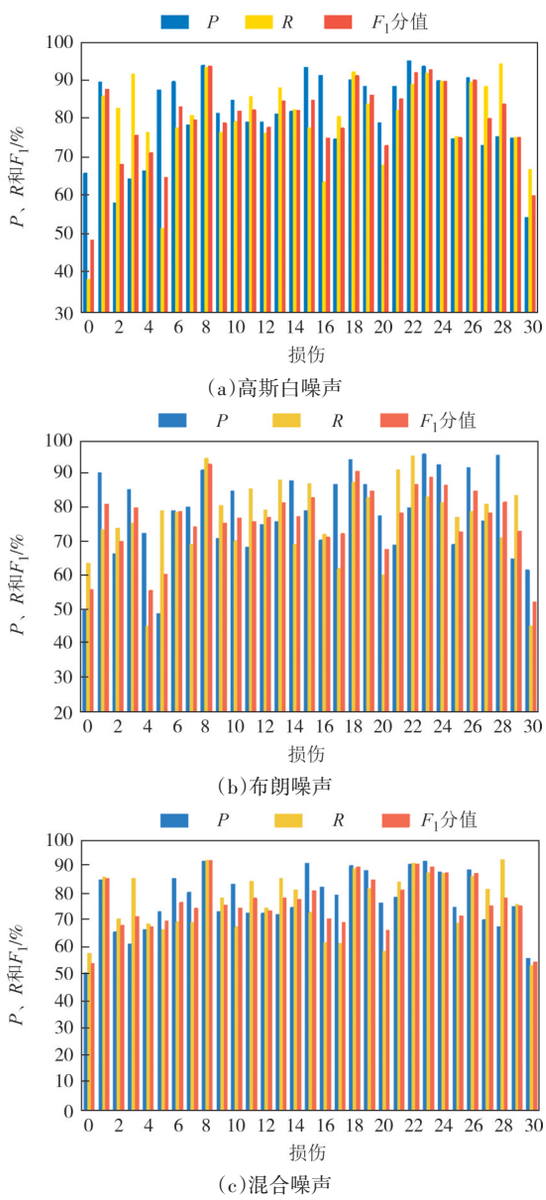

图 14　S-GCN 在 60% 噪声时对各损伤预测的 P、R 和 F_1 分值(QUGS)

Fig.14　P, R and F_1 of S-GCN for predicting various damages at 60% noise level (QUGS)

