

## 基于改进图卷积神经网络的地铁转向架 故障诊断方法

刘凯<sup>1</sup>, 王红波<sup>1</sup>, 韩如冰<sup>1</sup>, 刘俊<sup>2</sup>, 宫岛<sup>3,4</sup>, 周劲松<sup>3,4</sup>, 门志辉<sup>3,4</sup>

(1. 南京中车浦镇城轨车辆有限责任公司, 江苏南京 210031; 2. 中车南京浦镇车辆有限公司, 江苏南京 210031;

3. 同济大学交通学院, 上海 201804; 4. 同济大学上海市轨道交通结构耐久与系统安全重点实验室, 上海 201804)

**摘要:**为提高地铁列车转向架故障诊断的准确率与鲁棒性,提出一种融合卷积神经网络(CNN)与改进图卷积网络(GCN)的多传感器信息融合诊断方法。首先对各传感器采集的振动信号进行连续小波变换,生成时频图;其次利用5层CNN对各通道时频图进行特征提取,并将每个传感器视为图结构中的一个节点,提取的特征作为节点属性输入GCN;然后为克服传统GCN中邻接矩阵固定、无法反映节点间动态关联的缺陷,设计多层感知机(MLP)根据节点特征自适应更新邻接权重,实现动态图卷积;最后通过两层GCN与分类头完成故障识别。实验表明,所提方法平均诊断准确率达99.4%,在部分工况下最高可达100%,显著优于单通道CNN及CNN-LSTM、CNN-GRU、CNN-Transformer、MSSCNN等现有模型。混淆矩阵与t-SNE可视化结果显示,各类故障特征聚类清晰,错分率低于1%。研究证明,该方法在多工况、多故障模式下均具备优异的诊断精度与稳定性,为地铁转向架智能运维提供了可靠技术支持。

**关键词:**转向架;故障诊断;卷积神经网络;图神经网络

中图分类号:U279.3

文献标志码:A

## A Fault Diagnosis Method for Metro Bogie Based on an Improved Graph Convolutional Neural Network

Liu Kai<sup>1</sup>, Wang Hongbo<sup>1</sup>, Han Rubing<sup>1</sup>, Liu Jun<sup>2</sup>, Gong Dao<sup>3,4</sup>, Zhou Jinsong<sup>3,4</sup>, Men Zhihui<sup>3,4</sup>

(1. CRRC Nanjing Puzhen Rail Transport Co., Ltd., Nanjing 210031; 2. CRRC Nanjing Puzhen Co., Ltd., Nanjing 210031;

3. College of Transportation, Tongji University, Shanghai 201804; 4. Shanghai Key Laboratory of Rail Infrastructure

Durability and System Safety, Tongji University, Shanghai 201804)

**Abstract:** To improve the accuracy and robustness of fault diagnosis for metro train bogie, a multi-sensor information fusion diagnosis method combining convolutional neural network (CNN) and an improved graph convolutional network (GCN) is proposed. First, vibration signals collected from multiple sensors are transformed into time-frequency maps using continuous wavelet transform (CWT). Then, a 5-layer CNN is employed to extract features from each channel's time-frequency map, where each sensor is treated as a node in a graph and the extracted features serve as node attributes for the GCN. To overcome the limitation of traditional GCNs with fixed adjacency matrices that fail to reflect dynamic relationships among nodes, a multilayer perceptron (MLP) is de-

收稿日期:2026-01-19

基金项目:国家自然科学基金项目(52375115);上海东方英才计划项目(QNKJ2025010)

signed to adaptively update adjacency weights based on node features, enabling dynamic graph convolution. Finally, fault classification is performed through two GCN layers followed by a classification head. Experiments demonstrate that the proposed method achieves an average diagnostic accuracy of 99.3%, and the maximum can reach 100% under some working conditions, significantly outperforming existing models such as single-channel CNN, CNN-LSTM, CNN-GRU, CNN-Transformer, and MSSCNN. The confusion matrix and t-SNE visualization results show clearly clustered fault features with a misclassification rate below 1%. The study shows that the proposed method maintains excellent diagnostic accuracy and stability under multiple operating conditions and fault modes, providing reliable technical support for the intelligent operation and maintenance of metro bogie systems.

**Key words:** bogies; fault diagnosis; convolutional neural networks; graph neural networks

列车转向架作为车辆走行部的核心承载结构,直接承担列车的牵引、制动、导向及载荷传递等关键功能,其运行状态对列车行车安全性、平稳性与可靠性具有决定性影响。因此,对转向架关键部件实施有效的状态监测与故障诊断,是保障城市轨道交通系统安全运行的重要前提<sup>[1-2]</sup>。随着列车运行速度和服役强度的不断提高,转向架长期处于复杂载荷与多变工况环境中,其故障形式呈现出隐蔽性强、演化过程复杂等特点,传统基于经验或单一特征的诊断方法已难以满足工程应用需求。

