

DOI:10.11918/202502062

传统木结构复杂损伤的图神经网络诊断方法

葛子毅^{1,2}, 姜绍飞^{1,2}, 桂悦源^{1,2}, 宋华霖^{1,2}

(1. 福州大学 土木工程学院, 福州 350108; 2. 福建省土木工程多灾害防治重点实验室(福州大学), 福州 350108)

摘要: 针对传统木结构损伤识别算法在参数空间完备性、高维数据利用效率及局部-整体损伤联合诊断能力上的不足, 提出基于图神经网络(GNN)的多模态数据融合损伤识别方法。首先, 以结构节点加速度响应以及材性参数为输入, 融合传感器拓扑关系构建图结构数据, 实现节点间损伤特征的交互传递与协同识别。其次, 提出联合识别算法, 由局部损伤识别网络(LCGCN-LDI)与整体材性劣化网络(GCN-MPI)组成, 分别对节点进行损伤识别及对材性参数进行修正。最后, 试验验证联合识别算法的结构损伤综合识别精度达94.7%, 局部损伤准确率为97.6%, 自振频率预测误差由传统模型的28.9%降至9.4%。结果表明, 联合识别算法对传统木结构复杂损伤的识别效果优于传统算法, 具备较强的精度与鲁棒性。

关键词: 传统木结构; 结构健康监测; 损伤识别算法; 图神经网络

中图分类号: TU366.2

文献标志码: A

文章编号: 0367-6234(2026)02-0132-08

Graph neural network-based diagnosis of complex damages in traditional timber structures

GE Ziyi^{1,2}, JIANG Shaofei^{1,2}, GUI Yueyuan^{1,2}, SONG Hualin^{1,2}

(1. College of Civil Engineering, Fuzhou University, Fuzhou 350108, China; 2. Fujian Provincial Key Laboratory on Multi-Disasters Prevention and Mitigation in Civil Engineering(Fuzhou University), Fuzhou 350108, China)

Abstract: To address the limitations of traditional timber structure damage identification algorithms in parameter space completeness, utilization efficiency of high-dimensional data, and integrated local-global damage diagnosis capabilities, this paper proposes a multi-modal data fusion damage identification method based on a graph neural network (GNN). First, with the acceleration response of structural nodes and material parameters as inputs, the graph structure data is constructed by fusion of sensor topological relations to realize the interactive transmission and collaborative identification of damage features between nodes. Second, this paper proposes a joint recognition algorithm, which is composed of a local damage identification network (LCGCN-LDI) and a global material deterioration network (GCN-MPI), to identify the damage of nodes and correct the material property parameters respectively. Finally, experimental validation shows that the joint identification algorithm achieves an overall structural damage recognition accuracy of 94.7%, and a local damage detection accuracy of 97.6%; the prediction error of natural vibration frequency is reduced from 28.9% to 9.4%. The results show that the joint recognition algorithm outperforms traditional algorithms in identifying complex damage in traditional timber structures, exhibiting high accuracy and robustness.

Keywords: traditional timber structure; structural health monitoring; damage identification algorithm; graph neural network

传统木结构的保护与传承是文化遗产可持续管理的关键课题,但在长期服役过程中易受环境侵蚀、材料老化及灾害耦合作用影响,普遍存在柱脚腐蚀、榫卯脱榫等渐进性损伤^[1]。以汶川地震为例,古建筑因隐蔽损伤未及时预警导致的直接经济损失高达数亿元^[2-3],凸显传统人工巡检与静态模型分析方法在实时性与精准性上的严重不足^[4]。因此,发展

高精度、低干预的智能损伤识别技术,对保障木结构安全性、延续文化遗产生命力具有重要意义。

结构健康监测(structural health monitoring, SHM)技术通过神经网络建立结构响应与损伤的映射关系,已成为损伤识别领域的研究热点^[5]。现有方法如多层感知机(multilayer perceptron, MLP)、卷积神经网络(convolutional neural networks, CNN)等

收稿日期: 2025-02-28; 录用日期: 2025-04-07; 网络首发日期: 2025-07-25

网络首发地址: <https://link.cnki.net/urlid/23.1235.T.20250725.1653.002>

基金项目: 国家自然科学基金面上项目(52278295); 国家“十三五”重点研发计划(2020YFD1100403)