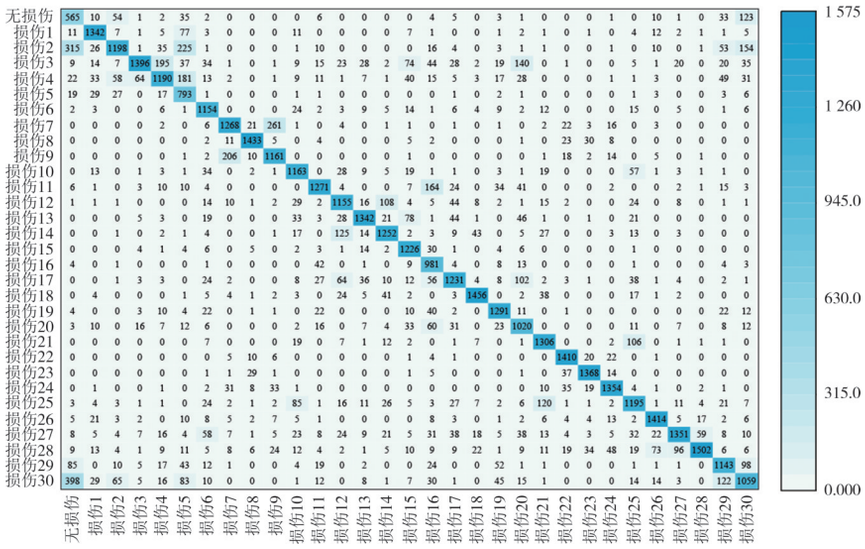

(a)高斯白噪声

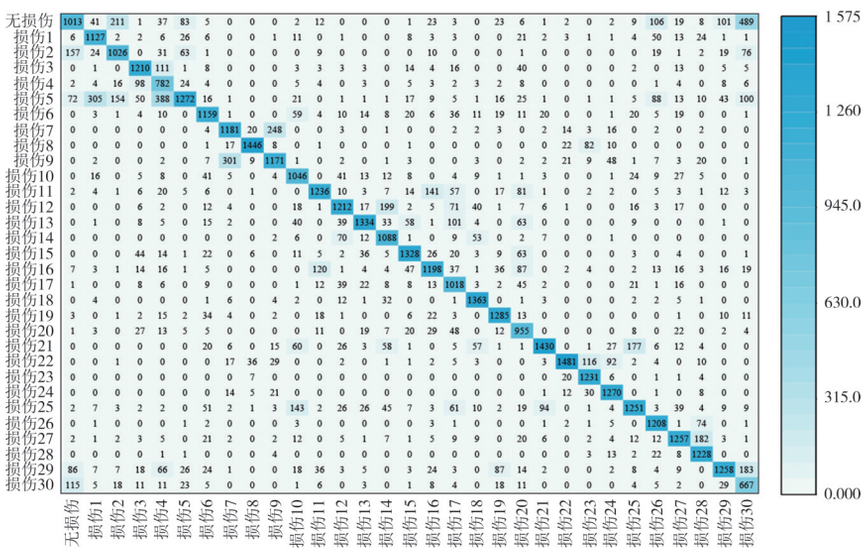

(b)布朗噪声

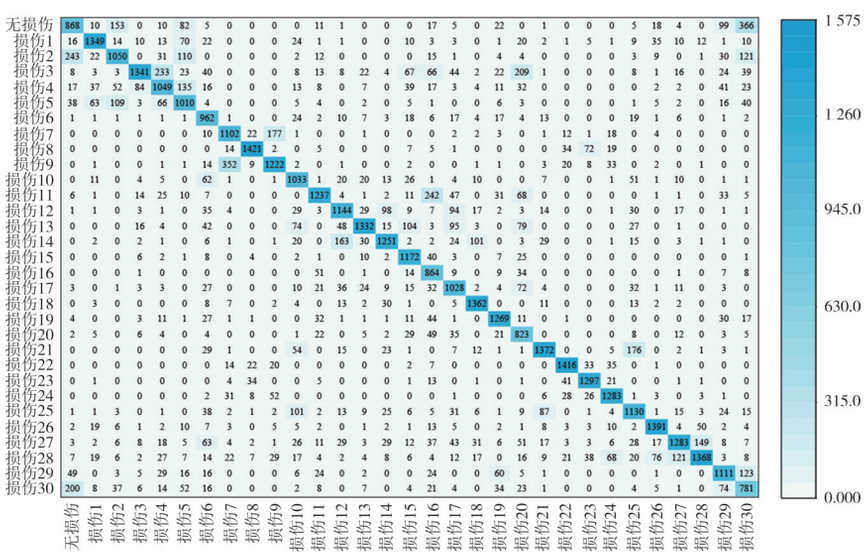

(c)混合噪声

图 15 S-GCN 在 60% 噪声时损伤预测混淆矩阵(QUGS)

Fig.15 S-GCN damage prediction confusion matrix at 60% noise (QUGS)

上,尤其在高斯白噪声强干扰环境中可达85.26%.表明了S-GCN模型的有效性,以及在严重噪声污染场景下卓越的损伤特征提取能力,从而确保了损伤识别的准确性.