近年来,随着信号处理与智能诊断技术的发展,学者们围绕转向架及其关键部件开展了大量研究工作。Men等<sup>[3]</sup>通过引入改进的经验模态分解方法并结合支持向量机,实现了齿轮箱故障的高精度识别;李刚等<sup>[4]</sup>将格拉姆角场与卷积神经网络(CNN)相结合,用于高速列车横向减振器故障诊断;岑潮宇等<sup>[5]</sup>基于自适应噪声完备集合经验模态分解提取信号特征,并结合核极限学习机实现了抗蛇行减振器的故障类型识别;门志辉等<sup>[6]</sup>采用格拉姆角场域双通道采样方式,并引入Transformer网络,实现了牵引传动系统的高精度故障诊断。此外,针对实际工程中样本分布不均衡和数据匮乏问题,Men等<sup>[7]</sup>利用改进生成对抗网络扩充小样本数据集,提升了铁路货车轴承的诊断性能;彭刘禹等<sup>[8]</sup>提出了一种广义精细复合多尺度波动离散熵特征提取方法,并结合CNN实现了轮对轴承故障诊断;Men等<sup>[9]</sup>通过风格迁移技术构建轴承故障孪生数据

源,有效缓解了数据缺失对模型性能的影响。

尽管上述研究在特征提取方法和智能诊断模型方面取得了显著进展,但大多数方法仍主要基于单一传感器或简单特征融合策略,难以充分刻画转向架系统中多传感器之间的潜在关联关系。随着传感器布置数量的增加,转向架运行数据逐渐呈现出多源、多尺度和强异构的特点,单一传感器信息往往难以全面反映系统真实运行状态,进而限制了故障诊断精度和模型泛化能力。

针对上述问题,本文提出一种基于多传感器信息融合的转向架故障诊断方法。首先,利用连续小波变换(CWT)对各传感器振动信号进行时频分析,提取具有良好时频分辨率的特征表示;其次,通过卷积神经网络对各通道时频特征进行深度特征提取;然后,将不同传感器视为图结构中的节点,并将提取的特征作为节点属性输入图卷积神经网络(GCN),以实现多传感器信息的协同建模;接着针对传统GCN中邻接矩阵固定、难以反映节点间动态关联的问题,引入多层感知机(MLP)基于节点特征自适应构建动态图邻接矩阵,从而刻画传感器之间的动态关联关系;最后,通过迭代训练实现对转向架故障模式的智能识别与诊断。

## 1 基础理论

### 1.1 连续小波变换

小波变换是一种时频分析方法,与傅里叶变换不同,它不仅能反映信号在频率域上的特征,还能

反映其在时间域上的局部特征。小波变换通过一组伸缩和平移的小波基函数去匹配信号,从而得到信号在不同尺度(频率)和时间位置上的特征<sup>[10]</sup>。

对信号  $x(t)$ , 其连续小波变换定义为

$$W(a,b) = \int_{-\infty}^{+\infty} x(t)\psi_{a,b}(t)dt \quad (1)$$

式中:  $a$  为尺度因子(scale), 控制小波的伸缩;  $b$  为平移因子(translation), 控制小波的时间位置;  $\psi_{a,b}(t)$  为小波基函数, 由母小波  $\psi(t)$  生成

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}}\psi\left(\frac{t-b}{a}\right) \quad (2)$$

本文母小波选用Morlet小波, 该小波具有良好的时频局部化特性, 能够有效刻画故障信号中瞬态冲击与非平稳特征, 因而被广泛应用于旋转机械与轨道交通装备的故障诊断研究中。在尺度参数设置方面, 尺度范围设定为  $a \in [1, 128]$ 。并采用线性等间隔取值方式, 共选取128个尺度。尺度与伪频率之间的对应关系由小波中心频率确定, 从而覆盖信号的主要频带范围, 确保低频结构特征与高频冲击特征均能够被有效表征。

## 1.2 卷积神经网络

CNN是一种典型的深度学习模型, 具有强大的特征自动提取能力。它通过在输入数据上使用卷积核进行局部连接和权值共享, 能够有效捕捉空间或时间上的局部相关特征<sup>[11]</sup>。CNN的结构通常由卷积层、激活层、池化层和全连接层组成: 卷积层用于提取不同层次的特征, 激活层引入非线性增强表达能力, 池化层用于降低数据维度并提高模型的平移不变性, 全连接层则整合前面提取到的特征完成分类或回归任务。

## 1.3 图卷积神经网络

GCN是一种专为图结构数据设计的神经网络模型, 用于在节点、边和图层面进行特征学习。与传统卷积神经网络在规则网格上进行局部卷积不同, GCN通过图的邻接关系在非欧几里得空间上实现信息传播与特征聚合<sup>[12]</sup>。

对于一个图  $G=(V,E)$ , 其中  $V$  为节点集合,  $E$  为边集合, 节点特征矩阵为  $X \in \mathbb{R}^{N \times d}$ , 邻接矩阵为  $A \in \mathbb{R}^{N \times N}$ 。

GCN的单层传播规则可表示为

$$H^{l+1} = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^l W^l) \quad (3)$$

式中:  $\tilde{A} = A + I_N$  为邻接矩阵加上自连接;  $\tilde{D}_{ii} =$

$\sum_j \tilde{A}_{ij}$ ,  $\tilde{D}$  为对应的度矩阵;  $H^l$  为第  $l$  层的节点表示;  $W^l$  为该层的可训练权重;  $\sigma(\cdot)$  为非线性激活函数(如 ReLU)。

