

DOI: 10.13382/j.jemi.B2407678

# 基于 CNN-GraphSAGE 双分支特征融合的 齿轮箱故障诊断方法\*

韩 延<sup>1</sup> 吴 迪<sup>2</sup> 黄庆卿<sup>1</sup> 张 焱<sup>1</sup>

(1. 重庆邮电大学工业物联网与网络化控制教育部重点实验室 重庆 400065;

2. 重庆交通职业学院智能制造与汽车学院 重庆 402247)

**摘要:**针对卷积神经网络(CNN)在振动数据结构信息上挖掘不足导致故障诊断精度不高的问题,提出一种基于卷积神经网络与图采样和聚合网络(CNN-GraphSAGE)双分支特征融合的齿轮箱故障诊断方法。首先,对齿轮箱振动数据进行小波包分解,利用分解后的小波包特征系数构建包含节点和边的图结构数据;然后,建立 CNN-GraphSAGE 双分支特征提取网络,在 CNN 分支中采用空洞卷积网络提取数据的全局特征,在 GraphSAGE 网络分支中通过多层特征融合策略来挖掘数据结构中隐含的关联信息;最后,基于 SKNet 注意力机制融合提取的双分支特征,并输入全连接层中实现对齿轮箱的故障诊断。为验证研究方法在齿轮箱故障诊断上的优良性能,首先对所提方法进行消融实验,然后在无添加噪声和添加 1 dB 噪声的条件下进行对比实验。实验结果表明,即使在 1 dB 噪声的条件下,研究方法的平均诊断精度为 92.07%,均高于其他对比模型,证明了研究方法能够有效地识别齿轮箱的各类故障。

**关键词:**图卷积神经网络;卷积神经网络;故障诊断;注意力机制

**中图分类号:** TH165.3; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.1520;510.4030

## Gearbox fault diagnosis method based on CNN-GraphSAGE dual-branch feature fusion

Han Yan<sup>1</sup> Wu Di<sup>2</sup> Huang Qingqing<sup>1</sup> Zhang Yan<sup>1</sup>

(1. Ministry of Education Key Laboratory of Industrial Internet of Things and Networked Control, Chongqing University of Posts and Telecommunications, Chongqing 400065, China; 2. School of Intelligent Manufacturing and Automotive, Chongqing Vocational College of Transportation, Chongqing 402247, China)

**Abstract:** Aiming at the problem that the convolutional neural network (CNN) is insufficiently mined on the information of vibration data structure, which leads to the low accuracy of fault diagnosis, a CNN-GraphSAGE dual-branch feature fusion method for gearbox fault diagnosis is proposed. Firstly, the vibration data of the gearbox is subjected to wavelet packet decomposition, and the wavelet packet coefficients are constructed into graph structured data containing nodes and edges. Then a dual-branch feature extraction network is established, with the CNN branch using a dilated convolutional network to extract global features of the data, and the GraphSAGE branch using a multi-layer feature fusion strategy to mine the implicit correlation information in the data structure. Finally, an attention fusion module based on the SKNet attention mechanism is constructed to fuse the dual-branch extracted features, and then the fused features are input into the fully connected layer to realize the fault diagnosis of gearbox. In order to verify the excellent performance of the proposed method in gearbox fault diagnosis, the ablation experiments were conducted first, and then comparative experiments were carried out under the condition of no added noise and adding 1 dB noise. The experimental results show that even under the condition of 1 dB noise, the average diagnostic accuracy of the proposed method is 92.07%, which is higher than the comparison models. The proposed method can effectively recognize various types of faults in gearboxes.

**Keywords:** graph convolutional neural network; convolutional neural network; fault diagnosis; attention mechanism

## 0 引言

齿轮箱作为重要的动力传动装置,被广泛使用在各种重大机械设备中<sup>[1-2]</sup>。开展齿轮箱智能诊断技术研究,及时消除隐患,保障齿轮箱的正常运行,具有重要意义<sup>[3]</sup>。

近年来,基于深度学习的故障诊断方法得到了广泛的研究,陈仁祥等<sup>[4]</sup>提出了一种基于卷积神经网络(convolutional neural network, CNN)的滚动轴承故障诊断方法,将自适应提取时频特征与模式识别有机融合在一起,有效避免了传统方法中特征选择的不确定性对故障诊断的影响。李益兵等<sup>[5]</sup>利用快速傅里叶变换将原始时域信号转换成频域信号,通过稀疏滤波提取低维故障特征,使得模型在噪声环境下具有更高的准确性和鲁棒性。Zhang 等<sup>[6]</sup>提出了一种基于卷积神经网络的诊断算法,将原始信号转换为二维图像的后进行特征提取,消除特征提取过程过于依赖专家经验的影响。魏秀业等<sup>[7]</sup>提出了一种基于特征融合与深度残差网络的行星齿轮箱故障诊断方法,解决了行星齿轮箱振动信号相互耦合和故障诊断不准确等问题。上述方法在故障领域取得了较好的成效,但这些方法只能处理欧氏空间数据,对于非欧氏空间数据中具有不同局部结构的节点,无法挖掘节点之间隐含的关联信息。

图卷积网络(graphical convolutional networks, GCN)<sup>[8]</sup>解决了卷积神经网络无法处理非欧氏空间数据的局限,能够提取具有大跨度的图样本中的节点的特征,通过多层的卷积操作来挖掘图数据中具有不同局部结构的节点之间隐含的关联信息<sup>[9-10]</sup>。目前,图卷积网络在故障诊断领域也受到了学者广泛的关注,如 Li 等<sup>[11]</sup>提出了一种多感受野图卷积网络,通过将数据样本转换为加权图以实现数据样本之间的差异关系,以及从不同的感受野下提取特征信息。针对齿轮箱振动信号具有强烈的非线性性和非平稳性等特点<sup>[12]</sup>,部分学者将原始振动信号经过小波包变换后得到的时频图构建成图结构数据,如 Yu 等<sup>[13]</sup>首先将振动信号进行小波包分解得到时频特征图,然后引入图卷积网络来提取具有大跨度定义的图样本点的特征,最后使用快速图卷积核和特定的池化改进来减少节点数量实现故障类别的快速分类。陈起磊等<sup>[14]</sup>提出了一种基于视频图与改进图卷积神经网络的故障诊断方法,通过超像素分割法将由小波包分解得到的时频图生成超像素块,并将其作为节点,然后输入到通过结构学习方法改进的网络中。上述方法在故障领域也取得了较好的成效,但这些方法忽略了由多个图卷积层提取的多阶邻域信息之间的互补性和相关性,导致模型最终的分类精度也受到影响。此外,由于振动信号包含