作者简介: 葛子毅(1991—),男,博士研究生; 姜绍飞(1969—),男,教授,博士生导师

通信作者: 姜绍飞,cejf@fzu.edu.cn

虽在整体振动特征提取上取得进展,但传统神经网络需将高维传感数据降维为固有频率、模态振型等全局特征^[6-7],导致局部损伤信息丢失;其次,传感器网络的空间拓扑关系未被有效建模,数据间复杂关联性遭忽视,严重制约多损伤协同识别能力^[8-9]。近年来,图神经网络(graph neural network, GNN)凭借其对非欧式空间关系的表征优势在故障诊断等领域展现出潜力,Li 等^[10]提出了一种基于图神经网络的机器学习框架,实现了高精度的全时空结构动态响应预测,且泛化能力强。Zhang 等^[11]提出了一种基于多任务深度学习模型,通过协同学习桥梁元素语义解析与表面缺陷分割任务,在提升分割精度的同时降低了计算成本。然而,上述方法通常利用模态信息对桥梁等结构进行损伤识别,近来学者通过长短时记忆(long short-term memory, LSTM)网络、时空差分图卷积神经网络开展了古代石拱桥损伤识别的相关研究^[11-13]。

针对当前传统木结构损伤识别中存在的不足,提出基于图神经网络的“局部-整体”双层次多损伤联合识别算法。以加速度响应及材性参数为输入,利用多模态数据融合机制,依据传感器位置与构件拓扑关系构建加权图数据,通过边权重量化节点间力学交互强度,增强损伤特征的空间传播建模能力,分别实现了结构局部的损伤定位与量化及整体材性参数修正。最后,通过开展单层双榫木框架环境激励试验,模拟多种复杂损伤耦合工况,通过对比数值仿真与实测数据,系统评估算法在稀疏传感条件下的鲁棒性与有效性。

1 图神经网络原理

1.1 图结构数据

图结构数据(graph data)是一种抽象化的数据表示形式,它采用了图论的理论框架,用于描述和模拟各种实际问题中的关系和结构。通用的图结构数据是一个五元组 $G(V, E, A, X, D)$ ^[14],其中,节点 V (vertex)代表实体或对象,边 E (edge)则表示这些实体之间的关联关系,根据边和节点的连接形式可定义邻接矩阵 $A_{N \times N}$,即

$$A_{N \times N} = \begin{cases} 1, & \text{if } v_i v_j \in E \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

邻接矩阵描述了图中节点之间的连接关系和权重,将节点表示为矩阵中的行和列,矩阵的元素表示节点之间是否有边连接; $X_{N \times F}$ 为节点的特征矩阵; $D_{N \times N}$ 度矩阵是一个对角矩阵,其对角线上的元素表示每个节点的度(连接边的数量)。一个常见的图结构数据如图 1 所示。




图 1 常见图结构数据形式及其组成

Fig. 1 Common graph structure data forms and their composition

图结构数据能有效表征传感器网络的物理拓扑关系。传统数据结构难以充分表征传感器位置与构件连接的空间关联,而图结构通过节点(传感器)、边(物理连接)及特征(传感数据)的映射,可精准描述整体拓扑特性。此外,节点特征可关联局部损伤信息,柱脚腐蚀与榫卯脱榫分别集中于柱底及连接处,故将传感器布设于此类关键区域,使节点位置直接关联损伤类型、位置与程度,形成局部损伤的拓扑映射。

1.2 图神经网络及其优势

Gori 等基于循环神经网络(recurrent neural network, RNN)首次提出了图神经网络(graph neural network, GNN)。此后,Bruna 进一步提出了图卷积网络(graph convolutional network, GCN),利用卷积神经网络(convolutional neural networks, CNN)分析图结构数据^[15],提取和表示图结构数据的特征,处理复杂的图结构数据,在学习图结构数据方面展现出强大的功能。其定义如下:

$$X^{(l+1)} = \sigma(\bar{D}^{-\frac{1}{2}} \bar{A} \bar{D}^{-\frac{1}{2}} X^{(l)} W^{(l)}) \quad (2)$$

式中: $X^{(l+1)}$ 表示下一层的输出特征; $X^{(l)}$ 表示本层的输入特征; $\bar{A} = A + I_N$ 为无向图的邻接矩阵加上每个节点自连接形成的单位矩阵, I_N 为单位矩阵; $\bar{D}_{ij} = \sum_j \bar{A}_{ij}$ 为图的度矩阵, $\bar{D}^{-\frac{1}{2}}$ 为其中的一个元素; $W^{(l)}$ 为可训练的参数矩阵; σ 为激活函数,采用 ReLU 函数。

与传统的深度学习方法相比,图神经网络可以接受根据结构形式构建的复杂图结构数据作为输入,能够优化变换所有属性(包括节点、边和全局属性),实现节点之间的互动与通信,同时有效利用图结构的形式信息而不改变其结构,具备排列不变性,更适用于处理复杂的识别任务。

2 整体-局部双层次多损伤联合识别方法

传统木结构损伤可分为局部与整体两类:局部损伤以柱脚腐蚀、榫卯脱榫为主;整体损伤源于木材材性离散性与性能劣化。基于课题组已开展的智能算法提升评估精度的研究基础^[16],提出图 2 所示的基于图神经网络(GNN)的多损伤联合识别方法。