## 1.4 改进图卷积神经网络

假设系统布置有  $S$  个传感器, 每个传感器采集到的原始信号经连续小波变换后, 表示为二维图像

$$X_s^n \in \mathbb{R}^{H \times W}, \quad s=1, 2, \dots, S \quad (4)$$

对于第  $n$  个样本, 其多传感器输入表示为

$$\mathcal{X}^n = \{X_1^n, X_2^n, \dots, X_S^n\} \quad (5)$$

为保证不同传感器特征的可比性, 采用共享参数的深层卷积神经网络  $f_{\text{CNN}}(\cdot; \theta_c)$  对每个传感器进行特征映射

$$h_s^n = f_{\text{CNN}}(X_s^n; \theta_c), \quad h_s^n \in \mathbb{R}^f \quad (6)$$

将所有传感器特征堆叠, 可得样本级节点特征矩阵为

$$H^n = \begin{bmatrix} (h_1^n)^T \\ (h_2^n)^T \\ \vdots \\ (h_S^n)^T \end{bmatrix} \in \mathbb{R}^{S \times f} \quad (7)$$

不同于传统GCN采用固定邻接矩阵  $A$ , 本文引入特征驱动的动态邻接学习机制。对任意传感器节点对  $(i,j)$ , 定义其邻接权重为

$$a_{ij}^n = g_\phi([\mathbf{h}_i^n \parallel \mathbf{h}_j^n]), \quad a_{ij}^n \in (0, 1) \quad (8)$$

式中:  $[\cdot \parallel \cdot]$  为向量拼接;  $g_\phi(\cdot)$  为可学习的非线性映射函数(MLP);  $a_{ij}^n \in (0, 1)$ 。

为满足无向图假设, 对邻接矩阵进行对称化处理

$$\tilde{a}_{ij}^n = \frac{a_{ij}^n + a_{ji}^n}{2} \quad (9)$$

同时引入自环, 得到最终邻接矩阵为

$$\hat{A}^n = \tilde{A}^n + I \quad (10)$$

该设计确保节点自身特征在信息传播过程中不被削弱。

定义样本级度矩阵为

$$D_{ii}^n = \sum_{j=1}^S \tilde{a}_{ij}^n \quad (11)$$

采用对称归一化形式

$$\hat{A}^n = (D^n)^{-\frac{1}{2}} \tilde{A}^n (D^n)^{-\frac{1}{2}} \quad (12)$$

第  $l$  层图卷积的传播过程定义为

$$\mathbf{H}^{l+1} = \sigma(\hat{\mathbf{A}}^n \mathbf{H}^l \mathbf{W}^l) \quad (13)$$

式中： $\mathbf{H}^0$  (GCN初始量) =  $\mathbf{H}^n$ , (第  $n$  个样本的 CNN 特征)  $l=0, 1, \dots, L-1$ ;  $\mathbf{W}^l$  为第  $l$  层可学习权重;  $\sigma(\cdot)$  为非线性激活函数。

## 2 研究方法整体概述

本文所提出的转向架故障诊断方法整体流程如图1所示,主要包括信号预处理、时-频特征提取、特征表示学习、多传感器关联建模以及故障识别5个步骤。首先,对各传感器采集的原始振动信号进行统一

切分处理,以保证不同传感器在时间尺度上的同步性和样本一致性。在此基础上,采用CWT对切分后的信号进行时-频分析,将一维时间序列信号映射为二维时-频特征图,从而同时表征信号在时间域和频率域上的局部特性,为后续深度特征学习提供高分辨率的输入数据。随后,针对每个传感器通道对应的时-频特征图,构建CNN进行特征提取。CNN通过多层卷积和非线性映射,能够自动学习时-频图中与故障状态相关的判别性特征,并有效抑制噪声干扰。各传感器通道经CNN提取后的高维特征向量作为对应节点的特征表示,用于后续多传感器信息融合建模。