丰富的局部特征,图卷积网络在处理图数据时通常是通过邻接矩阵传播信息,所以处理此类信号时可能无法直接捕获到这些局部特征。

为解决上述问题,本文提出一种卷积神经网络与图采样和聚合网络(CNN-GraphSAGE)双分支特征融合的齿轮箱故障诊断方法,通过利用 CNN-GraphSAGE 在提取数据特征信息上互补的优势,提高模型表达能力和学习能力。首先在 CNN 分支上采用空洞卷积来增加感受野,从而捕获更多的全局信息;此外,考虑到每一层 GraphSAGE 网络可以聚合多阶邻域节点内的局部结构信息,可以为分类任务提供更多相关和互补的信息,设计一种融合多层特征的 GraphSAGE 网络(MF-GraphSAGE),在挖掘数据结构中隐含的关联信息的同时,还能充分利用提取到的多阶特征信息。然后使用 SK 注意力机制(selective kernel networks, SKNet)<sup>[15]</sup>融合空洞卷积网络和 MF-GraphSAGE 网络分别提取到的特征,并将融合后的特征输入分类器,得到最终的分类结果。最后,利用齿轮箱的振动数据来验证本文所提方法的有效性。

## 1 图卷积神经网络

对于图  $G = (V, E)$ ,其中  $V$  和  $E$  分别表示节点和边,邻接矩阵  $A$  可以表示为:

$$A_{i,j} = \begin{cases} \exp\left(-\frac{\|v_i - v_j\|^2}{\sigma^2}\right), & v_i \text{ 和 } v_j \text{ 是邻居节点} \\ 0, & v_i \text{ 和 } v_j \text{ 不是邻居节点} \end{cases} \quad (1)$$

式中:  $\sigma$  是参数;向量  $v_i$  和  $v_j$  分别表示节点  $V_i$  和  $V_j$  的特征;  $A_{i,j}$  表示节点  $V_i$  和  $V_j$  的边。

对于图卷积网络,确定了邻接矩阵  $A$ ,则可根据邻接矩阵  $A$  来创建对应的图拉普拉斯矩阵  $L = D - A$ ,其中  $D$  是图的度矩阵,即  $D_{i,i} = \sum_j A_{i,j}$ ,为了增强图的泛化能力,将上述的拉普拉斯矩阵改写为:

$$L = I_k - D^{-1/2} A D^{-1/2} \quad (2)$$

式中:  $I_k$  是单位矩阵。然后对  $L$  进行特征值分解可得到:

$$L = U \Lambda U^T \quad (3)$$

式中:  $\Lambda = \text{diag}([\lambda_0, \lambda_1, \dots, \lambda_{k-1}])$ 。傅里叶换的本质是求  $f(x)$  和以  $e^{-iox}$  为基向量的积分,那么  $x$  和  $g$  在图上的卷积可以表示为:

$$x \times g = U[U^T x] \cdot [U^T g] \quad (4)$$

令式(4)中的  $U^T g = g_\theta$ ,则式(4)最终表示为:

$$x \times g = U g_\theta U^T x \quad (5)$$

由于式(5)中的  $g_\theta$  计算十分困难,通过使用迭代  $k$

次的切比雪夫多项式进行替换拟合,因此式(5)可被改写为:

$$x \times g = \sum_{k=0}^K \theta'_k T_k(\tilde{L}) x \quad (6)$$

式中:  $\theta'_k$  是切比雪夫系数;  $T_k$  是切比雪夫多项式;  $\tilde{L}$  表示  $L$  的归一化。而当  $K = 1$  时,上式可进一步被简化为:

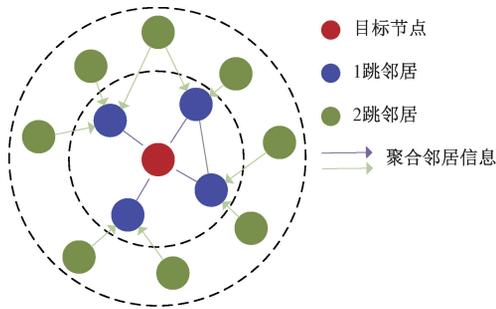
$$x \times g \approx \theta(\mathbf{I}_N + \mathbf{L}) = \theta(\mathbf{I} + \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2}) \quad (7)$$

最后,得到 GCN 的传播规则为:

$$H^{(l+1)} = \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} H^{(l)} \mathbf{W}^{(l)} + b^{(l)}) \quad (8)$$

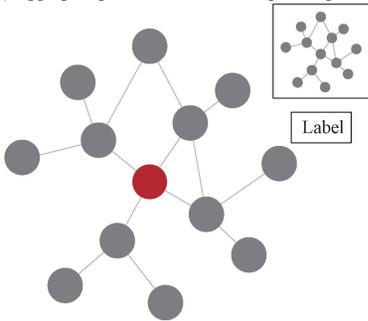
式中:  $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ ,  $\tilde{\mathbf{D}}$  表示  $\tilde{\mathbf{A}}$  的度矩阵;  $\sigma$  表示激活函数;  $H^{(l)}$ 、 $\mathbf{W}^{(l)}$  和  $b^{(l)}$  分别表示第  $l$  层的输出值、权重矩阵和偏置。

GCN 是一种有效的图表示学习框架,它的核心类似于传统 CNN 中的卷积操作,每层 GCN 都会通过邻居节点的信息来更新节点的表示,然后将更新后的节点信息来预测该节点的标签,如图 1 所示。通过利用邻接矩阵来描述节点之间的连接关系,以及执行图卷积操作,逐层提取节点的高级特征。



