

# 多尺度图池化特征融合的集成智能故障诊断方法

张亚军<sup>1,2</sup>, 潘东辉<sup>1,3</sup>, 张先杰<sup>3</sup>, 张海峰<sup>1,3</sup>, 钟凯<sup>1,2</sup>, 刘永斌<sup>4</sup>

(1. 安徽大学计算智能与信号处理教育部重点实验室, 安徽 合肥 230601;

2. 安徽大学物质科学与信息技术研究院, 安徽 合肥 230601; 3. 安徽大学数学科学学院, 安徽 合肥 230601;

4. 安徽大学电气工程与自动化学院, 安徽 合肥 230601)

**摘要:** 图神经网络模型由于其丰富的故障表征能力,已在故障诊断领域得到广泛应用。然而现有模型在处理故障数据时仅利用相邻节点间的局部信息,未能充分提取全局特征信息,为了克服单一模型故障诊断精度不高和泛化能力不足的问题,提出一种基于多尺度图池化特征融合与图卷积网络(MSGP-GCN)的集成故障诊断方法。通过对原始信号构建图模型,使用图池化粗化得到全局信息。根据节点的度在不同尺度下分配权重,进而利用全局信息结合权重更新节点特征。将更新后的节点特征分别输入不同的分类器中,对分类结果使用多数投票策略实现智能故障诊断。在 SEU 仿真数据集和真实的磨煤机数据集上对所提出的方法进行验证,结果表明所提模型能够明显提高故障诊断的精度和泛化能力,平均诊断精度分别达到 98.31% 和 97.21%。

**关键词:** 故障诊断; 全局信息; 图池化; 图卷积网络; 多数投票策略

**中图分类号:** TH165<sup>+</sup>.3; TH133.33 **文献标志码:** A **文章编号:** 1004-4523(2024)12-2148-10

**DOI:** 10.16385/j.cnki.issn.1004-4523.2024.12.017

## 引言

旋转机械作为现代工业中的关键机械设备,长期在高温、疲劳、重载等复杂环境中运行,该类设备发生故障可能会引起严重的事故,甚至造成巨大的经济损失和人员伤亡<sup>[1]</sup>。为了提高旋转机械设备的运行效率,减少人力和财力的损失,可以通过对设备进行状态监测,进而诊断其健康状态。因此,如何准确诊断旋转机械设备的故障已成为故障诊断领域的研究热点<sup>[2]</sup>。

传统的智能故障诊断方法主要包括两个步骤:利用信号处理方法提取特征和利用机器学习方法进行故障分类。如人工神经网络<sup>[3]</sup>、支持向量机<sup>[4]</sup>和随机森林<sup>[5]</sup>等已应用于机械故障诊断领域。虽然基于传统的机器学习方法进行故障诊断已经取得了一定的效果,但由于模型的浅层结构,使得该类方法在处理复杂数据时的非线性学习能力受到了限制。相比于机器学习方法,深度学习具有深层结构和强大的非线性学习能力,可以提取更深层次、更具有表征能力的特征。以深层神经网络<sup>[6]</sup>、卷积神经网络(CNN)<sup>[7]</sup>、自动编码器(AE)<sup>[8]</sup>和递归神经网络

(RNN)<sup>[9]</sup>为代表的深度学习模型,在故障诊断领域得到了广泛的应用并取得了丰富的研究成果。例如,李霖蒲等<sup>[10]</sup>利用一维卷积神经网络提取特征,然后利用动态对抗学习策略动态地调整条件分布和边缘分布在迁移学习过程中的重要程度,从而实现滚动轴承的智能故障诊断。CHEN 等<sup>[11]</sup>提出了一种基于多传感器数据融合的智能故障诊断方法,其将提取的特征输入多个稀疏自动编码器中进行特征融合,融合后的特征向量可作为机器健康指标,并用于训练深度信念网络进行故障分类。

上述基于深度学习的模型仅能处理欧氏空间中的数据,忽略了数据之间的分布信息和几何结构,丰富的拓扑结构信息未能被充分利用。在这种背景下,图神经网络(GNN)的出现很好地解决了上述问题。GNN 旨在对图形数据进行建模来处理具有复杂特征关系的数据。GNN 模型已成功应用于诸多领域,如常识推理<sup>[12]</sup>、自然语言处理<sup>[13]</sup>、社交网络<sup>[14]</sup>和交通流预测<sup>[15]</sup>等。ZHAO 等<sup>[16]</sup>提出了多尺度图引导节点注意卷积网络的诊断方法,首先基于 Pearson 度量的无监督卷积自动编码器构造邻接矩阵,然后对不同节点上不同邻域信息进行加权融合,最后通过 GCN 实现故障分类。余晓霞等<sup>[17]</sup>提出了利

**收稿日期:** 2022-12-11; **修订日期:** 2023-02-09

**基金项目:** 国家自然科学基金资助项目(61973001,52075001);安徽省自然科学基金资助项目(2208085QF205);安徽省高校自然科学研究重点项目(2022AH050097,KJ2021A0071)。

用自适应图卷积神经网络对发动机附件机匣故障进行诊断的方法,对发动机机匣所采集的振动信号构建图模型,通过自适应图卷积核进行特征提取,利用全连接层实现故障诊断。

虽然图卷积神经网络已经在故障诊断领域中得到了广泛的应用<sup>[18]</sup>,但目前仍然存在两个问题:首先,在图卷积神经网络模型中,节点特征的更新主要是利用其邻居节点信息,而忽略了非邻居节点信息,然而在非邻居节点中也会存在非常重要的信息。因此,在更新节点信息时若不能充分使用全局信息进行更新,会导致更新后的节点信息特征表示不够丰富。其次,由于旋转机械设备的复杂性和数据的异质性,单一模型的故障诊断算法在处理该类问题时泛化能力将受到限制,从而使故障诊断精度降低。为了解决上述问题,本文提出了基于多尺度图池化特征融合与图卷积网络(MSGP-GCN)的集成故障诊断方法。首先对原始数据经过快速傅里叶变换(FFT)和数据归一化进行预处理,目的是对原始数据进行去噪和消除数据量纲不一致带来的不利影响,进而使用K-最近邻(KNN)构建图模型,将得到的图模型作为输入,经过图池化粗化得到全局信息,根据节点的度在不同尺度下分配权重大小来更新节点特征。然后将粗化得到的全局信息根据节点权重分配到每个节点,进一步对节点特征进行更新。最后将在不同尺度下更新的节点特征分别输入不同的GCN分类器中,根据每个GCN分类器的分类结果使用多数投票策略得到最终的故障诊断结果。