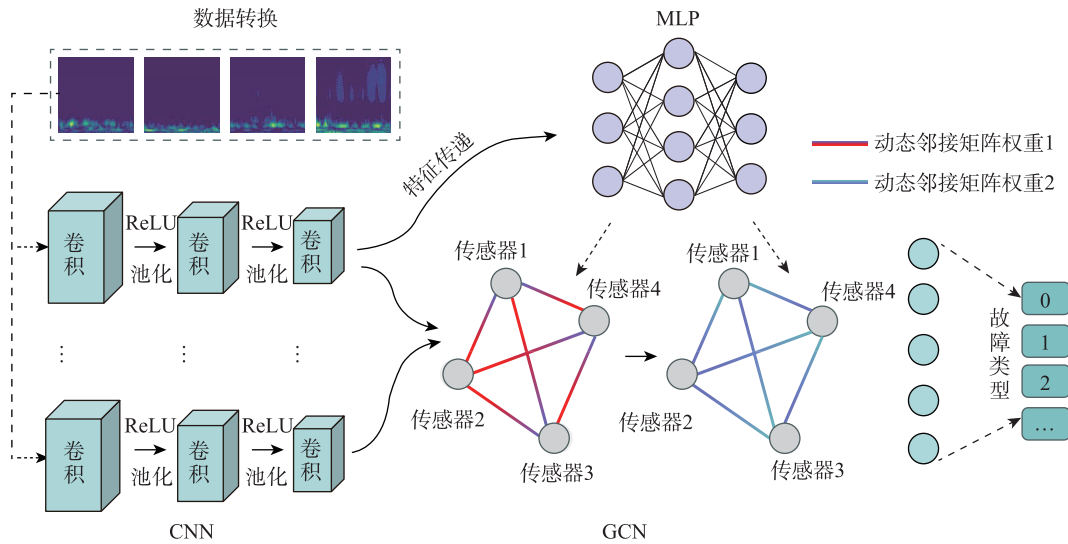


图1 研究方法的流程示意图  
Fig. 1 Flowchart of the research methodology

在多传感器关联建模阶段,本文将不同传感器视为图1结构中的节点,构建基于GCN的特征融合框架。为克服传统GCN依赖固定邻接矩阵、难以反映传感器间动态关系的问题,引入MLP对节点特征进行映射,根据节点间特征相似性自适应学习邻接权重,从而动态构建邻接矩阵,实现传感器间关联关系的自适应建模。通过动态图卷积操作,不同传感器节点的信息在图结构中进行传播与聚合,充分挖掘多源数据之间的潜在关联特征。

最后,经过多层GCN融合后的全局特征输入至分类模块,通过迭代训练完成转向架不同故障模式的识别与判别。该方法在特征提取与关系建模两个层面实现了多传感器信息的深度融合,为复杂工况下转向架故障的准确诊断提供了有效支撑。

表1为改进GCN模型的参数设置情况。

## 3 试验验证

实验数据来源于北京交通大学转向架故障数据集。该数据集基于真实地铁车辆转向架按比例缩放构建,能够模拟典型运行工况,是轨道交通故障诊断领域的重要公开数据集,涵盖驱动齿轮箱、轴箱轴承、牵引电机等多种单一与复合故障。实验平台<sup>[13]</sup>如图2所示。采样频率统一为64 kHz,电机轴承型号为SKF 6205-2RSH,主动齿轮的轴向轴承型号为HRB 32305,轴箱轴承型号为HRB352213。

实验选取了部分振动数据进行验证。采集信号经小波变换获得时频特征图,构建模型训练数据库,包含电机轴承故障、轴弯曲等多种故障模式,统

表1 改进GCN模型的超参数设置

Tab.1 Hyperparameter settings of the improved GCN model

层编号	网络结构	卷积核/池化	输出通道	输出尺寸
Conv1	Conv+BN+ReLU+MaxPool	3×3/2×2	32	32×32
Conv2	Conv+BN+ReLU+MaxPool	3×3/2×2	64	16×16
Conv3	Conv+BN+ReLU+MaxPool	3×3/2×2	128	8×8
Conv4	Conv+BN+ReLU+MaxPool	3×3/2×2	128	4×4
Conv5	Conv+BN+ReLU+GAP	3×3/自适应平均池化	88	1×1
GCN-1	GCNConv+ReLU	-	128	-
GCN-2	GCNConv	-	256	-
FC1	Linear+ReLU	Dropout(p=0.2)	128	-
FC2	Linear	-	类别数	-




图2 北京交大转向架实验台<sup>[13]</sup>

Fig. 2 Beijing Jiaotong University bogie test bench<sup>[13]</sup>

—以0~9标签进行标注,图3为部分具体实物图。数据按4:1比例划分为训练集与测试集,具体的故障信息以及所对应的数据划分情况及见表2、表3所示。

模型采用Python+PyTorch实现,学习率设为0.000 1,批次为32,迭代100轮。运行环境为Intel i5-13th处理器、NVIDIA RTX 4060Ti显卡、1TB RAM、Windows 11系统。同时使用单通道CNN作为对比模型。如图4所示,两种算法的迭代曲线表明,相较于单通道CNN,本文方法的训练过程更加稳定、收敛性更佳。此外,为验证该方法相较于现有模型的优势,本文与CNN-LSTM、CNN-Transformer、MSSCNN方法进行了对比分析,CNN-LSTM与CNN-Transformer模型参数与本文所用CNN参数基本一致,LSTM的隐藏单元数设置为128,输出序列中最后一个时间步的隐藏状态作为全




图3 故障实物图<sup>[13]</sup>

Fig. 3 Fault physical diagram<sup>[13]</sup>

表2 故障模式类别

Tab.2 Failure mode category


标签	故障模式
0	轴箱轴承内圈故障+轴承内圈故障+轴弯曲
1	齿轮箱轴承内圈故障+轴弯曲
2	双侧轴箱轴承内圈故障+齿轮箱缺齿+轴弯曲
3	双侧轴箱轴承内圈故障+轴弯曲
4	齿轮箱缺齿+轴弯曲
5	轴箱轴承内圈故障+轴弯曲
6	轴弯曲
7	电机轴承故障+齿轮箱轴承内圈故障
8	电机轴承故障+齿轮箱缺齿
9	电机轴承故障+轴箱轴承内圈故障