(a) 聚合邻居节点的信息

(a) Aggregating information from neighboring nodes



(b) 使用聚合后的信息来预测节点标签

(b) Using aggregated information to predict node labels

图 1 图卷积神经网络原理

Fig. 1 The principle of graph convolutional neural networks

## 2 CNN-GraphSAGE 双分支特征融合的齿轮箱故障诊断模型

由于 CNN 和 GraphSAGE 可以提取不同类型的特征,因此本文采用了两条支路并行提取振动信号不同特征的方法,并将提取到的不同类型的特征进行融合,该方法打破了单个模型的性能瓶颈。在其中一条支路采用空洞卷积来提取振动信号的全局特征,另一条支路中采用融合多层特征的 GraphSAGE 网络挖掘数据结构中隐含的关联信息,并充分利用提取到的多阶特征信息。最后将提取到的特征输入到注意力融合模块中,以提高对与任务相关的重要信息的关注,从而提高模型的诊断性能和泛化能力。

### 2.1 双分支特征提取网络

由于普通卷积神经网络的感受野是固定的,所以在提取数据的特征时会受到限制,若通过增加卷积核的尺寸来增大感受野,则会导致模型也随之变大,计算量也跟着增加。而空洞卷积可以在不增加卷积核尺寸的条件下来扩大卷积核的视野。

空洞卷积主要思想是在卷积核的像素之间插入“空洞”来增大视野,从而在深度卷积神经网络中实现密集特征提取<sup>[16]</sup>。空洞卷积作为卷积的一种,提供了一种通过线性扩大卷积核的域来指数地增加网络的感受野的方法,以及通过跳变步长获得数据特征,从而输出更多的信息,并保持参数不变<sup>[17]</sup>。

空洞卷积网络的卷积核大小计算公式为:

$$F = k + (k - 1)(r - 1) \quad (9)$$

式中:  $k$  表示原始卷积核大小;  $r$  表示空洞卷积的参数空洞率;  $F$  则表示空洞卷积的实际卷积核大小。在这样的定义下,二维数据上的扩张卷积如图 2 所示。

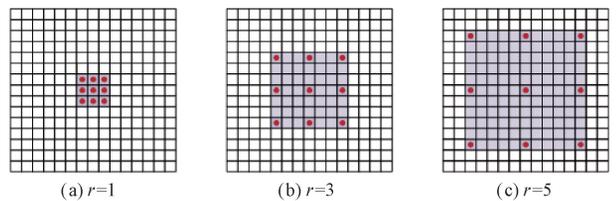


图 2 卷积核  $k=3$  时,不同空洞率  $r$  下的空洞卷积示意

Fig. 2 Schematic diagram of dilated convolution at different dilation rates  $r$  when the convolution kernel  $k=3$

图卷积网络可以自然的用于对图结构数据中的长距离空间关系进行建模,挖掘数据的结构信息。其中 GraphSAGE 通过聚合邻居节点的特征信息的方式来获得中心节点的特征信息<sup>[18]</sup>。与以往模型在提取邻居节点特征信息时考虑所有邻近节点不同,GraphSAGE 引入了

对邻居节点的随机采样机制,能够使每一个节点仅涵盖小于所预先设定的采样数量的邻居节点,因而从单一的局部结构拓扑逐渐向多重局部结构拓扑的归纳表示转变,避免节点的特征每次都需要重新训练的情况,其聚合邻居节点特征信息过程为:

$$\mathbf{X}_{\mathcal{N}(u)}^p \leftarrow \text{AGGREGATE}_p(\{\mathbf{X}^p(v, :), \forall v \in \mathcal{N}(u)\}) \quad (10)$$

$$\mathbf{X}^{p+1}(u, :) \leftarrow \sigma(\text{CONCAT}(\mathbf{X}^p(u, :), \mathbf{X}_{\mathcal{N}(u)}^p) \Theta^p) \quad (11)$$

式中,  $\{\mathbf{X}^p(v, :), \forall v \in \mathcal{N}(u)\}$  表示在第  $p$  层节点  $u$  的邻居节点  $u$  的特征信息;  $\text{AGGREGATE}_p(\cdot)$  是一个聚合器;  $\mathbf{X}_{\mathcal{N}(u)}^p$  表示在第  $p$  层  $u$  所有邻居节点的特征表示;  $\Theta^p$  表示权重矩阵;  $\sigma(\cdot)$  是激活函数。

考虑到多层图卷积网络会导致过平滑以及忽略每层提取的多阶邻域信息之间的互补性和相关性,设计了一种 MF\_GraphSAGE 网络,将每一层提取到的特征添加一个注意力之后进行融合,在消除了过平滑问题的同时还能充分利用每层卷积操作提取到的多阶邻域信息。其中对聚合更新后的输出特征进行注意力加权的实现过程为:

$$y^{l+1} = f_{res}(\mathbf{X}^{l+1}) = \psi(\mathbf{X}^{l+1}, \mathbf{W}_{l+1}) = \text{ReLU}(\mathbf{W}_{l+1}(\text{BN}(\text{Linear}(\mathbf{X}^{l+1}))) + b_{l+1}) \quad (12)$$

式中:  $\mathbf{X}^{l+1}$  表示聚合更新后的特征;  $y^{l+1}$  表示注意力加权之后的特征信息;  $\mathbf{W}_{l+1}$  和  $b_{l+1}$  是  $\mathbf{X}^{l+1}$  的权重和偏置矩阵;  $\text{Linear}(\cdot)$  表示线性层; BN 表示批归一化层;  $\text{ReLU}(\cdot)$  表示激活函数;  $\psi(\cdot)$  表示残差计算公式。最后将每层卷积的输出特征与加权后的特征相乘后的结果拼接起来。MF\_GraphSAGE 网络的实现过程为:

$$\hat{y} = \text{concate}(\mathbf{X}^{l+1} y^{l+1}) \quad l = 1, 2, \dots, m \quad (13)$$

式中:  $\text{concate}(\cdot)$  表示拼接函数;  $m$  表示 GraphSAGE 网络的层数;  $\hat{y}$  表示 MF\_GraphSAGE 网络的输出特征。其网络结构如图 3 所示。