## 1 基本方法和理论

### 1.1 图卷积网络

GCN将卷积的思想从低维规则数据推广到高维不规则的图数据上。GCN按照卷积方式可以分为空间域卷积和谱域卷积两种。谱域卷积通过近似拉普拉斯矩阵的谱分解从谱域中提取图的结构特征。给定一个具有 $n$ 个节点特征的无向无权图 $G=(V, E, A)$ ,其中 $V=\{v_i; i=1, \dots, n\}$ 为图 $G$ 节点的集合, $E=\{e_{ij}=\langle v_i, v_j \rangle; i, j=1, \dots, n\}$ 为图 $G$ 连边的集合, $A \in \mathbb{R}^{n \times n}$ 为邻接矩阵,节点间的关系可表示为:

$$D_{i,j} = \begin{cases} 1, & \langle v_i, v_j \rangle \in E \\ 0, & \text{else} \end{cases} \quad (1)$$

拉普拉斯矩阵 $L$ 可以通过度矩阵 $D$ 和邻接矩阵 $A$ 的差定义:

$$L = D - A \quad (2)$$

式中 $D$ 为对角矩阵。

节点 $v_i$ 的度 $D_{ii}$ 为:

$$D_{ii} = \sum_j A_{ij} \quad (3)$$

使用对称归一化拉普拉斯算子,对称归一化拉普拉斯矩阵可以表示为:

$$L^{\text{sym}} = D^{-\frac{1}{2}} L D^{-\frac{1}{2}} = I - D^{-\frac{1}{2}} A D^{-\frac{1}{2}} \quad (4)$$

式中 $I$ 为单位矩阵,对称归一化拉普拉斯矩阵 $L^{\text{sym}}$ 为实对称半正定矩阵,因此可以得到:

$$L^{\text{sym}} = U \Lambda U^T \quad (5)$$

式中 $U$ 为由归一化拉普拉斯矩阵 $L^{\text{sym}}$ 的特征向量组成的正交矩阵; $\Lambda$ 为特征值的对角矩阵,则图上的谱域卷积可以表示为:

$$g_\theta x = U g_\theta(\Lambda) U^T x \quad (6)$$

式中 $g_\theta(\Lambda)$ 表示为 $L^{\text{sym}}$ 的特征值的函数,对于大型图来说,计算 $L^{\text{sym}}$ 的特征分解成本很高,因此式(6)的计算成本很高。为了解决这个问题,通过切比雪夫多项式的截断展开近似 $g_\theta$ ,进一步将其简化为一阶近似,然后添加了一个自循环,最终GCN的正向传递公式为:

$$Z = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} X \Theta) \quad (7)$$

式中 $\Theta$ 为可学习的参数矩阵; $\tilde{A} = A + I$ ; $\tilde{D}$ 为 $\tilde{A}$ 的度矩阵, $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ ; $X$ 为节点特征矩阵; $\sigma$ 为激活函数; $Z$ 为卷积后的图形信号。

### 1.2 Top-k池化

图池化可以减小特征图的大小,扩大接受域,从而产生更好的泛化性能。Top-k池化(Top-k Pooling, TKP)是一种常见的图池化方法,示意图如图1所示。经过TKP处理后的图可以变成更为稀疏的图结构,能够粗化得到图结构的全局特征信息,有利于处理数据量较大的图结构,减少内存和计算时间的消耗。TKP是直接选取 $k$ 个最重要的节点作为粗化节点,在图中只保留这些粗化节点之间的连接,因此粗化后的图是原图的一个子图。例如,给定一个具有 $n$ 个节点的图 $G$ ,每个节点特征维度为 $c$ 。图 $G$




图1 Top-k池化示意图

Fig. 1 Schematic diagram of Top-k pooling

可以用两个矩阵表示:邻接矩阵  $A \in \mathbf{R}^{n \times n}$ ,特征矩阵  $X \in \mathbf{R}^{n \times c}$ 。TKP对图数据进行下采样,然后自适应地选择一个节点子集来形成一个新的图  $G'$ 。图池化的分层传播规则为:

$$X' = X_i \odot \left( \text{TKP} \left( \frac{XP}{\|P\|} \right) \right) \quad (8)$$

$$A' = A(i, i) \quad (9)$$

式中  $P \in \mathbf{R}^{c \times 1}$  为一个可训练的投影向量,取节点特征  $X$  在投影向量  $P$  上的前  $k$  个投影值;  $\odot$  表示矩阵的数乘运算。通过将得到的前  $k$  个值与对应的节

点特征向量做矩阵乘积,进而得到池化后的节点特征。因此,池化后得到的图  $G'$  的邻接矩阵为  $A' \in \mathbf{R}^{k \times k}$ ,特征矩阵为  $X' \in \mathbf{R}^{k \times c}$ 。

## 2 MSGP-GCN 故障诊断方法

本节详细介绍 MSGP-GCN 故障诊断框架,包括构建图模型、图池化提取全局信息和使用集成方法实现故障诊断。所提出的 MSGP-GCN 智能故障诊断模型的总体流程如图 2 所示。