通过动力激励获取结构振动响应,将原始传感数据重构为图结构,实现局部损伤等级分类与整体材性参数退化同步评估。该算法可从图数据中精准提取多损伤特征,支撑木结构健康状态的智能诊断。

接矩阵与节点振动特征),经全连接层输出 10 项木材材性参数,评估材料性能退化。网络采用 Adam 优化器(学习率 0.001)与交叉熵损失函数。

类似局部损伤识别网络,通过一层 GCN 层来聚合和传递图结构传感数据。输入为由图结构传感数据定义的邻接矩阵和节点的特征矩阵。邻接矩阵为有权图的邻接矩阵,输入的特征矩阵为振动响应。通过一次聚合操作对振动响应特征进行提取,在图卷积层后加入一个全连接层,输出 10 项木材的材性参数。该方法突破了高维数据利用与拓扑关系建模上的局限性,通过多模态数据融合直接保留原始高维传感数据,避免传统降维导致的局部信息丢失。同时,加权图结构依据传感器物理连接拓扑量化节点间力学交互强度,使信息传递过程中优先关注强关联区域,从而增强损伤特征的空间传播建模能力。

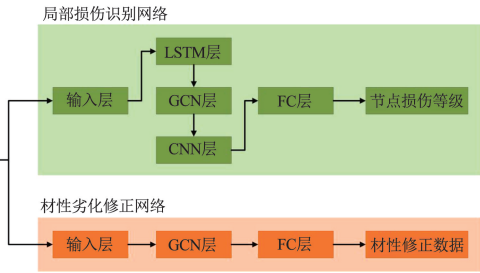


图 2 整体-局部多层次多损伤联合识别流程

Fig. 2 Process of global and local two-level multi-damage joint recognition algorithm

2.1 局部损伤识别算法 (LCGCN-LDI)

提出的联合算法结构如图 3 所示,其中,局部损伤识别算法 LCGCN-LDI (LSTM-CNN based graph convolutional networks for local damage identification) 根据本文环境激励实验传感器布设情况及图结构形式,提出的模型输入为 20×500 矩阵,表示 20 个传感器节点 (12 物理 + 8 虚拟) 的加速度时程数据 (500 Hz 采样 \times 5 s),输出为各节点对应的损伤等级 (0~3 级)。LSTM 层提取时序特征 (时间步长为 500),CNN 捕捉局部空间特征 (节点邻域窗口为 3),GCN 层通过加权邻接矩阵实现损伤特征交互传递。算法采用 Adam 优化方法进行参数的反向传播更新,学习率设置为 0.01,同时使用经典的交叉熵损失函数。

3 案例验证与分析

3.1 试验设计与物理实体建模

为验证数字孪生驱动的预知性运维技术对传统木结构多损伤场景的适应性,选取单层双榫传统木框架(图 4(a))作为试验对象。框架几何参数:木梁长 1.8 m,截面尺寸 60 mm \times 120 mm;木柱高 1.6 m,截面直径 75 mm。基于 GB/T 50165—2020《古建筑木结构维护与加固技术规范》,采用物理切削法模拟两类典型损伤。其中,柱脚腐蚀通过在木柱底部中心位置开槽,空洞横截面积按规范临界值 ($S_c = 0.6S_2, S_2 = 17\ 671.5\ \text{mm}^2$) 设定 4 档损伤等级 (0~3 级),如表 1 所示,对应安全、临界、危险状态。榫卯脱榫则通过切割梁端榫头长度 (10、20、30 mm),模拟拔榫损伤。通过组合两类损伤,共构建 19 组试验模型(见表 2)。




图 3 联合算法结构

Fig. 3 Joint algorithm structure

2.2 整体材性劣化识别算法 (GCN-MPI)

整体材性劣化识别算法 GCN-MPI(graph convolutional networks for material parameter identification) 是图 3 的第 2 个组成部分,通过单层 GCN 聚合图数据(邻

表 1 柱根内部损伤孔槽尺寸

Tab. 1 Dimensions of internal damage holes in column roots

损伤等级	损伤程度/%	孔槽半径/mm	孔槽深度/mm
0	0	0	0
1	40	47	200
2	60	58	200
3	80	67	200

如图 4(b)所示,为捕捉结构动力响应特征,在木框架关键节点(柱脚、榫卯连接处)布置 12 个加速度传感器(编号 1~12),并设置 8 个虚拟节点(编号 13~20)用于计算柱中响应。虚拟节点基于木构件轴向振动响应的连续性与平滑性假设,相邻真实传感器数据采用 3 次样条插值法生成^[21]。试验通过环境激励法模拟地震荷载,实时记录各节点加速