表3 数据划分情况


Tab.3 Data division situation

电机转速/横向负载	训练样本数	测试样本数
20 Hz/0	160	40
40 Hz/0	160	40
60 Hz/0	160	40
20 Hz/+10 kN	160	40
40 Hz/+10 kN	160	40
60 Hz/+10 kN	160	40
20 Hz/-10 kN	160	40
40 Hz/-10 kN	160	40
60 Hz/-10 kN	160	40

局特征表示。Transformer 编码器采用2层结构,注意力头数为8,通过平均池化方式融合所有Token的全局信息。MSSCNN的具体参数参考文献[14]。诊断结果如表4所示,图5为其所对应的柱状图。从表4和图5可以看出,本文方法在诊断精度上表现最优,进一步证明了模型的有效性。此外,为进



(a) 本文算法



(b) 单通道CNN

图4 不同算法的迭代曲线对比  
Fig. 4 Comparison of iterative curves of different algorithms

一步验证实验结果的统计显著性,在表3中补充开展了t检验,并计算了相应的p值。统计分析结果表明,各对比方法对应的p值均小于0.05,说明所提出

表4 各工况下不同传感器通道的诊断准确率

Tab.4 The diagnostic accuracy of different sensor channels under various working conditions

工况	传感器1	传感器2	传感器3	传感器4
工况1	93.36%±2.101 4%	93.28%±0.674 6%	99.12%±0.253 0%	74.72%±1.652 5%
工况2	97.28%±0.674 6%	98.56%±0.631 0%	94.72%±1.317 2%	79.04%±4.986 0%
工况3	88.64%±1.760 8%	99.68%±0.772 9%	88.56%±8.399 4%	90.24%±2.408 9%
工况4	92.48%±3.640 8%	90.56%±2.661 3%	95.20%±5.938 9%	76.80%±0.843 3%
工况5	96.80%±1.460 6%	93.68%±3.645 6%	94.16%±1.309 1%	78.88%±4.963 2%
工况6	98.80%±1.015 4%	99.28%±0.454 1%	97.44%±0.506 0%	67.12%±1.327 1%
工况7	91.52%±0.559 4%	88.16%±1.401 0%	97.52%±1.096 3%	80.48%±1.370 2%
工况8	94.40%±0.533 3%	98.48%±0.590 3%	98.32%±0.253 0%	80.88%±5.496 8%
工况9	92.48%±1.317 2%	99.76%±0.540 0%	90.48%±9.684 4%	89.76%±0.826 2%

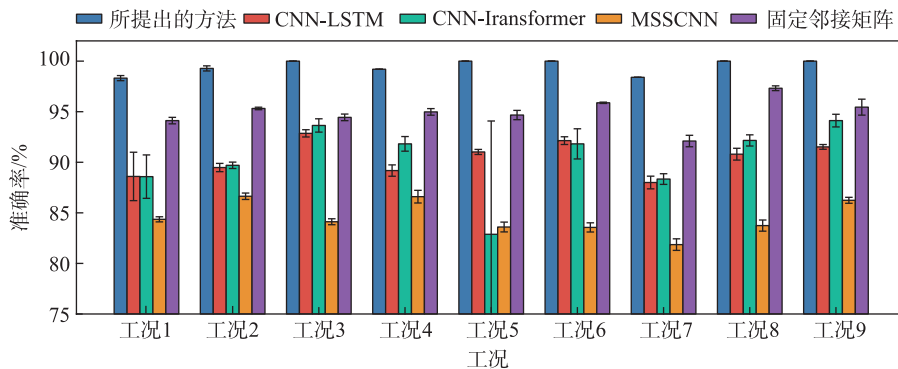


图5 不同方法准确率柱状图  
Fig. 5 Bar chart of accuracy rates of different methods

方法相较于其他方法在统计意义上具有显著优势。此外,为了更加全面地评估模型性能,本文在表5中给出了各模型的召回率(Recall)和F1-Score。结果显示,所提出方法在各项评价指标上均优于对比方法,说明其在不同类别上的识别能力更加均衡,具有更好的综合诊断性能。为深入分析分类性能,采

用混淆矩阵与  $t$ -SNE<sup>[15]</sup>进行特征可视化,如图6和图7所示。结果表明,模型在各故障模式下的分类表现优异,错分样本极少,特征分布聚类清晰,验证了所提方法良好的特征提取与判别能力。

为检验本文所提出模型在结构参数设置上的合理性,采用不同网络结构配置开展消融实验,相

表5 不同模型各工况下的评价指标对比

Tab. 5 Comparison of evaluation indexes under different working conditions of different models