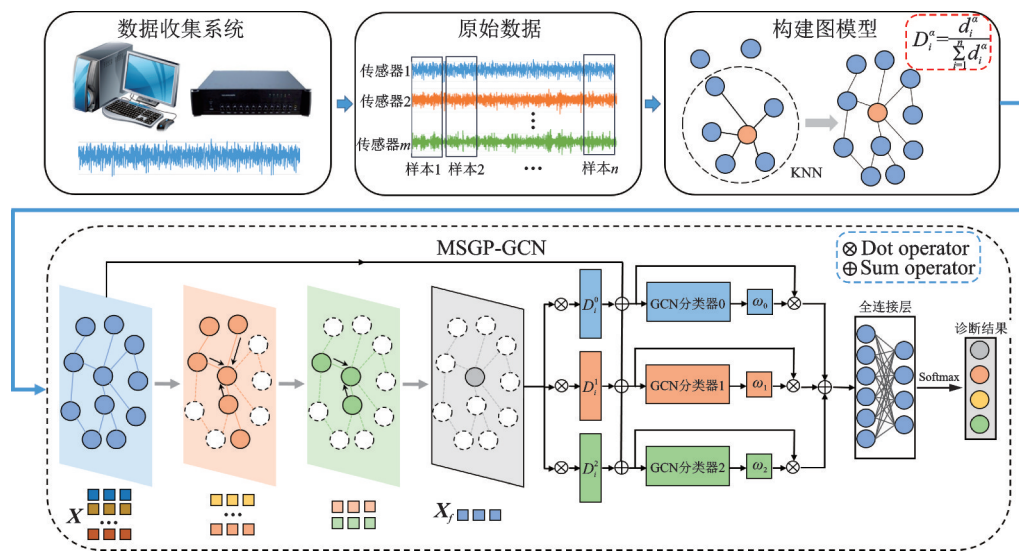


图 2 MSGP-GCN 框架流程图

Fig. 2 MSGP-GCN framework flow chart

### 2.1 构建图模型

由于信号的连续性和周期性,样本之间存在复杂的相关性,可以通过构建以信号块为节点的图模型来描述复杂的相关性,充分挖掘样本之间的特征信息。构建图模型的关键是要考虑到每个样本之间的连边关系,通过连边来表示样本之间复杂的结构关系。在获得连边关系之前,需要对时域信号进行预处理以获得有效的特征表示。为了消除数据中量纲对故障诊断的影响,首先对输入数据  $S$  进行数据最大-最小归一化:

$$S_{\text{norm}} = \frac{S - S_{\min}}{S_{\max} - S_{\min}} \quad (10)$$

式中  $S_{\text{norm}}$  为经过数据归一化处理的时域信号。

由于时域信号较平滑,故障识别能力有限且容易受到噪声干扰,将其作为输入很难得到有效的故障诊断结果。而谱域信号在发生故障时会有显著变化,因此对时域信号进行 FFT 得到频域信号<sup>[19]</sup>, FFT 过程可表示为:

$$X = \text{FFT}(S_{\text{norm}}) \quad (11)$$

式中  $X$  为经过 FFT 得到的频域信号。

对经过预处理后的数据  $X$  按照指定的样本长度进行划分,以获得多个样本。通过使用 KNN 相似性指标来计算不同样本间的相似度,进而构建图拓扑结构,以便于更好地表示样本之间复杂的结构关系。通过计算目标节点与其他节点之间的欧氏距离,选取欧氏距离最小的前  $K$  个节点作为邻居节点构建图拓扑结构,构图过程为:

$$D(x_i, x_j) = \sqrt{\sum_{i,j=1}^n (x_i - x_j)^2} \quad (12)$$

$$N(x_i) = \text{KNN}(D(x_i, x_j)) \quad (13)$$

式中  $D(x_i, x_j)$  表示节点  $x_i$  与节点  $x_j$  之间的欧氏距离;  $N(x_i)$  表示节点  $x_i$  的邻居节点,通过对节点  $x_i$  与其邻居节点  $N(x_i)$  构建连边,可得到图模型  $G(X, A)$ ,构图过程如图 3 所示。

### 2.2 利用图池化和集成方法更新节点特征

图池化通常接在图卷积后面保留图拓扑结构中重要节点的特征,稀疏图拓扑结构,减少网络的参数




图3 KNN 构图过程

Fig. 3 KNN construction graph process

数量。本文通过  $m(m=4)$  层图池化操作挖掘全局信息,首先利用图卷积层融合邻居节点的信息学习每个节点的特性表示,保留了卷积过程中的平移不变性,图卷积操作表示为:

$$H = GCN(X, A) \quad (14)$$

式中  $H$  表示经过图卷积更新后的节点特征,然后采用批量正则化和 ReLU 激活函数来加快网络的训练和收敛的速度,最后进行 TKP 保留重要节点的特征信息,粗化得到图结构的全局信息,如图 4 所示。图池化操作表示为:

$$X_f = TKP(H, A) \quad (15)$$

式中  $X_f \in \mathbb{R}^{1 \times c}$  表示图池化后得到的全局信息。

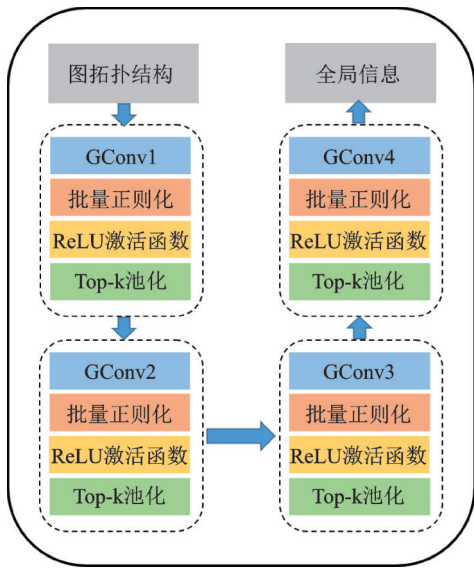


图4 全局信息提取过程

Fig. 4 Global information extraction process

为了充分利用图结构的全局信息和统计指标,本文引入权重因子  $\alpha$ ,在三种尺度的情况下为每个节点分配不同的权重。第一种情况下取  $\alpha = 0$ ,表示将粗化得到的全局信息平均分配到原始图模型中的每个节点中;第二种情况下取  $\alpha = 1$ ,表示根据节点度的大小分配不同的权重,节点的度越大,表明节点的信息特征越重要,节点的权重也越大,再将全局信息根据权重分配到每个节点中;第三种情况下取  $\alpha = 2$ ,表示使度大的节点权重占比更大,使度小的

节点权重占比更小,为了让节点之间的区分度更加明显,以便于突显出重要节点的信息<sup>[20]</sup>,节点特征的更新过程可表示为:

$$D_i^\alpha = \frac{d_i^\alpha}{\sum_{i=1}^n d_i^\alpha}; \alpha = 0, 1, 2 \quad (16)$$

$$\hat{X}_\alpha = D_i^\alpha \odot X_f + X \quad (17)$$

式中  $d_i^\alpha$  表示在权重因子为  $\alpha$  情况下第  $i$  个节点的度;  $D_i^\alpha \in \mathbb{R}^{n \times 1}$  表示在不同尺度下为节点分配的权重;  $\hat{X}_\alpha \in \mathbb{R}^{n \times n}$  表示更新后的节点特征。

为了避免出现使用单一模型在故障诊断中存在的泛化能力差和分类精度不佳的问题,本文使用集成学习方法将多个弱分类器融合后获得一个强分类器以达到更佳分类效果。将在不同尺度下更新的节点特征输入不同的 GCN 分类器中进行分类,根据分类准确率为每个尺度下的特征分配不同的权重,然后根据权重更新节点特征。

$$w_\alpha = \frac{Acc_\alpha}{\sum_{\alpha=0}^2 Acc_\alpha} \quad (18)$$

$$\tilde{X} = \sum_{\alpha=0}^2 (w_\alpha \odot \hat{X}_\alpha) \quad (19)$$

式中  $Acc_\alpha$  表示在权重因子为  $\alpha$  的情况下的分类精度;  $\tilde{X} \in \mathbb{R}^{n \times n}$  表示经过集成学习方法更新后的特征;  $w_\alpha$  为每个尺度下的特征分配权重,最后利用交叉熵损失的全连接网络和 Softmax 函数对更新后的特征进行故障分类。

### 3 试验验证

#### 3.1 数据集描述

**SEU 数据集** 东南大学 SEU 数据集包含齿轮和轴承的健康和故障数据集,该数据集利用动力传动系统模拟器收集。如图 5 所示,该模拟器平台由电机、制动器、控制器模块和两个测试齿轮箱组成。通过安装在驱动电机、行星齿轮箱和平行齿轮箱上




图5 SEU 齿轮箱试验台

Fig. 5 SEU gearbox test platform

的加速度传感器,以 5120 Hz 的频率对数据进行采样,模拟器的转速和负载配置分别为 20 Hz/2 V 和 30 Hz/2 V,不同工作条件下共收集 20 类。SEU 数据集包括两种工况下的 4 个轴承故障和 1 个正常状态。SEU 数据集的描述如表 1 所示。

表 1 SEU 数据集故障类型描述  
Tab. 1 Fault type description of SEU data set

故障位置	故障描述
轴承	健康的轴承
	滚珠出现裂纹
	内圈出现裂纹
	外圈出现裂纹
	内圈和外圈出现裂纹
齿轮箱	健康的齿轮
	齿轮脚出现裂纹
	齿轮脚缺失
	齿轮齿根出现裂纹
	齿轮表面发生磨损

**磨煤机数据集** 磨煤机组故障数据集来源于华东某电力公司磨煤机组的真实运行过程,其锅炉采用中速磨正压直吹式制粉系统,每炉配 6 台 MP265G 中速磨煤机,其中燃用设计煤种时 5 台运行,1 台备用,设计煤粉细度  $R_{90}=20\%$ 。每层 8 只燃烧器对应 1 台磨煤机,如图 6 所示。磨煤机数据采集时间为 15 个月(2019 年 9 月 1 日至 2021 年 3 月 25 日),正常数据每 5 min 采集一次,故障数据每 1 s 采集一次。运行过程中共采集 32 种故障。故障数据的信号采集由 172 个传感器完成,一共包含 32 类故障。磨煤机数据集的描述如表 2 所示。



图 6 磨煤机示意图

Fig. 6 Schematic diagram of coal mill

### 3.2 试验设置

设备故障数据在输入模型前首先进行最大-最小归一化处理。对于 SEU 数据集,以 128 个采样点为单位作为一个样本,即每个样本的特征维度为

表 2 磨煤机数据集通道描述

Tab. 2 Channel description of coal mill data set

编号	描述	编号	描述
1	滤网差压高	17	电机异常
2	燃烧器烧通	18	轴承转换
3	油泵振动异常	19	轴承温度升高
4	液压油泄漏	20	振动大
5	炉膛处喷火	21	振动噪声
6	风速异常	22	轴承振动
7	粉管泄漏	23	粉管泄漏
8	加载力变小	24	磨煤机振动
9	风机振动异常	25	电路损坏
10	液压压力异常	26	磨煤机电流晃动
11	加载力过低	27	振动异常
12	加载力异常	28	风速低
13	油压异常	29	风机振动大
14	内部漏油	30	空气预热器电流晃动
15	发出报警信号	31	弯头漏粉
16	电流大	32	磨煤机振动大

