

时-空特征驱动的多轮次重构图卷积网络故障诊断方法

王庆昕¹, 张先杰², 张海峰², 钟 凯^{1†}, 陈宏田³, 韩 敏⁴

(1. 安徽大学 计算智能与信号处理教育部重点实验室, 物质科学与信息技术研究院, 安徽 合肥 230601;

2. 安徽大学 数学科学学院, 安徽 合肥 230601; 3. 阿尔伯塔大学 化学与材料工程系, 加拿大 埃德蒙顿 AB T6G 2V4;

4. 大连理工大学 工业装备智能控制与优化教育部重点实验室, 辽宁 大连 116024)

摘要: 近年来, 图神经网络被广泛应用于处理具有非欧结构的工业过程数据. 然而由于设备运行的过程数据常常受到噪声和冗余信息的干扰, 如果直接使用原始信号会导致构建的图模型不够精细和准确, 从而影响后续的诊断性能. 针对这一问题, 本文提出了一种时-空特征驱动的多轮次重构图卷积网络(STMR-GCN)故障诊断方法. 该方法首先利用多尺度卷积神经网络与GCN对故障信号进行特征提取. 然后根据样本之间的余弦相似性对图结构进行多次重构, 重构后的图模型能够更精确地反映样本之间的连边关系, 并将得到的图模型输入到GCN进行故障种类的识别. 最后, 在东南大学(SEU)仿真数据集和真实的磨煤机数据集上进行实验, 实验结果表明所提方法与其他对比方法相比诊断精度均有提高, 从而证明STMR-GCN模型在故障诊断方面的有效性和实用性.

关键词: 故障诊断; 时空特征; 多轮次图重构; 图卷积网络

引用格式: 王庆昕, 张先杰, 张海峰, 等. 时-空特征驱动的多轮次重构图卷积网络故障诊断方法. 控制理论与应用, 2025, 42(1): 149 – 157

DOI: 10.7641/CTA.2023.21063

Fault diagnosis method driven by spatial-temporal features-based multi-round reconstructed GCN

WANG Qing-xin¹, ZHANG Xian-jie², ZHANG Hai-feng², ZHONG Kai^{1†},
CHEN Hong-tian³, HAN Min⁴

(1. Key Laboratory of Intelligent Computing and Signal Processing of the Ministry of Education,
Institutes of Physical Science and Information Technology, Anhui University, Hefei Anhui 230601, China;

2. School of Mathematics Science, Anhui University, Hefei Anhui 230601, China;

3. Department of Chemical and Materials Engineering, University of Alberta, Edmonton AB T6G 2V4, Canada;

4. Key Laboratory of Intelligent Control and Optimization for Industrial Equipment of Ministry of Education,
Dalian University of Technology, Dalian Liaoning 116024, China)

Abstract: Recently, graph neural networks have been widely used to handle industrial process data with non-Euclidean structures. However, since the process data of equipment operation is often disturbed by noises and redundant information, the direct use of raw signal to construct a graph model will result in a less accurate graph structure, thus affecting the subsequent performance of the model diagnosis. A multi-round reconstructed graph convolutional network (GCN) fault diagnosis method that driven by spatial-temporal features (STMR-GCN) is proposed. The method firstly uses multi-scale convolutional neural network with GCN for feature extraction of fault signals. Then, graph structure will be reconstructed several times according to the cosine similarity between samples, and reconstructed graph model can reflect the connected edge relationship between samples more accurately. The obtained graph model is input to GCN to realize identification of fault types. Finally, experiments are conducted on Southeast University (SEU) simulation dataset and the real coal mill dataset, and experimental results show that the proposed method improves diagnosis accuracy compared with other comparative methods, which indicates the effectiveness and feasibility of STMR-GCN model in fault diagnosis.