度时程曲线,并通过小波包变换(continuous wavelet transform, CWT)将原始信号转换为时频图,以增强局部损伤特征的时频分辨率。共获得 19 组实测数


据集,每组包含 12 通道 \times 500 Hz \times 5 s 的时域数据及对应时频特征,为后续虚拟孪生体动态更新提供高保真输入。

表 2 损伤组合


Tab.2 Damage combination table

试验分组	节点编号				试验分组	节点编号			
	1,2	3,4	5,6,7,8	9,10,11,12		1,2	3,4	5,6,7,8	9,10,11,12
1	0	1	0	1	11	0	3	0	3
2	0	1	0	3	12	0	3	1	3
3	0	1	0	2	13	0	3	2	3
4	0	1	1	2	14	1	2	1	2
5	0	1	1	3	15	1	2	1	3
6	0	1	2	3	16	1	2	2	3
7	0	2	0	3	17	1	3	1	3
8	0	2	2	3	18	1	3	2	3
9	0	2	0	2	19	2	3	2	3
10	0	2	1	2					

注:节点编号 1~4 为柱脚损伤工况,损伤等级 0~3 分别对应柱脚挖空半径 0、47、58、67 mm;节点编号 6~12 为榫卯节点损伤工况,损伤等级 0~3 分别对应脱榫距离 0、10、20、30 mm。



(a) 单层双榫木框架模型



(b) 传感器位置及图结构形式

图 4 试验模型及传感器布置

Fig.4 Experimental model and sensor layout

3.2 图结构传感数据集构建与更新

3.2.1 初始虚拟孪生体构建

为实现物理实体与虚拟模型的动态映射,基于单层双榫木框架的几何参数与材料特性,构建初始虚拟孪生体模型。模型构建分为两部分。其中,几何模型采用 ABAQUS 有限元软件建立三维实体模型,复现环境激励试验中的构件尺寸与连接关系,榫卯节点采用接触模拟非线性关系,柱脚与地面设置为固定接触模拟角钢的位移限制;物理模型则依据福建地区标准杉木的实测数据,定义材料本构参数。为增强模型泛化能力,对全部 10 项材料参数施加 $\pm 15\%$ 的随机扰动,覆盖木材服役过程中的性能退化范围。

完成初始孪生体模型构建后,基于拉丁超立方抽样(LHS)方法,在材料参数扰动区间内生成 50 组样本,结合 33 种损伤组合(柱脚腐蚀与榫卯脱榫),

共构建 1 650 组多损伤融合工况的有限元模型。通过 Python 脚本批量修改 ABAQUS 输入文件(.inp),自动化完成损伤几何切削与材性参数替换。其中,对未进行材料参数扰动及损伤识别的模型命名为原始模型 M_0 ,对预设损伤的模型按照损伤组合分别命名为 $M_1 \sim M_{19}$ 。

3.2.2 数据驱动的图神经网络建模与训练

虚拟孪生体与物理实体的高保真映射需对多源异构数据进行深度处理与特征提取,为实现多损伤融合工况下的高精度识别,基于本研究提出的联合网络,基于 1 650 组数值模拟数据与 19 组实测数据,对加速度时程信号进行高斯噪声注入($\mu = 0, \sigma = 0.1$)和滑动窗口滤波(窗长 50 点),以模拟实际监测环境并抑制高频干扰。同时,依据结构拓扑关系构建包含 20 个节点的图结构,定义榫卯连接边权重为 2、其他边为 1,以量化节点间力学关联强度。

基于传感器布置,提取各个模型计算结果中所有传感器所在位置点的加速度时程曲线,作为传感器获取的原始传感数据。为所有振动信号加入遵从均值为 0、标准差为 σ 的高斯分布的环境噪声,噪声数据形式如下:

$$Sn_i(t) = Sn_i(t) + N(0, \sigma)(t) \quad (3)$$

其中, $Sn_i(t)$ 为第 i 个传感器在 t 时刻进行标准化后的应变值,本文取 $\sigma = 0.1$ 。

为了验证基于原始传感数据和提取后数据在局部损伤识别上的差异,通过小波包连续小波变换 (continuous wavelet transform, CWT) 方法将各节点的原始振动数据转化为时频图,并根据简单木框架结构形式,构建了相应的图结构形式,如图 4(b) 所示。

图 4 显示了基于传感器数据的图结构构建过程。1~12 号节点分别对应图 4(a) 中的传感器位置,节点特征来源于原始振动数据,并包含结构损伤类型和程度信息。为减少传感器数量,在木柱四等分位置增设虚拟节点(13~20 号),其特征通过插值计算获得。节点间权重表示相互影响程度,榫卯连接处权重设为 2(图 4(b) 中粗边表示),其余为 1。基于原始振动数据和时频图分别构建图结构,两者区别仅在于节点特征。