最后,将这两条支路上提取到的不同类型的特征送入基于注意力机制的融合模块中,最后经由全连接层映射到样本标签空间,实现故障类别的分类。

## 2.2 SKNet 注意力融合模块

在深度学习领域中,模型常需处理大量数据,但特定时刻仅少量数据重要。此时,注意力机制作为资源分配方案,解决信息过载问题,使有限计算资源集中处理重要信息。引入注意力机制后,神经网络能自动学习并关注重要输入,提升模型性能和泛化能力。

在双分支特征提取模块中,分别通过空洞卷积和融合多层特征的 GraphSAGE 图卷积提取到振动信号的特征信息以及非欧空间中样本之间的关系特征,然后将由这两条支路的提取到的特征输入到注意力模块中,以将

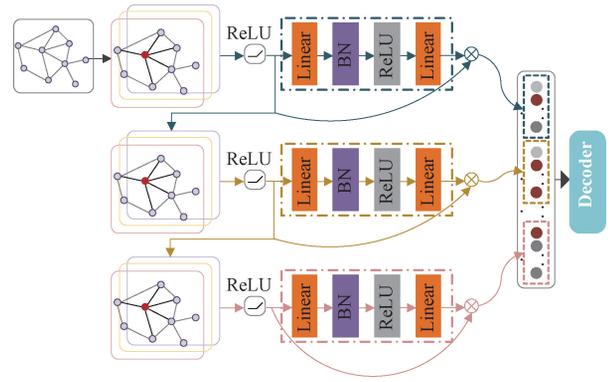


图 3 MF\_GraphSAGE 网络结构

Fig. 3 MF\_GraphSAGE network structure diagram

注意力放在重要的特征上。SKNet 注意力融合模块通过选择性地应用不同尺度的卷积核,能够有效地融合多尺度的特征信息,结构如图 4 所示<sup>[15]</sup>。

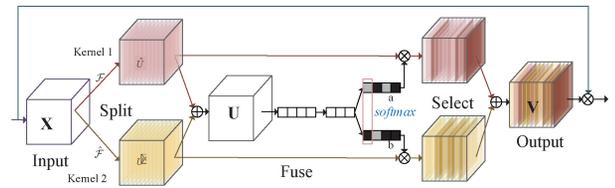


图 4 注意力融合模块

Fig. 4 Attention fusion module

## 2.3 目标函数

为了评价所提模型的诊断性能,采用交叉熵损失函数作为所提方法的优化目标函数,在训练期间,利用交叉熵损失的反馈来优化模型参数,使预测标签尽可能贴近实际标签,实现过程为:

$$L_{\text{loss}} = \frac{1}{N} \sum_{i=1}^N L_i = - \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_i^c \log p_i^c \quad (14)$$

式中:  $N$  表示训练样本总数;  $C$  表示数据集的故障类别总数;  $y_i^c$  表示一个指示函数,取值为 0 或者 1,即当节点  $i$  的真实标签属于故障类别  $c$  时取值 1,否则取值为 0;  $p_i^c$  表示节点  $i$  属于故障类别  $c$  的预测概率。