指标	本文方法	CNN-LSTM	CNN-Transformer	MSSCNN <sup>[14]</sup>	固定邻接矩阵	
工况1	准确率	98.32%±0.253 0%	88.60%±2.392 7%	88.58%±2.146 1%	84.36%±0.253 0%	94.12%±0.321 0%
	$t$ -test	-	0.000 1	0.000 1	0.000 1	0.001 6
	Recall	0.983 3	0.864 5	0.885 6	0.843 2	0.942 2
	F1-Score	0.983 3	0.864 2	0.885 4	0.843 1	0.941 7
工况2	准确率	99.28%±0.178 5%	89.48%±0.409 1%	89.70%±0.316 2%	86.64%±0.317 6%	95.32%±0.125 0%
	$t$ -test	-	0.001 2	0.001 0	0.000 6	0.005 2
	Recall	0.9929	0.894 7	0.896 6	0.866 3	0.953 1
	F1-Score	0.9929	0.894 8	0.896 7	0.866 2	0.952 2
工况3	准确率	100.00%±0	92.86%±0.359 1%	93.64%±0.659 3%	84.12%±0.294 5%	94.44%±0.327 0%
	$t$ -test	-	0.001 5	0.001 7	0.000 4	0.002 7
	Recall	1	0.928 2	0.934 5	0.841 2	0.944 0
	F1-Score	1	0.926 2	0.935 1	0.841 2	0.943 8
工况4	准确率	99.20%±0	89.18%±0.560 9%	91.82%±0.724 2%	86.60%±0.626 1%	94.98%±0.326 7%
	$t$ -test	-	0.000 9	0.001 4	0.000 5	0.012 8
	Recall	0.992 0	0.890 5	0.918 1	0.865 9	0.949 8
	F1-Score	0.992 0	0.890 4	0.917 9	0.865 9	0.949 9
工况5	准确率	100.00%±0	91.02%±0.250 9%	82.88%±11.200 6%	83.60%±0.485 3%	94.67%±0.459 9%
	$t$ -test	-	0.000 5	0.000 1	0.000 2	0.000 2
	Recall	1	0.910 2	0.818 7	0.836 0	0.946 8
	F1-Score	1	0.910 2	0.818 9	0.836 0	0.946 8
工况6	准确率	100.00%±0	92.14%±0.382 6%	91.82%±1.491 6%	83.56%±0.454 0%	95.88%±0.066 1%
	$t$ -test	-	0.000 2	0.000 1	0.000 1	0.000 1
	Recall	1	0.920 9	0.918 0	0.835 5	0.958 9
	F1-Score	1	0.921 4	0.917 9	0.835 7	0.959 0
工况7	准确率	98.40%±0	88.00%±0.626 8%	88.34%±0.527 8%	81.86%±0.572 2%	92.10%±0.566 7%
	$t$ -test	-	0.000 1	0.000 1	0.000 1	0.000 1
	Recall	0.984 0	0.880 0	0.882 3	0.808 9	0.921 1
	F1-Score	0.983 9	0.879 9	0.882 5	0.809 1	0.921 1
工况8	准确率	100.00%±0	90.80%±0.583 1%	92.16%±0.552 6%	83.74%±0.551 4%	97.32%±0.235 9%
	$t$ -test	-	0.000 1	0.000 1	0.000 1	0.000 1
	Recall	1	0.906 9	0.921 6	0.837 7	0.973 0
	F1-Score	1	0.907 5	0.922 0	0.837 3	0.973 1
工况9	准确率	100.00%±0	91.52%±0.234 8%	94.12%±0.625 7%	86.24%±0.295 1%	95.45%±0.789 1%
	$t$ -test	-	0.000 1	0.000 2	0.000 1	0.001 7
	Recall	1	0.915 2	0.941 2	0.862 2	0.954 4
	F1-Score	1	0.914 9	0.941 0	0.862 4	0.954 3

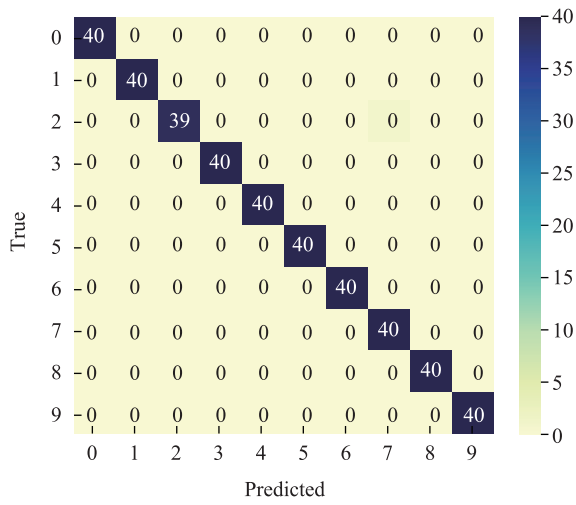


图6 混淆矩阵图

Fig. 6 Confusion matrix chart




图7 特征可视化图

Fig. 7 Feature visualization graph

关结果汇总于表6。表6中,CNN:4 GCN:2表示CNN层数为4,GCN层数为2。可以看出,当去除一层CNN或一层GCN后,模型的诊断精度均出现不同程度的下降,表明模型在特征提取能力和结构化信息建模能力方面均受到削弱。进一步地,在原有结构基础上分别增加一层CNN或GCN后,模型诊断精度并未表现出显著提升,整体性能基本保持不变。这说明在当前任务和数据规模条件下,继续加深网络结构难以带来有效的性能增益。因此,综合考虑模型诊断精度与结构复杂度,本文所构建的模型结构与参数配置在性能与轻量化之间取得了较好的平衡,具有较好的合理性与实用性。