为训练神经网络,建立特征与标签的样本对。局部损伤识别中,每组图数据生成 20 维标签向量,表示 1~20 号节点的损伤等级;整体材性劣化中,标签为 10 项材性数据。基于原始传感数据图和时频图数据,分别训练局部损伤识别算法(LCGCN-LDI),训练结果如图 5 所示。




图 5 基于原始传感数据图数据的训练结果

Fig. 5 Training results based on the original sensor data

以 5~12 号节点为例,该局部损伤识别网络对框架内不同单个节点损伤识别训练过程如图 6 所示。可以看出,随着模型的训练次数增加,训练损失逐渐减小。特别是在前 250 个批次的训练中,损失曲线下降速度较快。这表明在训练阶段,模型学到了丰富的特征信息,在训练中权重参数发生了显著变化。其次,在第 750 个批次时,损失曲线已接近平

稳状态,显示出了较为理想的收敛效果。这意味着预测值与实际值之间的差异非常小。最终,该算法在训练集上对 20 处位置的损伤识别综合准确率可达约 94.7%。




图 6 5~12 号节点训练结果

Fig. 6 Training results of nodes 5 to 12

3.3 模型效能对比与验证

为验证 GNNDIA 算法对实际工程场景的适应性,选取第 6、18 组损伤组合试验模型的实测数据进行损伤识别分析。试验模型涵盖柱脚腐蚀与榫卯脱榫的多损伤耦合工况,传感器网络采集的加速度时程数据经预处理后输入训练完成的 GNNDIA 模型。表 3 显示,柱脚腐蚀节点(1~4 号)识别准确率达 97.6%,其中,3 级腐蚀因刚度显著下降,频响特征明显,识别精度为 99.2%;而 1 级腐蚀因损伤轻微,特征模糊,精度略降为 93.1%。榫卯脱榫节点(5~12 号)整体识别精度为 85.3%,其中,30 mm 脱榫因几何形变剧烈,精度达 91.5%,而 10 mm 脱榫因信号扰动较大,精度降至 86.6%。进一步分析材料参数修正结果(表 4),模型预测的顺纹弹性模量 E_L 误差 $\leq 1.5\%$,横纹剪切模量 G_{RT} 误差 $\leq 3.8\%$,表明数据-机制融合修正方法可有效反映木材服役性能退化规律。

表 3 损伤识别准确率

Tab. 3 Damage identification accuracy

节点编号	准确率/%	节点编号	准确率/%
1	0.999	11	0.858
2	0.976	12	0.898
3	0.921	13	0.999
4	0.992	14	0.969
5	0.984	15	0.953
6	0.866	16	0.992
7	0.843	17	0.999
8	0.953	18	0.999
9	0.953	19	0.999
10	0.890	20	0.999

表 4 材性参数预测
Tab.4 Wood property parameter prediction

损伤组合	密度 $\rho / (10^{-10} \text{t} \cdot \text{mm}^{-3})$	顺纹弹性模量 E_L / MPa	横纹径向弹性模量 E_R / MPa	横纹弦向弹性模量 E_T / MPa	ν_{LR}	ν_{LT}	ν_{RT}	G_{LR} / MPa	G_{LT} / MPa	G_{RT} / MPa
6	3.34	7 310	406	849	0.438	0.413	0.214	442	571	136
8	3.42	7 317	401	881	0.428	0.431	0.228	451	539	134

注: ν_{LR} 、 ν_{LT} 、 ν_{RT} 分别为木材顺纹、横纹径向及横纹弦向的泊松比, G_{LR} 、 G_{LT} 、 G_{RT} 分别为木材顺纹、横纹径向及横纹弦向的剪切模量。其中, LR、LT、RT 分别为木材顺纹、横纹径向及横纹弦向构成的平面。

基于环境激励试验获取结构动力响应, 采用随机子空间法 (SSI) 提取前 3 阶自振频率, 如表 5 所示, 对比虚拟孪生体模型与原始有限元模型的预测精度。木框架一阶自振频率实测值为 2.531 Hz 与 2.431 Hz, 虚拟孪生体模型预测值分别为 2.622 Hz (误差 3.6%) 与 2.532 Hz (误差 4.2%), 显著优于

原始有限元模型 3.263 Hz。高阶频率预测误差进一步降低, 三阶频率实测值为 5.476 Hz, 虚拟孪生体预测误差为 9.4%, 而原始模型误差达 34.0%。误差降低归因于模型动态更新机制, 实时修正材料参数与几何损伤, 使虚拟孪生体刚度分布与物理实体一致, 从而提升动力特性保真度。