1024,通过 FFT 进行简单去噪和初步特征提取。对于磨煤机组故障数据集,将每个采样点作为一个样本,其特征维度为 172。SEU 数据集实验的任务为 20 类故障分类问题,每个类有 1000 个样本,总共 20000 个样本。磨煤机数据集的实验任务为 32 类故障分类问题,每类 800 个样本,训练、验证、测试数据集的比率为 6:2:2,随机进行数据分割。为了获得更准确的结果,每个试验进行 10 次以获得平均值。该框架使用 Pytorch Geometric 库实现,迭代训练 300 个 epoch;学习率为衰减学习率,初始学习率设置为 0.015,  $K=10$ ,并在实验中使用 Adam 优化器进行优化。

### 3.3 试验结果分析

为了获得最佳的诊断结果,分别在两个对比实验中讨论了池化层的层数  $m$  的大小对诊断准确率的影响。在  $m$  大小不同的情况下,诊断准确率的平均值如图 7 所示。从图 7 中可以看出诊断准确率会随池化层数  $m$  增加而提高。当  $m$  取值大于 4 后,模型的诊断准确率就会降低,可能是由于池化层数过深、数据过拟合,导致诊断准确率下降。因此当  $m$  取 4 时,模型在两个数据集上均取得最高的诊断准确率。SEU 数据集和磨煤机数据集的最高准确率分别为 98.42% 和 97.39%。因此,后续的试验结果都是基于 4 层池化层的模型进行试验。

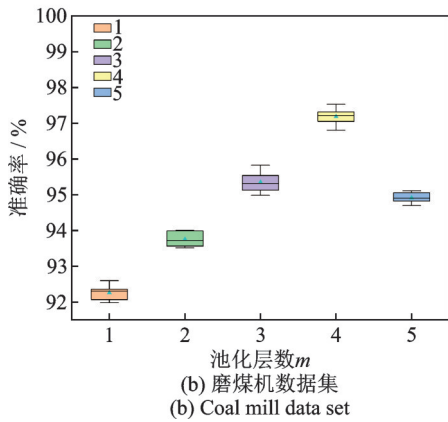
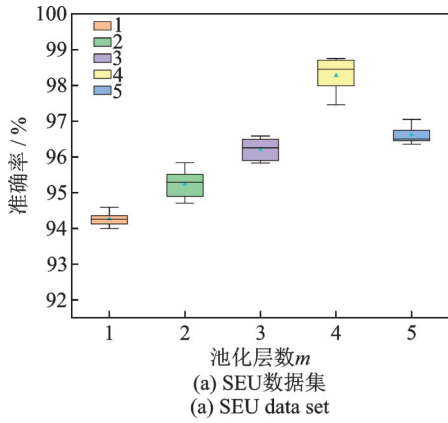


图 7 不同池化层数的诊断准确率

Fig. 7 Diagnostic accuracy for different pooling layers


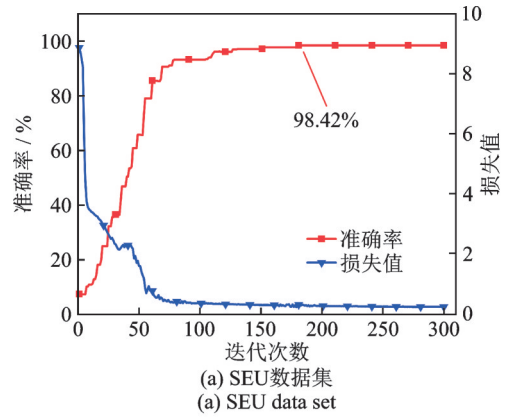


图 8 训练损失和诊断准确率曲线

Fig. 8 Training loss and diagnostic accuracy curves

通过展示 MSGP-GCN 模型的不同迭代次数的损失值和诊断准确率来可视化该模型的训练收敛过程,图 8 给出了该模型在两个数据集上的训练损失值和诊断准确率。从图 8 中可以看出,本文所提出的模型具有良好的收敛性能。在 SEU 数据集上训练 181 个 epoch 达到收敛效果,准确率为 98.42%;在磨煤机数据集上训练 211 个 epoch 达到收敛效果,准确率为 97.39%。这表明本文提出的模型的训练过程是比较平稳的,且具有较好的适用性和良好的故

障诊断性能。

为了验证本文所提方法对故障诊断的有效性和稳定性,本文将 MLP, GCN, HoGCN<sup>[21]</sup>, MRF-GCN<sup>[22]</sup>, MSGP-GCN-e 和 MSGP-GCN 进行比较,取 10 次诊断准确率的平均值如表 3 所示。由表 3 可以看出,MSGP-GCN 模型在两个数据集上的平均诊断准确率最高,分别为 98.31% 和 97.21%,且该模型的标准差最小。与不加集成方法的 MSGP-GCN-e 模型相比,MSGP-GCN 模型诊断精

表 3 不同方法在两个数据集上的诊断准确率

Tab. 3 Diagnostic accuracy of different methods for two data sets

数据集	方法	最大准确率/%	最小准确率/%	平均准确率/%	标准差/%
SEU 数据集	MLP	93.20	80.60	90.52	5.05
	GCN	95.50	89.45	94.37	3.53
	HoGCN	97.02	94.33	95.60	1.98
	MRFGCN	98.06	96.80	97.05	0.85
	MSGP-GCN-e	98.35	95.23	96.85	1.05
	MSGP-GCN	99.05	98.03	98.31	0.53
磨煤机数据集	MLP	77.35	53.05	57.36	4.98
	GCN	93.26	88.31	90.59	2.07
	HoGCN	94.38	90.25	92.92	1.53
	MRFGCN	96.26	94.03	94.86	0.83
	MSGP-GCN-e	96.05	94.93	95.13	0.43
	MSGP-GCN	98.03	97.01	97.21	0.34