## 3 基于 CNN-GraphSAGE 双分支特征融合的齿轮箱故障诊断流程

本文方法的整体流程如图 5 所示。所提方法的故障诊断流程主要分为 4 部分,即数据采集、数据预处理、模型的构建以及最后的故障诊断模块。

1) 数据采集,通过在设备上安装的传感器来采集齿轮箱各个部位的振动信号。

2) 数据预处理,将采集到的齿轮箱的振动数据进行

预处理,并将振动数据转换成图结构数据。然后划分数据集,即将数据集分为训练集和测试集。

3) 故障诊断模型的建立和训练,首先,搭建好上面所述的故障诊断模型,然后把训练数据导入到这个模型

里面进行学习,接着用训练完成的模型来对测试数据集进行齿轮箱故障的识别。

4) 模型的评估,把经过训练的模型用于测试数据集,以此来对数据进行分类和识别。

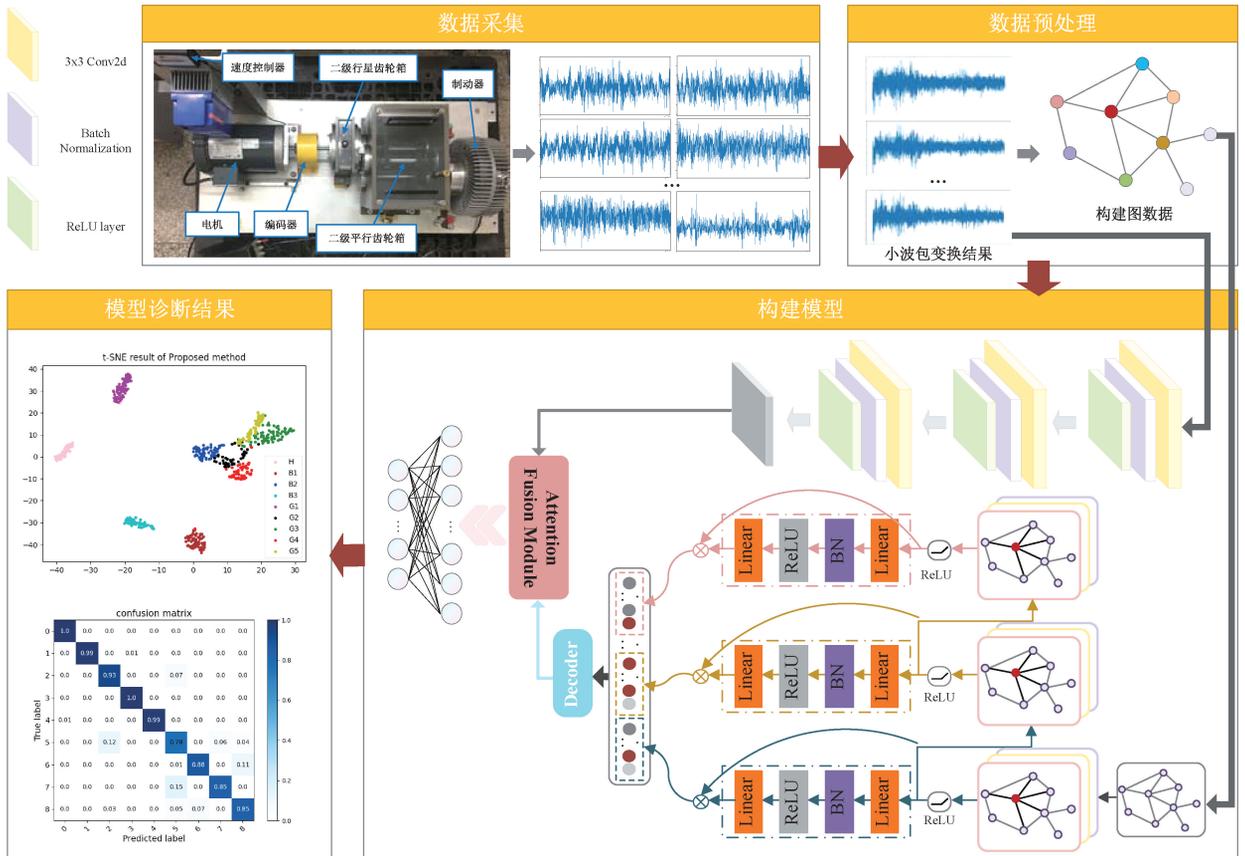


图 5 CNN-GraphSAGE 双分支特征融合的齿轮箱故障诊断模型整体流程

Fig. 5 The overall process of the CNN GraphSAGE dual branch feature fusion gearbox fault diagnosis model.

### 4 实验验证

#### 4.1 实验数据集介绍

为了验证本文模型的准确性,采用了动力传动系统诊断模拟器 (drivetrain diagnosis simulator, DDS) 所采集到的 9 类健康状态下的振动数据来进行验证,如图 6 所示。

本文模拟了平行齿轮箱在单一工况下的 9 中健康状况,包括 1 类正常状态数据和 8 类典型故障状态的数据(即轴承和齿轮故障),如表 1 所示。数据采集过程使用了 12 800 Hz 采样频率,每次采样的长度设置为 200 K,重复进行了 4 次采集。每一种故障类别均涉及一种加载条件,且每类故障均包含 200 个样本,每个样本的长度均为 4 096 个点。为了保证训练和测试的充分性和

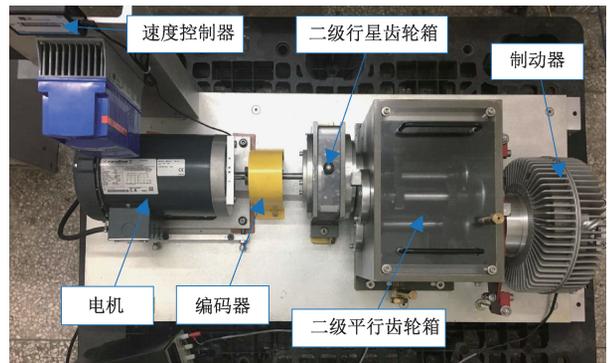


图 6 DDS 齿轮箱测试台示意

Fig. 6 Schematic diagram of DDS gearbox test bench

严格性,在实验验证阶段将该数据集按照 7 : 3 的比例划分为训练集和测试集。

表 1 数据集描述

Table 1 Description of the dataset

状态	标签	描述
健康	0	正常
故障	1	轴承内圈故障
	2	轴承外圈故障
	3	轴承滚动体故障
	4	齿轮偏心
	5	齿轮断齿
	6	齿轮缺齿
	7	齿轮表面磨损
	8	齿轮齿根裂纹

4.2 模型参数设置

本文模型参数如表 2 所示。在空洞卷积分支上的特征提取器  $F(\cdot)$  由 3 层 2 维卷积层和激活函数 ReLU 组成;图卷积分支上的特征提取器  $F(\cdot)$  由 3 层改进的残差 GraphSAGE 和激活函数 ReLU 组成;分类器  $C(\cdot)$  由 3 层全连接层组成。

表 2 模型参数

Table 2 Model parameter

网络层	参数	激活函数
空洞卷积分支	卷积层 1, BN Kernel_size = 3, stride = 1, dilation = 2	ReLU
	卷积层 2, BN Kernel_size = 3, stride = 1, dilation = 3	ReLU
	卷积层 3, BN Kernel_size = 3, stride = 1, dilation = 4	ReLU
图卷积网络分支	卷积层 1, BN Input = 1, output = 32	ReLU
	卷积层 2, BN Input = 32, output = 64	ReLU
	卷积层 3, BN Input = 64, output = 128	ReLU
分类器	Decoder 输出维度 (32, 64, 11)	
	全连接层 1 神经元 128, Dropout 0.3	\
	全连接层 2 神经元 32, Dropout 0.3	\
	全连接层 3 神经元个数 9	\

此外,本文采用 Adam 优化器对网络的参数更新,学习率为 0.005,训练批次大小为 200。为了证明本文方法在噪声背景下的故障诊断能力,在进行数据预处理之前对原始信号添加了 1 dB 的噪声。为了减小随机性对实验结果的影响,本节所有实验均独立重复 5 次,并取 5 次实验的平均值作为最终的实验结果。

4.3 实验与结果分析

为了探究本文模型中各个组成部分对整体模型的影响,分别对每个部分进行单独的实验,以评估该部分在齿轮箱故障诊断过程中起到的作用,消融实验结果如表 3 所示。

从表 3 的消融实验可以看出,在 1 dB 的噪声背景下,当模型为混合空洞卷积网络或者 MF\_GraphSAGE 时,模型的故障诊断精度为 85.07% 和 87.96%。以分支并行的思路将混合空洞卷积和 MF\_GraphSAGE 网络分别提取

表 3 消融实验

Table 3 Ablation experiment

模型	平均值±标准差/%
空洞卷积	85.07±1.22
MF_GraphSAGE	87.96±0.78
空洞卷积+MF_GraphSAGE	90.71±0.15
本文	92.07±0.44