表 5 模态计算结果对比
Tab.5 Comparison of calculation results

模态阶数	实测自振频率/Hz		自振频率/Hz		误差/%		M_0 自振频率/Hz	误差/%	
	M_6	M_{18}	M_6	M_{18}	M_6	M_{18}		M_6	M_{18}
一阶	2.531	2.431	2.622	2.532	3.6	4.2	3.263	28.9	34.2
二阶	4.607	4.507	4.871	4.684	5.7	3.9	5.834	26.6	29.4
三阶	5.476	5.376	5.989	5.512	9.4	2.5	7.338	34.0	36.5

注: 原始模型为未损伤模型 M_0 , 虚拟孪生体模型依据损伤组合表 (表 2) 分别为 M_6 及 M_{18} 。

为证明所提 LCGCN-LDI 损伤识别算法的有效性, 在相同训练条件下开展了与其他算法结构的比较, 包括不同 GCN 层数的 LCGCN-LDI、基于时频图的 LCGCN-LDI、一般图神经网络 (GCN) 和损伤识别领域最常用的卷积神经网络 (CNN)。其中, 所有对比模型 (GCN、CNN、SVM 等) 均基于相同训练集 (1 650 组数值数据 + 19 组实测数据) 划分, 采用一致的硬件环境 (NVIDIA RTX 3090 GPU) 与优化器 (Adam), 其中 GCN 层数设为 2 层以匹配 LCGCN-LDI 的 GCN 模块深度, 学习率统一为 0.01。各算法的训练结果如图 7 所示。

试验表明, LCGCN-LDI 通过融合 LSTM 与 CNN 层, 较普通 GCN 网络显著提升识别精度与训练效率 (双层 GCN 最优)。基于时频图的方法因小波包变换 (CWT) 导致特征损失, 识别精度仅 78%, 验证了原始振动信号的优势。传统 CNN 算法受限于欧式数据处理, 无法建模节点关联与交互, 难以胜任多损伤识别任务。相较而言, LCGCN-LDI 利用图结构数据, 通过节点特征交互与拓扑信息融合, 显著增强多损伤特征提取能力。

3.4 基于预测模型的安全性评估

通过联合识别算法建立传统木结构框架的预测模型后, 依据《建筑抗震设计规范》和《古建筑木结构维护与加固技术标准》中抗震构造要求对 0.1g 及 0.22g 地震作用下预测模型是否满足抗震要求进行评估, 结果见表 6。可以看出, 预测模型在遭遇 7 度设防地震 (0.1g) 作用后, 各项评估结果均满足标准要求, 且与安全限值留有空间, 表明结构在多次遭遇地震后仍然符合 7 度地震抗震设防标准。最大层间位移角 1/107 小于 1/30 的抗震变形验算限制, 结构整体未出现倒塌及明显倾斜现象, 可认为加固后结构整体依然具有良好的承载力及变形能力, 满足现行抗震设防要求。

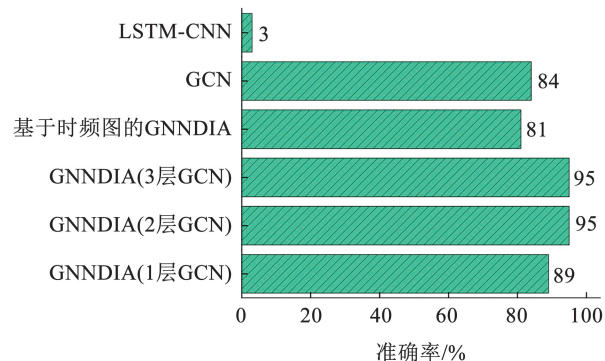


图 7 网络模型对比

Fig.7 Comparison of network models

表 6 基于标准的抗震性能评估

Tab. 6 Standard-based seismic performance evaluation

地震动	评估项目	鉴定标准	分析指标	状态评估
7 度设防地震 (0.1g)	柱础错位	$\rho_d \leq 1/10$	$\rho_d \approx 1/30$	合格
	榫卯节点	$\rho_l \leq 1/4$	$\rho_l \approx 1/21$	
	整体倾斜	$\Delta_1 \leq H/250$	$\Delta_1 \approx 0 \text{ mm}$	
	层间位移角	$\theta_p \leq 1/30$	$\theta_p \approx 1/107$	
7 度罕遇地震 (0.22g)	柱础错位	$\rho_d \leq 1/10$	$\rho_d \approx 1/16$	合格
	榫卯节点	$\rho_l \leq 1/4$	$\rho_l \approx 1/10$	
	整体倾斜	$\Delta_1 \leq H/250$	$\Delta_1 \approx 0.586 \text{ mm}$	
	层间位移角	$\theta_p \leq 1/30$	$\theta_p \approx 1/79$	