Key words: fault diagnosis; spatial-temporal features; multi-round graph reconstruction; graph convolutional network

Citation: WANG Qingxin, ZHANG Xianjie, ZHANG Haifeng, et al. Fault diagnosis method driven by spatial-temporal features-based multi-round reconstructed GCN. *Control Theory & Applications*, 2025, 42(1): 149 – 157

收稿日期: 2022-12-06; 录用日期: 2023-11-10.

†通信作者. E-mail: kaizhong0402@ahu.edu.cn; Tel.: +86 18356951430.

本文责任编辑: 刘淑君.

国家自然科学基金项目(61973001), 安徽省自然科学基金项目(2208085QF205), 安徽省高等学校自然科学基金项目(2022AH050097)资助.

Supported by the National Natural Science Foundation of China (61973001), the Anhui Provincial Natural Science Foundation (2208085QF205), the Natural Science Foundation of the Higher Education Institutions of Anhui Province (2022AH050097).

1 引言

随着现代工业水平的发展,机械设备的集成化与自动化程度越来越高.与此同时,人们对机械系统高性能、安全性和可靠性的需求也与日俱增.因此,对机械设备的运行状态进行监测和故障诊断具有重要意义^[1-2].基于机理模型的故障诊断方法是最早被广泛使用的技术,其核心思想是构建设备的数学模型以实现故障分类.然而这种方法需要大量的先验知识,且更适用于输入、输出或状态变量较少的情况.随着数据采集和存储技术的发展,基于数据的智能故障诊断方法受到学术界和工业界的普遍关注.作为典型的数据驱动方法,深度学习模型具有强大的非线性映射和特征表示能力,可以在没有先验知识的情况下直接从原始信号中学习代表性特征,同时实现故障分类^[3].近年来,各种基于深度学习的方法,如卷积神经网络(convolutional neural network, CNN)^[4]、自动编码器^[5]、深度信念网络^[6]和递归神经网络^[7]等已被广泛应用于故障诊断.

基于深度学习的方法可以有效地捕获常规数据的隐藏特征,但忽略了非欧结构数据(不具备平移不变性的数据,如知识图谱数据、化学成分结构数据等)或多个传感器的各种物理测量之间的相互依赖性.为了解决这一问题,越来越多的研究考虑数据之间的关系,并以图结构来对信号数据进行建模.在这一背景下,图神经网络模型在故障诊断领域迅速发展^[8-10].例如,文献[11]基于图论的频谱分析构建时空图用于提取故障信号中的深层隐藏特征,可以有效地获取数据中的拓扑信息.在此基础上,文献[12]引入注意力机制自适应学习边权重,使用多个独立的图神经网络块提取子图特征,并成功应用于电力系统的故障诊断.随后,文献[13]针对工程实践中标记数据匮乏的问题提出了一种半监督多尺度注意感知图卷积网络(graph convolutional network, GCN),从而实现对大量未标记样本信息的有效利用.近期,文献[14]进一步对于无标签的工业场景设计了一种智能故障诊断框架,该框架基于胶囊网络、自编码器和图卷积网络,充分挖掘了样本间的辅助信息,且在真实和仿真的实验中都验证了方法的有效性.

尽管图神经网络在故障诊断领域已经取得了良好的效果,但是之前的工作仍然存在着一个共同的问题:传统的图神经网络往往基于信号的原始特征,即先验信息来计算样本对之间的相似性,再使用 K 近邻(K nearest neighbors, KNN)算法构建图模型.然而,原始信号中可能存在大量的噪声和冗余信息,这会导致虚假连边或真实连边关系被忽略的问题,从而使得构建的图模型不够准确.并且图模型的性能与参数 k 的选择密切相关.针对以上问题,本文提出了一种时-空特

征(时间特征和空间特征)驱动的多轮次(每次迭代进行多次)重构图卷积网络(spatial-temporal features driven multi-round reconstructed GCN, STMR-GCN)故障诊断方法.本文的主要贡献点总结如下:

1) 利用多尺度CNN和GCN对原始信号数据进行特征提取,在去除信号样本中的噪声和冗余信息的同时充分提取其中的时间和空间信息,因此得到的特征图包含更加丰富的数据信息;

2) 通过对图结构进行多轮次重构得到更精准的图模型,可以更准确地反映样本之间的连边关系,避免了由于GCN聚合错误的连边信息而导致模型诊断性能下降的问题,并且可以通过自适应地调整轮次数提高模型的可拓展性;

3) 在SEU仿真数据集和真实的磨煤机运行数据集上验证本文提出的STMR-GCN框架,实验结果表明所提方法与其他基于深度学习的故障诊断方法相比,具有更好的鲁棒性及更高的诊断精度.

2 图卷积网络

GCN是一种基于卷积思想的有效图表征学习模型.按照卷积方式的不同可以分为两类:谱域图卷积和空域图卷积.谱域图卷积有着丰富的理论基础,本文主要介绍谱域图卷积.

设一个无向图可以记为 $G=(V, E)$,其中 $V=\{v_1, v_2, \dots, v_n\}$ 为顶点集, $E \subseteq V \times V$ 为边集,则可以得到邻接矩阵 $A \in \mathbb{R}^{n \times n}$.对于图 G 中的顶点对 (v_i, v_j) , A_{ij} 的值可以记为

$$A_{ij} = \begin{cases} 1, & \text{如果}(v_i, v_j) \subseteq E, \\ 0, & \text{其他.} \end{cases} \quad (1)$$

进一步,可以得到图的拉普拉斯矩阵

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

其中: D 是对角度矩阵, D_{ii} 是节点 V_i 的度, $D_{ii} = \sum_j A_{ij}$.使用对称归一化拉普拉斯算子,可以表示为

$$L^{\text{sym}} = D^{-\frac{1}{2}} L D^{-\frac{1}{2}} = I - D^{-\frac{1}{2}} A D^{-\frac{1}{2}}, \quad (3)$$

其中 I 是单位矩阵,对称归一化拉普拉斯矩阵 L^{sym} 是实对称半正定矩阵.因此可以得到

$$L^{\text{sym}} = U \Lambda U^T, \quad (4)$$

其中: U 是归一化拉普拉斯矩阵 L^{sym} 的特征向量组成的正交矩阵, $\Lambda = \text{diag}\{\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_n\}$ 是特征值的对角矩阵.图上的谱域卷积可以定义为

$$h = g_\theta * x = U g_\theta(\Lambda) U^T x, \quad (5)$$

其中: x 为节点特征, h 是图卷积之后得到的特征图, g_θ 可以看作特征函数, θ 是可学习的参数.

由于式(5)的计算复杂度较高,为了解决这一问题,通过切比雪夫多项式的截断展开近似 g_θ ,并进一步将

其简化为一阶近似及添加一个自循环, 同时, 为了增加卷积的非线性, 使用激活函数对卷积的结果进行非线性激活, 最终卷积运算记为

$$Z = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} XW), \quad (6)$$

其中: $\tilde{A} = A + I$, \tilde{D} 是 \tilde{A} 的度矩阵, W 是可学习的参数

矩阵, X 是节点的特征矩阵, Z 是卷积后的特征矩阵.

3 STMR-GCN故障诊断方法

本节将详细介绍所提出的STMR-GCN方法如何进行故障诊断, 图1给出了方法的整体框架. 下面将具体介绍所提方法的主要模块.