由图14和图15可知,在不同类型噪声的影响下,S-GCN对QUGS结构各类别的损伤识别效果略有差异.因为该结构损伤场景更为丰富,各类别的损伤识别差异愈加明显.这个结果表明,对于QUGS这类损伤细化场景,监测数据容易受到不同类型噪声的干扰,造成个别损伤类别间特征重叠、难以区分,甚至出现误检、漏检等情况.但从强噪声干扰环境下的整体识别效果来看,S-GCN模型呈现较高水准的损伤识别能力,体现其优异的噪声鲁棒性.

3　S-GCN模型横向评估分析

为了进一步评估S-GCN的损伤识别性能,以案例1中60%高斯白噪声干扰下的桥式钢结构损伤识别场景为例,选择结构损伤识别领域常用的1DCNN、MLP、ResNet50网络模型进行横向对比分析.为确保评价的公平性,除隐藏层外,四种网络的主要参数均保持一致,如表11所示.经100轮Epoch训练,得到各网络模型的训练时间及损伤识别准确率,如表12及图16所示,同时给出了四种网络模型各层的特征演进过程(t-SNE可视化[29]),如图17所示.

表11　四种网络模型的参数配置

Tab.11　Parameters of four types of networks models

网络模型	S-GCN	1DCNN	MLP	ResNet50
输入	1 024	1 024	1 024	1 024
隐藏层	Conv1 ReLU Conv2 Linear	Conv1 Conv2 ReLU MaxPool Linear	Linear ReLU Linear ReLU Linear	Conv1 ReLU MaxPool Residualblocks AvgPool Linear
输出	13	13	13	13
学习率	0.01	0.01	0.01	0.01
优化器	Adam	Adam	Adam	Adam

由表12可知,S-GCN网络的训练时间显著优于其他三种网络模型.主要原因是S-GCN在处理图结构数据时,能够有效地挖掘节点间的复杂关系,通过邻域信息的聚合和更新操作,比传统的神经网络更高效,进而减少计算量.另外,在图卷积神经网络中,由于每层更新的信息均源自邻居节点的聚合信息,因此容易出现层数过深导致信息冗余或重合的情况.基于上述原因,本文设计的S-GCN模型仅保留两层图卷积操作,尽量保持良好的特征学习能力及训练效率.结合表12、图16及图17,可初步得到S-GCN具有以下优势.

表12　四种网络在100轮Epoch下的训练时间和准确率对比(60%高斯白噪声)

Tab.12　Comparison of training time and accuracy of four types of networks in 100 epochs (60% Gaussian white noise)

网络模型	S-GCN	1DCNN	MLP	ResNet50
训练时间/s	6.01	28.24	20.31	127.41
准确率/%	70.08	66.36	32.64	56.62

1)训练时间短:由于S-GCN网络层数较浅且结构简洁,在同等损伤数据规模下,S-GCN相较于MLP和1DCNN,训练时间缩短为1/3左右,相较于ResNet50,训练时间则缩短为1/20左右,反映S-GCN收敛速度快,在资源有限或需要快速迭代的场景下,S-GCN具有显著优势.

2)噪声鲁棒性好:即使S-GCN模型结构最简单,但其经过100轮训练后所得的损伤识别准确率为70.08%,相比其他模型具有更为优秀的噪声鲁棒性.

3)损伤数据特征聚合能力强:图17所示网络各层的特征演进过程表明,在面临同等混沌的输入数据时,S-GCN能够以最快的速度对混沌数据进行特征分离,呈现出结合结构空间节点特征对损伤状态分离及识别的显著优势.