注: ρ_d 为错位量与柱径之比, ρ_l 为拔出距离与榫头长度之比, Δ_1 为构架平面内倾斜量, θ_p 为木构架层间位移角限值。

当试验模型遭遇 7 度罕遇地震 (0.22g) 作用后, 由评估结果可以看出, 虽然各项指标有所上升, 但仍满足抗震构造设防要求。最大层间位移角达 1/79, 整体倾斜情况较 0.1g 震后增加, 但倾角仍远小于限值。柱础错位与节点拔榫距离增大, 分别达 1/16 (4.7 mm) 和 1/10 (6 mm)。以上指标可以认为预测模型在 0.22g 震后, 仍满足 7 度罕遇地震下木结构抗震设防构造要求。

4 结 论

1) 基于加权图结构的损伤表征方法突破了传统高维数据降维的局限性, 通过量化传感器节点间的力学交互强度, 实现了局部损伤特征与全局拓扑关系的协同建模。试验表明, 该方法综合识别精度达 94.7%, 局部损伤准确率为 97.6%, 较传统特征提取方法提升 91.7%。

2) 提出的“局部-整体”双层次联合识别算法 (LCGCN-LDI 与 GCN-MPI) 通过多模态数据融合, 实现了局部损伤等级分类与整体材性参数退化的同步更新。其中, 自振频率预测误差由传统模型的 28.9% 降至 9.4%, 验证了算法在复杂损伤耦合工况下的鲁棒性与高精度。

3) 通过虚拟孪生体模型与实测数据融合, 显著提升了结构动力特性保真度。在 7 度罕遇地震 (0.22g) 作用下, 预测模型层间位移角 (1/79)、柱础错位 (1/16) 等指标均满足现行抗震规范要求。

需指出的是, 提出的“整体材性劣化”表征材料参数的全局统计均值退化趋势, 尽管局部退化存在差异, 但该指标可为宏观判据, 与局部损伤诊断网络 (LCGCN-LDI) 协同使用, 兼顾整体性能与构件精细化评估需求。此外, 当前方法对极端损伤 (如柱脚

腐蚀等级超过预设阈值) 及非预设损伤类型 (如木材裂缝、虫蛀) 的适应性仍需进一步验证。未来研究将结合迁移学习与动态图结构优化算法, 探索未知损伤类型的在线识别能力, 同时融合材料微观劣化机制模型, 提升复杂异质环境下的评估鲁棒性。

参考文献

- [1] 谢启芳, 郑培君, 向伟, 等. 残损古建筑木结构单向直榫榫卯节点抗震性能试验研究[J]. 建筑结构学报, 2014, 35(11): 143
XIE Qifang, ZHENG Peijun, XIANG Wei, et al. Experimental study on seismic behavior of damage straight mortise-tenon joints of ancient timber buildings[J]. Journal of Building Structures, 2014, 35(11): 143. DOI:10.14006/j.jzjgxb.2014.11.018
- [2] 潘毅, 唐丽娜, 王慧琴, 等. 芦山 7.0 级地震古建筑震害调查分析[J]. 地震工程与工程振动, 2014, 34(1): 140
PAN Yi, TANG Lina, WANG Huiqin, et al. Investigation and analysis of damage to ancient buildings in Lushan Ms 7.0 earthquake [J]. Earthquake Engineering and Engineering Dynamics, 2014, 34(1): 140. DOI:10.13197/j.eeev.2014.01.140.pany.018
- [3] 谢启芳, 薛建阳, 赵鸿铁. 汶川地震中古建筑的震害调查与启示[J]. 建筑结构学报, 2010, 31(增刊 2): 18
XIE Qifang, XUE Jianyang, ZHAO Hongtie. Seismic damage investigation and analysis of ancient buildings in Wenchuan earthquake [J]. Journal of Building Structures, 201031(Sup. 2): 18
- [4] 赵一男, 公茂盛, 杨游. 结构损伤识别方法研究综述[J]. 世界地震工程, 2020, 36(2): 73
ZHAO Yinan, GONG Maosheng, YANG You. A review of structural damage identification methods [J]. World Earthquake Engineering, 2020, 36(2): 73
- [5] 周鹏飞, 张雍. 基于改进多目标粒子群算法的码头结构传感器优化布置[J]. 振动与冲击, 2025, 44(1): 243
ZHOU Pengfei, ZHANG Yong. Wharf structural optimal sensor placement based on IMOPSO algorithm [J]. Journal of Vibration and Shock, 2025, 44(1): 243. DOI:10.13465/j.cnki.jvs.2025.01.024
- [6] 姚姝, 张辉东, 周晓洁, 等. 空间单层网壳结构损伤杆件位置识别试验[J]. 哈尔滨工业大学学报, 2019, 51(6): 116
YAO Shu, ZHANG Huidong, ZHOU Xiaojie, et al. Test on member damage location identification of single-layer reticulated shell [J]. Journal of Harbin Institute of Technology, 2019, 51(6): 116. DOI: 10.11918/j.issn.0367-6234.201809195
- [7] 姜立春, 邵凡. 基于损伤模式识别法的复杂采空区群中薄弱单元甄别[J]. 哈尔滨工业大学学报, 2023, 55(7): 87
JIANG Lichun, SHAO Fan. Identification of weak units in complex goaf group based on damage mode recognition method [J]. Journal of Harbin Institute of Technology, 2023, 55(7): 87. DOI:10.11918/202111071
- [8] 丁自豪, 雷川鹤, 郑史雄, 等. 锈蚀 RC 柱水平抗力的机器学习预测及参数敏感性分析[J]. 哈尔滨工业大学学报, 2024, 56(11): 80
DING Zihao, LEI Chuanhe, ZHENG Shixiong, et al. Machine learning prediction and parameter sensitivity analysis for lateral