为验证所提出方法在跨工况条件下的泛化能

表6 不同模型结构下的准确率数值

Tab.6 Accuracy rates under different model structures					
工况	本文算法	CNN:4 GCN:2	CNN:6 GCN:2	CNN:5 GCN:1	CNN:6 GCN:3
工况1	98.32%	95.12%	98.14%	94.66%	97.88%
工况2	99.28%	98.32%	99.23%	97.45%	98.68%
工况3	100.00%	98.56%	100.00%	98.12%	99.78%
工况4	99.20%	97.56%	98.99%	97.03%	99.06%
工况5	100.00%	98.22%	99.98%	97.82%	100.00%
工况6	100.00%	99.56%	100.00%	98.60%	100.00%
工况7	98.40%	96.86%	98.36%	97.00%	98.00%
工况8	100.00%	98.23%	99.17%	97.78%	99.88%
工况9	100.00%	97.99%	100.00%	97.34%	99.56%

力,选取某一工况作为源域,其余工况作为目标域,构建基于领域对抗机制的域适应迁移学习框架进行训练,共设置了72种迁移任务。表7给出了不同迁移任务下的故障诊断准确率及其对应的标准差。结果表明,所提出方法具有良好的跨工况泛化性能。在仅采用基础迁移策略的情况下,大多数迁移任务的诊断准确率可稳定达到70%~80%;对于工况差异较小的相邻工况迁移任务,诊断准确率可进一步提升至95%以上。同时,各迁移任务对应的标准差整体较小,表明模型训练过程稳定,预测结果具有较高的一致性和可靠性。

## 4 结论

1) 本文提出了一种基于CNN与GCN串联的多传感器故障诊断方法,充分发挥CNN在局部特征提取方面的优势以及GCN在传感器拓扑关系建模方面的能力,实现了多源传感器信息的深度融合。通过引入基于MLP的节点关联强度自适应学习机制,模型能够动态更新邻接矩阵,有效克服了传统GCN依赖固定拓扑结构、难以适应工况变化的局限性,从而显著提升了复杂服役环境下的诊断泛化能力。

2) 在包含9种工况、10类故障的实测数据集上,所提出方法的平均诊断准确率达99.47%,且结果标准差接近于0,表明模型具有较强的稳定性与工程鲁棒性。进一步地,通过t检验验证了性能提升在统计意义上的显著性。此外,在跨工况迁移学习测试中,所提出方法在部分相近工况下可取得95%以上的诊断精度,验证了其良好的跨工况泛化能力。

表7 不同迁移任务下的准确率数值

Tab.7 Accuracy values under different transfer tasks

源域 \ 目标域	工况1	工况2	工况3	工况4	工况5	工况6	工况7	工况8	工况9
工况1	-	79.40%± 0.231%	82.80%± 0.297%	80.40%± 0.266%	70.60%± 0.675%	73.60%± 0.986%	80.80%± 0.458%	82.60%± 0.782%	72.00%± 0.235%
工况2	73.60%± 0.457%	-	88.00%± 0.434%	73.20%± 0.246%	67.20%± 0.268%	74.80%± 0.521%	53.60%± 0.641%	90.40%± 0.201%	80.12%± 0.273%
工况3	72.40%± 0.278%	89.60%± 0.365%	-	76.00%± 0.365%	69.20%± 0.331%	71.20%± 0.502%	78.80%± 0.081%	78.40%± 0.502%	81.60%± 0.372%
工况4	78.40%± 0.412%	74.00%± 0.583%	69.60%± 0.264%	-	76.80%± 0.514%	78.40%± 0.243%	68.40%± 0.123%	77.40%± 0.301%	67.80%± 0.551%
工况5	65.60%± 0.309%	77.20%± 0.117%	79.60%± 0.211%	80.80%± 0.192%	-	97.60%± 0.183%	69.05%± 0.207%	70.80%± 0.197%	83.60%± 0.092%
工况6	71.20%± 0.605%	70.40%± 0.152%	76.40%± 0.819%	74.40%± 0.182%	97.60%± 0.221%	-	87.60%± 0.153%	77.20%± 0.182%	73.60%± 0.288%
工况7	75.60%± 0.510%	72.00%± 0.401%	74.80%± 0.229%	65.05%± 0.284%	62.70%± 0.802%	70.30%± 0.291%	-	62.88%± 0.129%	89.60%± 0.511%
工况8	77.60%± 0.230%	88.00%± 0.277%	86.40%± 0.107%	65.90%± 0.206%	70.60%± 0.352%	76.56%± 0.812%	92.80%± 0.277%	-	96.80%± 0.173%
工况9	75.60%± 0.560%	77.60%± 0.370%	72.80%± 0.487%	66.20%± 0.682%	63.70%± 0.812%	78.22%± 0.785%	81.60%± 0.591%	96.80%± 0.301%	-