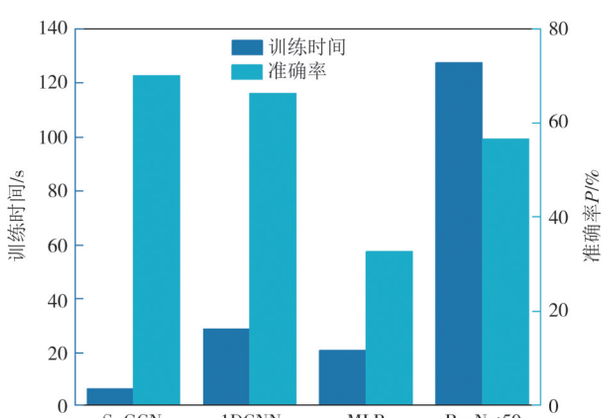

图16　四种网络的训练时间和损伤识别准确率(60%高斯白噪声)

Fig.16　Training time and damage recognition accuracy of four types of networks (60% Gaussian white noise)

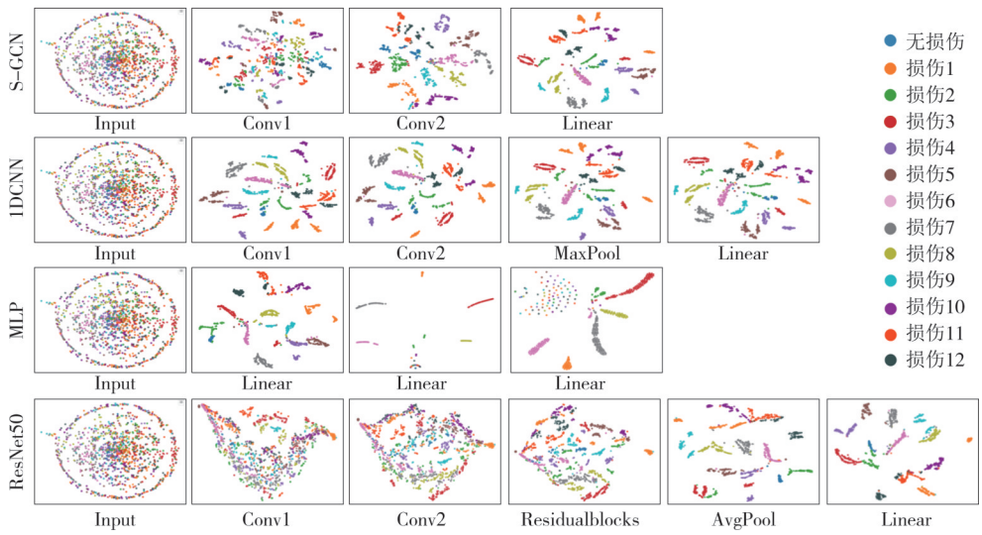

图 17 四种网络 t-SNE 对比图(60% 高斯白噪声)

Fig.17 Comparison of t-SNE in four types of networks (60% Gaussian white noise)

4 结 论

在数据驱动的深度学习结构损伤识别过程中,针对SDI效果受结构复杂程度、数据规模及噪声干扰等因素影响较大的问题,结合结构的节点属性特征及GCN优势,本文提出了一种称为S-GCN的融合结构多维特征的图卷积神经网络模型,从结构节点属性特征及振动数据两个维度实现结构的损伤分类识别.在充分考虑噪声干扰情况下,通过两个钢结构算例进行分析,得出以下结论:

1) 基于结构节点关系及其属性特征构造邻接矩阵,结合结构振动数据对S-GCN模型进行深度训练,有利于S-GCN充分捕捉结构节点特性及损伤数据特征.两个钢结构算例的损伤识别结果表明,S-GCN具有对损伤信息的敏锐学习能力及损伤样本判别能力,对测试数据表现出良好的泛化性能,在无噪声干扰情况下,能够实现98%以上的损伤识别准确率.

2) 当结构损伤数据受不同程度的噪声干扰时,S-GCN依然能够从强噪声干扰数据中提取结构的有效损伤特征信息.即使噪声干扰达60%,两个算例中也可获得高于70%的损伤识别准确率,说明S-GCN具备较好的噪声鲁棒性.尤其算例2中传感器位置均位于损伤节点处,所监测数据能够全面反映结构节点损伤状态,更利于S-GCN进行有效的损伤判别,即使在强噪声干扰情况下,也能获得高准确率的损伤识别效果.