- capacity of corroded RC columns[J]. Journal of Harbin Institute of Technology, 2024, 56(11): 80. DOI:10.11918/202310012
- [9] GAO Xinyu, WANG Zhijie, YANG Feng, et al. Benchmarking robustness of AI-enabled multi-sensor fusion systems: challenges and opportunities [C]//Proceedings of the 31st ACM Joint European Software Engineering Conference and Symposium on the Foundations of Software Engineering. [S. l.]: ACM, 2023: 871. DOI: 10.1145/3611643.3616278
- [10] LI Qilin, WANG Zitong, LING Li, et al. Machine learning prediction of structural dynamic responses using graph neural networks[J]. Computers & Structures, 2023, 289: 107188. DOI: 10.1016/j.compstruc.2023.107188
- [11] ZHANG Chenyu, KARIM M M, QIN Ruwen. A multitask deep learning model for parsing bridge elements and segmenting defect in bridge inspection images [J]. Transportation Research Record, 2023, 2677(7): 693. DOI:10.1177/03611981231155418
- [12] 马开臣, 许杨铭, 江林松, 等. 基于长短期记忆神经网络的钢桥面板疲劳损伤预后[J]. 工业建筑, 2025, 55(7): 109
MA Kaichen, XU Yangming, JIANG Linsong, et al. Prognosis of fatigue damage in steel bridge decks based on long short-term memory neural networks [J]. Industrial Construction, 2025, 55(7): 109
- [13] 张承文, 淳庆, 马宇坤, 等. 基于时空差分图卷积神经网络的古代石拱桥损伤识别研究[J]. 东南大学学报(自然科学版), 2025, 55(2): 370
ZHANG Chengwen, CHUN Qing, MA Yukun, et al. Research on damage detection of ancient stone arch bridges based on spatio-temporal difference graph convolutional neural networks[J]. Journal of Southeast University (Natural Science Edition), 2025, 55(2): 370. DOI: 10.3969/j.issn.1001-0505.2025.02.007
- [14] BATTAGLIA P W, HAMRICK J B, BAPST V, et al. Relational inductive biases, deep learning, and graph networks[J]. arXiv, 2018. DOI:10.48550/arXiv.1806.01261
- [15] MICHAEL D, XAVIER B, PIERRE V. Convolutional neural networks on graphs with fast localized spectral filtering [J]. Advances in Neural Information Processing Systems, 2016(12): 29. DOI:10.48550/arXiv.1606.09375
- [16] 姜绍飞, 宋华霖, 黄晓栏, 等. 数字孪生驱动的结构智能安全评估方法[J]. 土木工程学报, 2025, 58(11): 42
JIANG Shaofei, SONG Hualin, HUANG Xiaolan, et al. Digital twin driven intelligent assessment method for structural safety [J]. China Civil Engineering Journal, 2025, 58(11): 42

(编辑 刘 彤)

封面图片说明

封面图片来自本期论文“大跨 CFST 拱桥考虑成拱过程的地震响应分析方法”, 是大跨 CFST 拱桥结构与钢管混凝土材料特性的示意图。大跨 CFST 拱桥是中国西南山区交通网络的重要桥型, 对缩短中国西南山区的交通距离起到了重要作用。从整体上看, 展示了钢管混凝土拱桥的结构与分析示意图, 包含了计算中重点分析的 CFST 主拱圈、横撑等结构构件, 在分析中主要采用带塑性铰的纤维框架单元进行动力计算。示意图中的材料特性本构图展示了在计算中如何对材料非线性的影响进行考量, 钢管和混凝土的本构特性不同, 其结合在一起的特性会对桥梁结构产生特殊的受力机制影响。

(图文提供: 徐粒寒, 徐略勤, 周建庭, 袁茂均。重庆交通大学土木工程学院)