齿轮箱的全部特征和图数据上的包含了节点之间的几何结构信息的两种特征进行融合,结果表明这种方法下模型的诊断精度达到了 90.71%,相比于 MF\_GraphSAGE 模型的诊断精度提高了 2.75%,比混合空洞卷积模型的诊断精度提高了 5.64%。这种双分支特征融合的方法比分支本身的效果要好,说明同时考虑振动信号的全局特征和图数据上的结构信息对于齿轮箱的故障诊断起到了一定的提升作用。最后,在特征融合模块引入注意力机制,模型的诊断精度从 90.71% 提升到了 92.07%,表明了注意力机制在齿轮箱的故障诊断模型中也起着一定的提升的作用。可以看出本研究所提方法中每一个部分的改进都能够提高基础模型对齿轮箱故障诊断的精度。

此外,为了验证本文方法对齿轮箱故障诊断的优良性能,分别在未添加噪声和添加了 1 dB 噪声的条件下将所提方法与 GAT<sup>[19]</sup>、MRF\_GCN<sup>[11]</sup>、AGCNet<sup>[20]</sup> 等方法进行对比,实验结果如表 4 所示。

表 4 对比实验

Table 4 Comparative experiment

模型	平均值±标准差/%	
	未添加噪声	添加 1 dB 噪声
GAT	82.41±1.05	72.07±1.84
MRF_GCN	96.52±0.60	75.41±1.20
AGCNet	91.26±1.91	80.59±2.25
<b>本文</b>	<b>98.85±0.42</b>	<b>92.07±0.44</b>

从表 4 的对比实验可以看出,在未添加噪声的背景下,本文方法的平均识别精度为 98.85%,分别高于 GAT、MRF\_GCN、AGCNet 等模型的 82.41%、96.52% 和 91.26%。在添加了 1 dB 的噪声条件下,本文方法的平均识别精度为 92.07%,这一结果显著优于其他几组对比模型,后者分别达到了 72.07%、75.41% 和 80.59% 的精度。这些对比模型在提取图数据特征时,仅聚焦于节点间的关联,却忽视了数据的全局特性,从而限制了其诊断精度的提升。相比之下,本文方法的使用图卷积网络来提取节点之间的结构信息关系,捕捉图数据中的上下文特征,还引入空洞卷积网络来提取振动信号的全局特征,最后通过注意力机制,本文将这两条路径提取的特征进行有效融合,使得模型能够更加关注任务相关的特征信息,忽略无关的部分。这一策略增强了模型在振动信号中的故障特征挖掘能力,进而提高模型的故障诊断能力和精度。

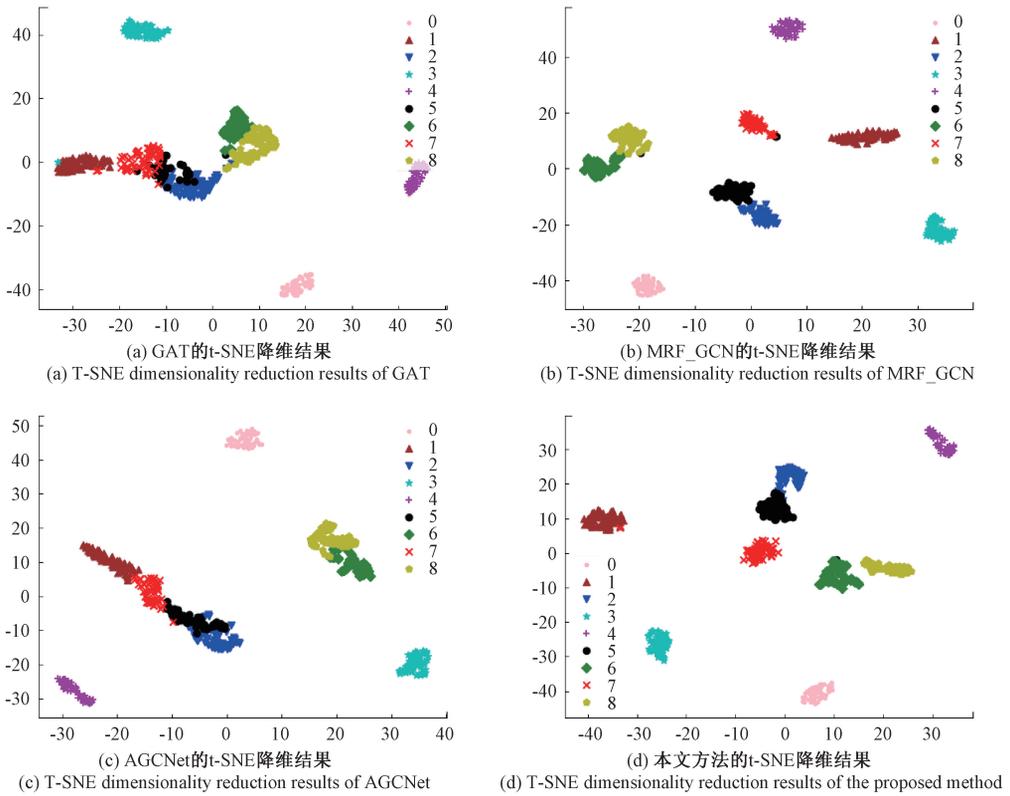


图 7 未添加噪声下各模型的 t-SNE 降维可视化结果

Fig. 7 Visualization results of t-SNE dimensionality reduction for each model without adding noise