3)与其他3个网络模型的横向评估分析表明,在同等数据规模下,S-GCN不仅在训练时间上显著优于1DCNN、MLP和ResNet50,且在训练效率与性能之间取得了良好的平衡.在大规模数据场景下,尤其融合结构数值模拟数据和实测数据的迁移学习结构损伤识别研究中,S-GCN有望表现出良好的应用潜力.

参考文献

[1] 李慧民, 董美美, 熊雄, 等. 基于振动的结构损伤识别研究综述[J]. 建筑结构,2021,51(4):45-50.
LI H M, DONG M M, XIONG X, et al. State-of-the-art review of vibration-based damage identification framework for structures [J]. Building Structure, 2021, 51(4): 45-50.(in Chinese)

[2] LI J,HAO H. A review of recent research advances on structural health monitoring in Western Australia[J]. Structural Monitoring and Maintenance,2016,3(1):33-49.

[3] AGDAS D, RICE J A, MARTINEZ J R, et al. Comparison of visual inspection and structural-health monitoring As bridge condition assessment methods [J]. Journal of Performance of Constructed Facilities, 2016, 30(3): 04015049.

[4] 赵俊, 程良彦, 马宏伟. 基于曲率模态的拱板结构损伤识别[J]. 暨南大学学报(自然科学版), 2008, 29(5): 470-477.
ZHAO J, CHENG L Y, MA H W. The damage detection in the arch basing on the changes in curvature mode shape[J]. Journal of Jinan University (Natural Science Edition), 2008, 29(5): 470-477.(in Chinese)

[5] 聂振华, 程良彦, 马宏伟. 基于结构动力特性的损伤检测可视化方法[J]. 振动与冲击, 2011, 30(12): 7-13.
NIE Z H,CHENG L Y,MA H W. Visualization method for structural damage detection based on its dynamic characteristics[J]. Journal of Vibration and Shock, 2011, 30(12): 7-13.(in Chinese)

[6] ZHANG J Q, JIN Z H, TENG S, et al. Structural damage detection based on decision-level fusion with multi-vibration signals [J]. Measurement Science and Technology, 2022, 33(10): 105112.

[7] 秦世强, 苏晟, 杨睿. 基于多标签卷积神经网络的结构损伤识别[J]. 建筑科学与工程学报, 2024, 41(3): 108-119.
QIN S Q, SU S, YANG R. Structural damage identification based on multi-label convolution neural network [J]. Journal of Architecture and Civil Engineering, 2024, 41(3): 108-119. (in Chinese)

[8] 贾然, 刘勇, 王立勇, 等. 特种车辆传动主轴运行载荷实时评估方法研究[J]. 湖南大学学报(自然科学版), 2024, 51(10): 58-66.
JIA R, LIU Y, WANG L Y, et al. Research on real-time evaluation methods for main shaft running load of special vehicle transmission[J]. Journal of Hunan University (Natural Sciences), 2024, 51(10): 58-66. (in Chinese)

[9] 马亚飞, 李诚, 何羽, 等. 基于小波散射卷积神经网络的结构损伤识别[J]. 振动与冲击, 2023, 42(14): 138-146.
MA Y F, LI C, HE Y, et al. Structural damage identification based on the wavelet scattering convolution neural network[J]. Journal of Vibration and Shock, 2023, 42(14): 138-146. (in Chinese)

[10] 刘玉驰, 蒋玉峰, 王树青, 等. 基于数据融合及残差卷积自编码器的结构损伤识别方法[J]. 振动与冲击, 2023, 42(4): 194-203.
LIU Y C, JIANG Y F, WANG S Q, et al. Data fusion and residual convolutional auto-encoder based structural damage identification [J]. Journal of Vibration and Shock, 2023, 42(4): 194-203. (in Chinese)

[11] 骆勇鹏, 王林堃, 廖飞宇, 等. 基于一维卷积神经网络的结构损伤识别[J]. 地震工程与工程振动, 2021, 41(4): 145-156.
LUO Y P, WANG L K, LIAO F Y, et al. Vibration-based structural damage identification by 1-dimensional convolutional neural network [J]. Earthquake Engineering and Engineering Dynamics, 2021, 41(4): 145-156. (in Chinese)

[12] YANG J H, PENG Z R. A new convolutional neural network-based framework and data construction method for structural damage identification considering sensor placement [J]. Measurement Science and Technology, 2023, 34(7): 075008.