度分别提高了1.46%和2.08%,说明使用集成方法的必要性。而MLP是简单的神经网络,不能有效地提取特征,因此诊断性能最差。GCN和HoGCN都只是在同一尺度下聚合邻居节点信息,而没有使用多尺度下的节点信息,虽然诊断性能优于MLP,但仍有提升的空间。MRFGCN是一种融合多个感受野的故障诊断方法,能够有效地提取特征,在两个数据集上的平均诊断准确率分别达到了97.05%和94.86%。相比之下,在两个数据集中MSGP-GCN模型不仅有最佳的故障诊断性能,而且有最好的稳定性。

为了展示本文所提方法获得的特征可视化结果,通过t分布随机邻居嵌入(t-SNE)方法对特征提取器的最后一层特征进行可视化,结果如图9所示,两个数据集中的原始样本特征中的可视化是相互重叠的,且重叠部分较多,类别之间很难区分。通过本文所提方法对特征进行提取,再通过t-SNE可视化后可以看出,两个数据集上的特征都能很好达到理想的分类效果,仅有较少样本分类错误。

通过使用在不同尺度下获得的节点特征样本集训练分类器,然后对每一个分类器的分类结果以多数投票的方式获得最终的诊断结果。如图10所示,在两个数据集中单个分类器的最高准确率为96.78%和96.05%,而集成分类器的准确率为98.42%和97.39%,准确率分别提高了1.64%和1.34%。由此说明,集成分类器优于单一分类器,集成分类器可以显著提高故障诊断的准确率。

为了展示在两个数据集中每一类故障的分类准确率,使用GCN模型和MSGP-GCN模型的诊断结果构建雷达图。如图11所示,在SEU数据集中故障类型2、类型5、类型7和类型19的诊断准确率显著提高,尤其是类型19在MSGP-GCN模型的分类准确率为98.53%,而在GCN模型的分类准确率为76.98%,对于磨煤机数据集来说,故障类型15和类型17的分类准确率差距尤为明显。MSGP-GCN模型的故障诊断准确率普遍比GCN模型的故障诊断准确率高,模型的诊断性能更稳定。

为了验证本文所提方法的诊断性能,表4列出了MSGP-GCN方法与对比算法在两个数据集上训练时用到的参数量。由表4可知,MLP和GCN的参数量相对较少,因为这两种方法结构较为简单,且其诊断准确率较差。HoGCN和MRFGCN的模型结构较为复杂,所以参数量也较多。MSGP-GCN的参数量相比于MLP和GCN较多,但是MSGP-GCN方法在诊断性能方面表现良好,且本

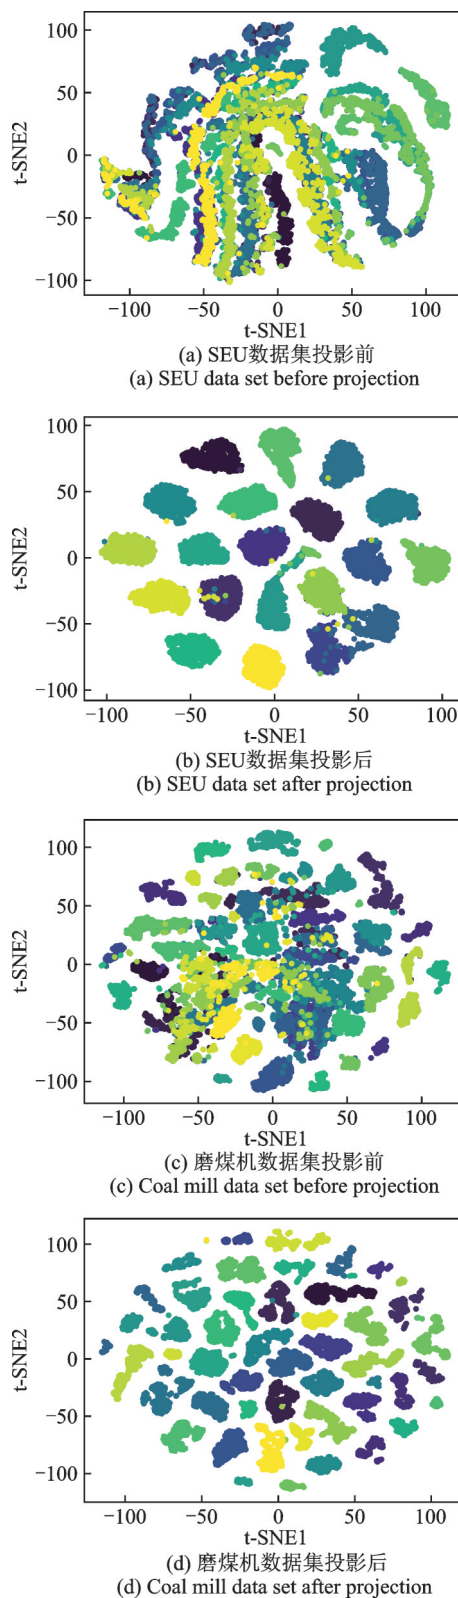


图9 t-SNE可视化结果

Fig. 9 t-SNE visualization results

文所提的方法由于使用图池化结构,所以每经过一次池化操作之后网络的节点个数都会有一定程度的减少,而其他对比算法每次都是遍历网络中所有的节点信息进行特征更新,算法的复杂度远远超过本文所提方法,所以整体来说本文所提方法优于上述对比算法。