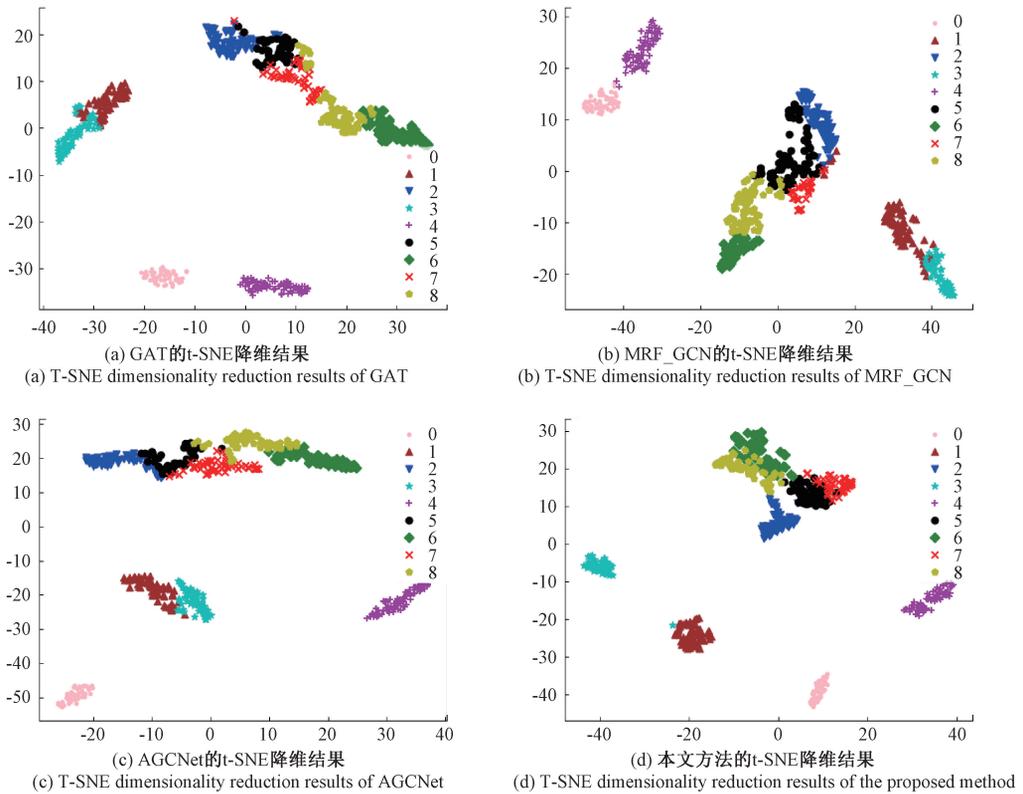


图 8 添加 1 dB 噪声下各模型的 t-SNE 降维可视化结果

Fig. 8 Visualization results of t-SNE dimensionality reduction for each model with 1 dB of noise added

为了全面展示本文模型在 DDS 数据上展现的故障诊断性能,采用 t-SNE 降维的方法将表 4 中列出的几种方法的特征提取结果进行了可视化处理,所得结果如图 7 和 8 所示。其中图 7(a)~(d)分别为 GAT、MRF\_GCN、AGCNet 和本文方法在未添加噪声下的 t-SNE 降维可视化结果,图 8(a)~(d)分别为 GAT、MRF\_GCN、AGCNet 和本文方法在添加 1 dB 噪声下的 t-SNE 降维可视化结果。

由图 7 和 8 可知,相比于 GAT、AGCNet、MRF\_GCN 等模型的诊断性能,本文方法能够在提取振动信号全局特征的同时,使用 MF\_GraphSAGE 网络来深入挖掘振动信号样本间隐含的关联信息,并有效利用每一层局部信息的相关性和互补性,从而确保模型能够全面且精准地捕捉到振动信号的故障特征。最后采用注意力机制融合

模块,有效地将两个分支上各自提取的差异化特征进行融合,这一步骤极大地增强了模型对于齿轮箱 9 种故障类别的精准识别能力,显著提升了齿轮箱故障诊断的精确度。

最后,为了更好的分析本文方法对各类故障类别的识别情况,将训练好的模型的用于测试集上的数据进行识别分类,并将最终的预测标签和测试集的真实标签以混淆矩阵的形式进行可视化,本文方法在未添加噪声的条件下和添加了 1 dB 噪声条件下的混淆矩阵输出结果如图 9 所示,其中图 9(a)是本文模型在未添加噪声下的混淆矩阵结果,图 9(b)是本文模型在为添加了 1 dB 噪声下的混淆矩阵结果,其中横坐标为模型对测试集的预测标签,纵坐标为测试集的真实标签。

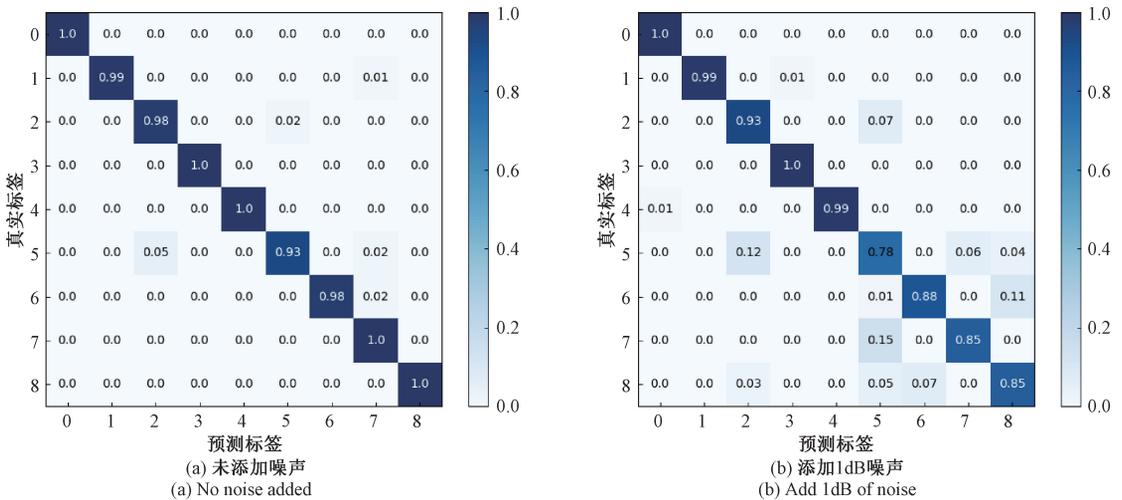


图 9 本文方法的混淆矩阵输出结果

Fig. 9 The confusion matrix output result of the proposed method

### 5 结 论

本文结合了空洞卷积和图卷积神经网络在提取特征信息上的优势,设计了一种双分支的特征提取网络,能够充分的提取数据的全局特征和挖掘数据的结构特征。然后引入注意力机制来融合两个网络提取到的不同类型的特征信息。最后分别在未添加噪声和添加 1 dB 噪声条件下使用 DDS 数据进行实验验证,并通过 t-SNE 降维和混淆矩阵输出对诊断结果进行可视化。实验结果表明,与现有的一些方法相比,本文提出的模型在噪声背景下齿轮箱的故障诊断效果更好。