[13] TRUONG T T, LEE J, NGUYEN-THOI T. Joint damage detection of structures with noisy data by an effective deep learning framework using autoencoder-convolutional gated recurrent unit [J]. Ocean Engineering, 2022, 243: 110142.

[14] LI T F, ZHOU Z, LI S N, et al. The emerging graph neural networks for intelligent fault diagnostics and prognostics: a guideline and a benchmark study [J]. Mechanical Systems and Signal Processing, 2022, 168: 108653.

[15] WU Z H, PAN S R, CHEN F W, et al. A comprehensive survey on graph neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 4-24.

[16] DANG V H, VU T C, NGUYEN B D, et al. Structural damage detection framework based on graph convolutional network directly using vibration data[J]. Structures, 2022, 38: 40-51.

[17] AGGELIS D G, PATSONAKIS C, STIROS S C. Vibration-based structural health monitoring of an old masonry arch bridge From automated OMA to damage detection [J]. Structural Control and Health Monitoring, 2014, 21(7): 918-940.

[18] WANG L, WANG W. Damage identification method based on frequency response function and support vector machine [J]. Mechanical Systems and Signal Processing, 2018, 99: 760-775.

[19] NGUYEN K H, KIM S Y, KANG S H. Enhanced damage detection of a structure using statistical damage index and artificial neural network [J]. Structural Control and Health Monitoring, 2019, 26(4): 23-37.

[20] 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 bridge structural damage detection based on convolutional and long short-term memory neural networks[J]. Journal of Railway Science and Engineering, 2020, 17(8): 1893-1902. (in Chinese)

[21] BAO Q, XU Y. Structural damage identification via modal parameters estimation based on cross-entropy optimization algorithm[J]. Structural Health Monitoring, 2021, 20(5): 12.

[22] 唐启智, 辛景舟, 周建庭, 等. 基于AR-GP模型的结构损伤识别方法[J]. 振动与冲击, 2021, 40(9): 102-109.
TANG Q Z, XIN J Z, ZHOU J T, et al. Structural damage identification method based on AR-GP model [J]. Journal of Vibration and Shock, 2021, 40(9): 102-109. (in Chinese)

[23] AVCI O, ABDELJABER O, KIRANYAZ S, et al. Wireless and real-time structural damage detection: a novel decentralized method for wireless sensor networks [J]. Journal of Sound and Vibration, 2018, 424: 158-172.

[24] 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, 2018, 275: 1308-1317.

[25] ABDELJABER O, AVCI O, KIRANYAZ S, et al. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks[J]. Journal of Sound and Vibration, 2017, 388: 154-170.

[26] AVCI O, ABDELJABER O, KIRANYAZ S, et al. Structural damage detection in real time: implementation of 1D convolutional neural networks for SHM applications [M]// Structural Health Monitoring & Damage Detection, Volume 7. Cham: Springer International Publishing, 2017: 49-54.

[27] KIRANYAZ S, INCE T, ABDELJABER O, et al. 1-D convolutional neural networks for signal processing applications [C]//ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Brighton, UK. IEEE, 2019: 8360-8364.

[28] AVCI O, ABDELJABER O, KIRANYAZ S, et al. Convolutional neural networks for real-time and wireless damage detection[M]// Dynamics of Civil Structures, Volume 2. Cham: Springer International Publishing, 2019: 129-136.

[29] LAURENS V D M, HINTON G. Visualizing data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9(2605): 2579-2605.