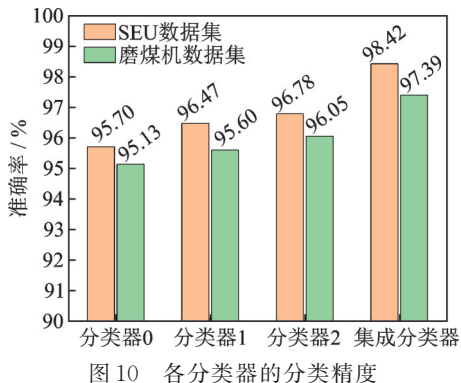


Fig. 10 Classification accuracy of each classifier

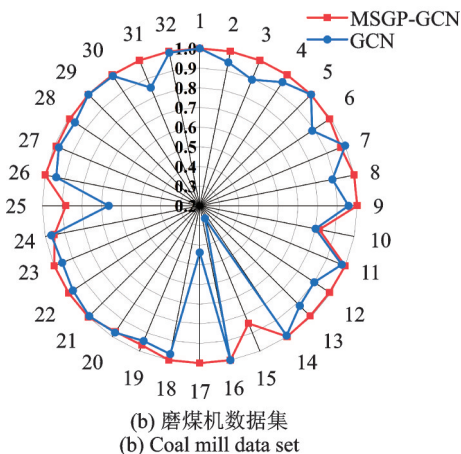
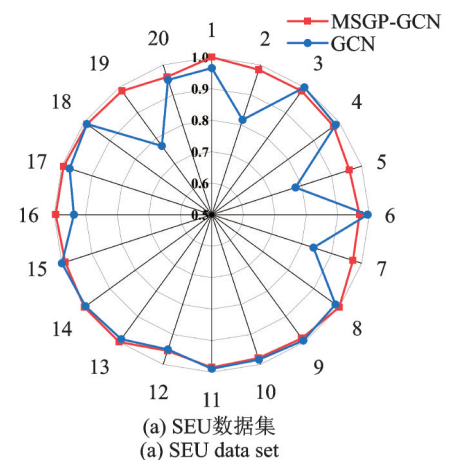


图 11 每一类故障的分类准确率

Fig. 11 Classification accuracy of each fault category

表 4 不同方法在两个数据集上的参数量

Tab. 4 Number of parameters of different methods for two data sets

方法	参数量	
	SEU数据集	磨煤机数据集
MLP	166400	87040
GCN	173312	150528
HoGCN	311072	256000
MRFGCN	524288	352256
MSGP-GCN-e	257676	218124
MSGP-GCN	258576	219024

## 4 总结及展望

本文针对故障诊断中现有 GNN 模型在节点更新时未能充分利用全局信息以及单一故障诊断模型泛化能力不足的问题,提出了基于图池化特征融合的集成智能故障诊断方法。通过对原始信号构建图模型,利用图池化粗化得到全局特征信息,根据不同尺度下节点的权重将全局信息分配到每个节点中进行特征更新,以达到充分使用全局信息更新节点特征的目的。然后将不同尺度下更新的节点特征分别输入不同的分类器中,根据不同分类结果采用集成方法对节点特征进行自适应更新,克服了使用单一模型造成的泛化能力较差的问题。本文在两个故障数据集上验证了所提模型在故障诊断中具有更高的准确率和鲁棒性。

本文的研究受限于要求每个类别的样本数量差异不大,而在实际工业应用中,正常数据量往往远大于故障数据量,会导致样本不平衡问题。在后续工作中将进一步研究利用数据增强方法来缓解样本不平衡对故障诊断造成的影响。

### 参考文献:

[1] 任磊,贾子翟,赖李媛君,等. 数据驱动的工业智能: 现状与展望[J]. 计算机集成制造系统, 2022, 28(7): 1913-1939.  
REN Lei, JIA Zizhai, LAI Liyuanjun, et al. Data-driven industrial intelligence: current status and future directions [J]. Computer Integrated Manufacturing System, 2022, 28(7): 1913-1939.

[2] 杨超,彭涛,阳春华,等. 高速列车牵引传动系统故障测试与验证仿真平台研究[J]. 自动化学报, 2019, 45(12): 2218-2232.  
YANG Chao, PENG Tao, YANG Chunhua, et al. Fault testing and validation simulation platform for traction drive system of high-speed trains [J]. Acta Automatica Sinica, 2019, 45(12): 2218-2232.

[3] 张攀,高文志,高博,等. 基于人工神经网络的柴油机失火故障诊断[J]. 振动、测试与诊断, 2020, 40(4): 702-710.  
ZHANG Pan, GAO Wenzhi, GAO Bo, et al. Misfire detection of diesel engine based on artificial neural networks [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(4): 702-710.

[4] 张瑞,李可,宿磊,等. 深度稀疏最小二乘支持向量机故障诊断方法研究[J]. 振动工程学报, 2019, 32(6): 1104-1113.