### 参考文献

[ 1 ] WANG CH G, LI H K, ZHANG K L, et al. Intelligent fault diagnosis of planetary gearbox based on adaptive

normalized CNN under complex variable working conditions and data imbalance[J]. Measurement, 2021, 180: 109565.  
 [ 2 ] 王朋飞, 刘长良, 徐健, 等. 基于图注意力和时间卷积网络的风电齿轮箱故障预警方法 [J]. 电子测量与仪器学报, 2023, 37(8): 204-213.  
 WANG P F, LIU CH L, XU J, et al. Wind turbine gearbox fault warning method based on graph attention and temporal convolutional network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 204-213.  
 [ 3 ] 刘长良, 刘少康, 李洋, 等. 变转速下基于改进多阶概率方法的风电齿轮箱故障诊断研究[J]. 仪器仪表学报, 2024, 45(5): 208-217.  
 LIU CH L, LIU SH K, LI Y, et al. Research on fault

- diagnosis of wind turbine gearbox under variable speed based on the improved multi-order probability approach [J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 208-217.
- [4] 陈仁祥, 黄鑫, 杨黎霞, 等. 基于卷积神经网络和离散小波变换的滚动轴承故障诊断[J]. 振动工程学报, 2018, 31(5): 883-891.  
CHEN R X, HUANG X, YANG L X, et al. Rolling bearing fault identification based on convolution neural network and discrete wavelet transform [J]. Journal of Vibration Engineering, 2018, 31(5): 883-891.
- [5] 李益兵, 曹睿, 江丽. 基于稀疏滤波和长短期记忆网络的旋转机械故障诊断方法[J]. 振动与冲击, 2022, 41(19): 144-151, 187.  
LI Y B, CAO R, JANG L. Fault diagnosis method of rotating machinery based on sparse filter and long-short term memory network [J]. Journal of Vibration and Shock, 2022, 41(19): 144-151, 187.
- [6] ZHANG J, SUN Y, GUO L, et al. A new bearing fault diagnosis method based on modified convolutional neural networks [J]. Chinese Journal of Aeronautics, 2020, 33(2): 439-447.
- [7] 魏秀业, 程海吉, 贺妍, 等. 基于特征融合与 ResNet 的行星齿轮箱故障诊断 [J]. 电子测量与仪器学报, 2022, 36(5): 213-222.  
WEI X Y, CHENG H J, HE Y, et al. Fault diagnosis of planetary gearboxes based on feature fusion and ResNet [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(5): 213-222.
- [8] NIEPERT M, AHMED M, KUTZKOV K. Learning convolutional neural networks for graphs [C]. International Conference on Machine Learning. PMLR, 2016: 2014-2023.
- [9] HONG D F, GAO L R, YAO J, et al. Graph convolutional networks for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(7): 5966-5978.
- [10] XU X ZH, ZHAO X Y, WEI M, et al. A comprehensive review of graph convolutional networks: Approaches and applications [J]. Electronic Research Archive, 2023, 31(7): 4185-4215.
- [11] LI T F, ZHAO ZH B, SUN CH, et al. Multireceptive field graph convolutional networks for machine fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2021, 68(12): 12739-12749.
- [12] 孙康, 金江涛, 李春, 等. 基于改进经验小波变换与分形特征集的风力机齿轮箱故障诊断 [J]. 太阳能学报, 2023, 44(5): 310-319.  
SUN K, JIN J T, LI CH, et al. Fault diagnosis of wind turbine gearbox based on improved empirical wavelet transform and fractal feature set [J]. Acta Energetica Solaris Sinica, 2023, 44(5): 310-319.
- [13] YU X, TANG B, ZHANG K. Fault diagnosis of wind turbine gearbox using a novel method of fast deep graph convolutional networks [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-14.
- [14] 陈起磊, 蒋亦悦, 唐瑶, 等. 基于时频图与改进图卷积神经网络的异步电机故障诊断方法 [J]. 振动与冲击, 2022, 41(24): 241-248.  
CHEN Q L, JIANG Y Y, TANG Y, et al. An induction motor fault diagnosis method based on the time-frequency image method and an improved graph convolution network [J]. Journal of Vibration and Shock, 2022, 41(24): 241-248.
- [15] LI X, WANG W H, HU X L, et al. Selective kernel networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 510-519.
- [16] WANG Y, YANG M, ZHANG Y, et al. A bearing fault diagnosis model based on deformable atrous convolution and squeeze-and-excitation aggregation [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [17] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [J]. 2015, DOI: 10.48550/arXiv.1511.07122.
- [18] HAMILTON W, YING R, LESKOVEC J. Inductive representation learning on large graphs [C]. NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017.
- [19] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. ArXiv preprint arXiv: 1710.10903, 2017.
- [20] 余晓霞, 汤宝平, 魏静, 等. 强背景噪声条件下自适应图卷积神经网络的航空发动机附件机匣故障诊断方法 [J]. 仪器仪表学报, 2021, 41(8): 78-86.  
YU X X, TANG B P, WEI J, et al. Fault diagnosis for aero-engine accessory gearbox by adaptive graph convolutional networks under intense background noise conditions [J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 78-86.

## 作者简介



韩延, 2012 年于重庆大学获得学士学位, 2015 年于重庆大学获得硕士学位, 2020 年于重庆大学获得博士学位, 现为重庆邮电大学讲师, 主要研究方向为装备智能运维、深度学习、边缘计算等。

E-mail: hanyan@cqupt.edu.cn

**Han Yan** received his B. Sc. degree, M. Sc. degree and Ph. D. degree from Chongqing University in 2012, 2015 and 2020, respectively. He is currently a lecturer at Chongqing University of Posts and Telecommunications. His main research interests include equipment intelligent operation and maintenance, deep learning and edge computing.



黄庆卿(通信作者), 2009 年于重庆大学获得学士学位, 2015 年于重庆大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为工业物联网、边缘计算、机械故障预测与健康管理等。

E-mail: huangqq@cqupt.edu.cn

**Huang Qingqing** (Corresponding author) received his B. Sc. degree and Ph. D. degree from Chongqing University in 2009 and 2015, respectively. He is currently an associate professor at Chongqing University of Posts and Telecommunications. His main research interests include industrial internet of things, edge computing, and prognostics and health management of machine.