3) 需要指出的是,本文方法在工程应用中的适用性仍受到一定前提条件的约束。当前模型基于固定数量与布局的传感器进行训练与验证,尚未系统评估传感器数量变化或传感器失效情况下的诊断性能;同时,本文主要在实际采集数据的噪声水平下进行实验,模型在更强噪声或复杂干扰环境下的鲁棒性仍有待进一步验证。未来研究将围绕传感器配置自适应、噪声鲁棒建模以及轻量化部署等方向展开,以进一步提升所提出方法在实际工程场景中的推广应用潜力。

#### 参考文献:

- [1] QIN N, DU J H, ZHANG Y M, et al. Fault diagnosis of multi-railway high-speed train bogies by improved federated learning[J]. IEEE Transactions on Vehicular Technology, 2023, 72(6): 7184-7194.
- [2] GUO L R, LI G S, CHEN C, et al. Vibration fatigue characteristics of a high-speed train bogie and traction motor based on field measurement and spectrum synthesis[J]. Machines, 2025, 13(7): 613.
- [3] MEN Z H, HU C Q, LI Y H, et al. A hybrid intelligent gearbox fault diagnosis method based on EWCEEMD and whale optimization algorithm-optimized SVM[J]. International Journal of Structural Integrity, 2023, 14(2): 322-336.
- [4] 李刚, 秦永峰, 齐金平. 基于GASF多通道图像时序融合的高速列车横向减振器故障诊断[J]. 振动与冲击, 2025, 44(15): 144-152, 191.  
LI G, QIN Y F, QI J P. High-speed train transverse damper fault diagnosis based on 1D-2D-GASF-CNN-GRU-MSA model[J]. Journal of Vibration and Shock, 2025, 44(15): 144-152, 191.
- [5] 岑潮宇, 代亮成, 池茂儒, 等. 基于KPCA-SO-KELM的抗蛇行减振器故障诊断[J]. 科学技术与工程, 2025, 25(11): 4551-4558.  
CEN C Y, DAI L C, CHI M R, et al. Fault diagnosis of yaw damper based on KPCA-SO-KELM[J]. Science Technology and Engineering, 2025, 25(11): 4551-4558.
- [6] 门志辉, 宫岛, 周劲松, 等. 基于格拉姆角场与并行卷积Transformer的列车传动系统故障诊断方法[J]. 机械工程学报, 2025, 61(24): 168-179.  
MEN Z H, GAO D, ZHOU J S, et al. Fault diagnosis method for train traction transmission system based on gram angle field and parallel convolutional transformer[J]. Journal of Mechanical Engineering, 2025, 61(24): 168-179.
- [7] MEN Z H, LI Y H, GAO L, et al. Fault diagnosis method for railway wagon bearings under imbalanced dataset based on improved ACWGAN[J]. Nonlinear Dynamics, 2025, 113(12): 14935-14962.

- [8] 彭刘禹, 胡俊锋, 张龙. 基于GRCMFDE与CNN的轮对轴承故障诊断方法研究[J]. 铁道科学与工程学报, 2025, 22(9): 4260-4270.  
PENG L Y, HU J F, ZHANG L. Fault diagnosis of wheel-set bearings based on GRCMFDE and CNN[J]. Journal of Railway Science and Engineering, 2025, 22(9): 4260-4270.
- [9] MEN Z H, GONG D, ZHOU K, et al. Unsupervised domain adaptation method for bearing fault diagnosis assisted by twin data under extreme sample scarcity[J]. Mechanical Systems and Signal Processing, 2025, 239: 113359.
- [10] 刘庆杰, 黄辉, 雷晓燕. 基于集合经验模态分解和小波变换的轮轨力应变信号降噪[J]. 城市轨道交通研究, 2016, 19(11): 26-29, 37.  
LIU Q J, HUANG H, LEI X Y. Wheel/rail strain signals de-noising by using EEMD and wavelet transform[J]. Urban Mass Transit, 2016, 19(11): 26-29, 37.
- [11] MEN Z H, CHEN Z, LI Y H, et al. Railway wagon bearing fault diagnosis method based on improved sparrow search algorithm optimizing variational mode decomposition and multi-level convolutional neural network[J]. Review of Scientific Instruments, 2024, 95(4): 045104.
- [12] LI T F, ZHAO Z B, SUN C, et al. Multireceptive field graph convolutional networks for machine fault diagnosis[J]. IEEE Transactions on Industrial Electronics, 2021, 68(12): 12739-12749.
- [13] QIN Y, WANG Y R, LI Z S, et al. An in-depth tutorial on BJTU-RAO bogie datasets for fault diagnosis[J]. IEEE Access, 2025, 13: 60879-60888.
- [14] LI Y H, MEN Z H, BAI X N, et al. A bearing fault diagnosis method based on M-SSCNN and M-LR attention mechanism[J]. Structural Health Monitoring, 2025, 24(2): 830-852.
- [15] MAATEN L V D, HINTON G. Visualizing Data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579-2605.



第一作者: 刘凯(1985—), 男, 高级工程师, 学士, 研究方向为轨道车辆制造与自动化。



通信作者: 宫岛(1985—), 男, 副教授, 博士, 硕士生/博士生导师, 研究方向为轨道车辆系统动力学, 振动噪声智能协同控制, 模态分析与正向设计, 轨道车辆智能走行, 轮轨关系。