- ZHANG Rui, LI Ke, SU Lei, et al. Fault diagnosis method of deep sparse least squares support vector machine[J]. *Journal of Vibration Engineering*, 2019, 32(6): 1104-1113.
- [5] 丁家满, 吴晔辉, 罗青波, 等. 基于深度森林的轴承故障诊断方法[J]. *振动与冲击*, 2021, 40(12): 107-113.
- DING Jiaman, WU Yehui, LUO Qingbo, et al. A fault diagnosis method of mechanical bearing based on the deep forest[J]. *Journal of Vibration and Shock*, 2021, 40(12): 107-113.
- [6] 周陈林, 董绍江, 李玲, 等. 滚动轴承多状态特征信息的改进型卷积神经网络故障诊断方法[J]. *振动工程学报*, 2020, 33(4): 854-860.
- ZHOU Chenlin, DONG Shaojiang, LI Ling, et al. Method to improve convolutional neural network in rolling bearing fault diagnosis with multi-state feature information[J]. *Journal of Vibration Engineering*, 2020, 33(4): 854-860.
- [7] 宫文峰, 陈辉, 张泽辉, 等. 基于改进卷积神经网络的滚动轴承智能故障诊断研究[J]. *振动工程学报*, 2020, 33(2): 400-413.
- GONG Wenfeng, CHEN Hui, ZHANG Zehui, et al. Intelligent fault diagnosis for rolling bearing based on improved convolutional neural network[J]. *Journal of Vibration Engineering*, 2020, 33(2): 400-413.
- [8] 王奉涛, 邓刚, 王洪涛, 等. 基于EMD和SSAE的滚动轴承故障诊断方法[J]. *振动工程学报*, 2019, 32(2): 368-376.
- WANG Fengtao, DENG Gang, WANG Hongtao, et al. A rolling bearing fault diagnosis method based on EMD and SSAE[J]. *Journal of Vibration Engineering*, 2019, 32(2): 368-376.
- [9] TANG Y, ZHANG X F, ZHAI Y J, et al. Rotating machine systems fault diagnosis using semisupervised conditional random field-based graph attention network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3521010.
- [10] 李霁蒲, 黄如意, 陈祝云, 等. 一种用于主轴轴承故障诊断的深度卷积动态对抗迁移网络[J]. *振动工程学报*, 2022, 35(2): 446-453.
- LI Jipu, HUANG Ruyi, CHEN Zhuyun, et al. A deep convolutional dynamic adversarial transfer network for spindle bearing fault diagnosis[J]. *Journal of Vibration Engineering*, 2022, 35(2): 446-453.
- [11] CHEN Z Y, LI W H. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(7): 1693-1702.
- [12] CHEN X J, JIA S B, XIANG Y. A review: knowledge reasoning over knowledge graph[J]. *Expert Systems with Applications*, 2020, 141: 112948.
- [13] YAO L, MAO C S, LUO Y. Graph convolutional networks for text classification[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1): 7370-7377.
- [14] 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.
- [15] HAO P, WANG H F, DU B W, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting[J]. *Information Sciences*, 2020, 521: 277-290.
- [16] ZHAO B, ZHANG X M, ZHAN Z H, et al. Multi-scale graph-guided convolutional network with node attention for intelligent health state diagnosis of a 3-PRR planar parallel manipulator[J]. *IEEE Transactions on Industrial Electronics*, 2021, 69(11): 11733-11743.
- [17] 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, 42(8): 78-86.
- YU Xiaoxia, TANG Baoping, WEI Jing, 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, 42(8): 78-86.
- [18] 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.
- [19] 雷春丽, 夏奔锋, 薛林林, 等. 优化深度残差网络及其在强噪声环境下滚动轴承故障诊断中的应用[J]. *振动工程学报*, 2023, 36(6): 1754-1763.
- LEI Chunli, XIA Benfeng, XUE Linlin, et al. Optimized deep residual network and its application in fault diagnosis of rolling bearing under the strong noise condition[J]. *Journal of Vibration Engineering*, 2023, 36(6): 1754-1763.
- [20] ZHAO X L, YAO J Y, DENG W X, et al. Multi-scale deep graph convolutional networks for intelligent fault diagnosis of rotor-bearing system under fluctuating working conditions[J]. *IEEE Transactions on Industrial Informatics*, 2022, 19(1): 166-176.
- [21] KISHAN K C, LI R, CUI F, et al. Predicting biomedical interactions with higher-order graph convolutional networks[J]. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2021, 19(2): 676-687.

- [22] 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.

## Ensemble intelligent fault diagnosis method based on multi-scale graph pooling feature fusion

ZHANG Ya-jun<sup>1,2</sup>, PAN Dong-hui<sup>1,3</sup>, ZHANG Xian-jie<sup>3</sup>, ZHANG Hai-feng<sup>1,3</sup>, ZHONG Kai<sup>1,2</sup>,  
LIU Yong-bin<sup>4</sup>

(1.Key Laboratory of Intelligent Computing and Signal Processing of the Ministry of Education, Anhui University, Hefei 230601, China; 2.Institutes of Physical Science and Information Technology, Anhui University, Hefei 230601, China; 3.School of Mathematical Sciences, Anhui University, Hefei 230601, China; 4.School of Electrical Engineering and Automation, Anhui University, Hefei 230601, China)

**Abstract:** The graph neural network models have been widely used in the field of fault diagnosis due to the advantage of abundant fault characterization capabilities. However, the existing models only utilize the local information among neighboring nodes when dealing with fault data, and fail to fully extract the global feature information. Meanwhile, in order to overcome the problems of low accuracy and insufficient generalization ability of single model. This paper proposes an ensemble method with multi-scale graph pooling feature fusion and graph convolutional network (MSGP-GCN). The graph model is constructed from the original signal, and global information is obtained using graph pooling coarsening. Then weights are assigned at different scales based on the degree of the nodes, and the global information is used to update the node features in combination with the weights. The updated node features are input into different classifiers respectively, and the intelligent fault diagnosis result is obtained by majority voting strategy among these classification results. The proposed approach is fully verified by two fault datasets, the SEU simulation dataset and the real coal mill dataset. The experimental results show that the proposed model can effectively improve fault diagnostic accuracy and generalization ability in aforesaid two real datasets, and the average diagnostic accuracy reaches 98.31% and 97.21%, respectively.

**Key words:** fault diagnosis; global feature information; graph pooling; graph convolutional network; majority voting strategy

**作者简介:** 张亚军(1998—),男,硕士研究生。E-mail: zhangyajun@stu.ahu.edu.cn。

**通讯作者:** 潘东辉(1984—),男,博士。E-mail: dhpan@ahu.edu.cn。