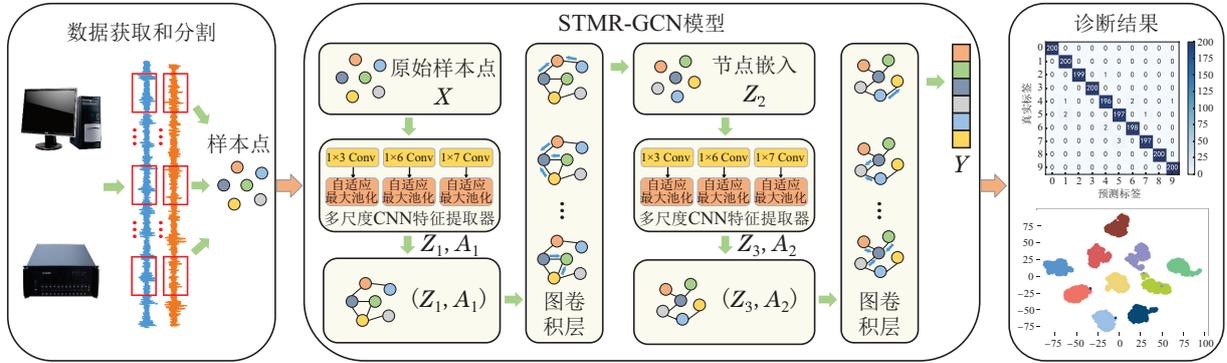


图 1 STMR-GCN故障诊断模型

Fig. 1 STMR-GCN fault diagnosis model

3.1 基于多尺度CNN和GCN的时空特征提取模型

在实际工业背景中, 原始信号往往会受到噪声和冗余信息的干扰, 本文采用多尺度CNN和GCN进行去噪并提取信号的时空特征. 时间特征提取器如图2所示, 对于长度为 L 的原始信号 S , 首先对其进行最大最小归一化处理, 以去除信号中的冗余信息及消除不同特征量纲的影响, 该过程可表示为

$$S_{\text{norm}} = \frac{S - S_{\min}}{S_{\max} - S_{\min}}. \quad (7)$$

数据进行归一化之后, 按照指定的样本长度对信号进行切分, 以获取多个样本. 通过为每个样本分配标签, 可以得到一个有标签的数据集, 记为

$$D = \{(x_i, y_j) | i \in 1, 2, \dots, n; j \in 1, 2, \dots, c\}, \quad (8)$$

其中: n 为样本个数, c 为类别数.

本文考虑使用具有不同大小卷积核的滤波器来对原始信号进行去噪同时提取多尺度时间信息. 将卷积滤波器记为 $f_{1 \times s}$, 其中 s 为滤波器大小, 由经验所得. 对样本 X 的卷积操作可以表示为

$$X_{(k)} = \sigma(f_{1 \times s} * X + b), \quad k = 1, 2, 3. \quad (9)$$

其中: $*$ 是卷积算子, b 是偏置值, σ 为非线性激活函数, $X_{(k)}$ 是经过不同大小卷积核卷积后得到的特征图. 本文选择修正线性单元ReLU作为激活函数, 以防止梯度消失问题和加速模型的收敛.

然后, 将得到的特征向量输入到池化层中, 这一步是为了提取最重要和位置不变的特征, 并且提高计算效率, 采用的自适应最大池化如下所示:

$$\hat{X}_{(k)} = \alpha \cdot \text{down}(X_{(k)}) + b, \quad (10)$$

其中: α 为常数, 用于调整池化层的数据; $\text{down}(\cdot)$ 表示下采样过程.

最后, 将学习到的样本特征向量进行拼接, 以融合信号中包含的不同时间尺度的信息, 可表示为

$$Z_1 = [\hat{X}_{(1)} \hat{X}_{(2)} \hat{X}_{(3)}]. \quad (11)$$

得到的特征图用于重构图模型, 并输入到GCN中提取空间特征.

3.2 基于时-空特征的多轮次图重构和故障诊断

通过构建图模型并利用GCN提取高阶特征, 模型可以更好地挖掘存在于样本之间的潜在信息. 原始特征中存在噪声和冗余信息, 这会导致难以得到准确的图结构从而影响后续的诊断精度.

因此, 本文设计了一个基于时空特征提取器的深度学习模型帮助学习节点表示及邻接矩阵, 以完成对

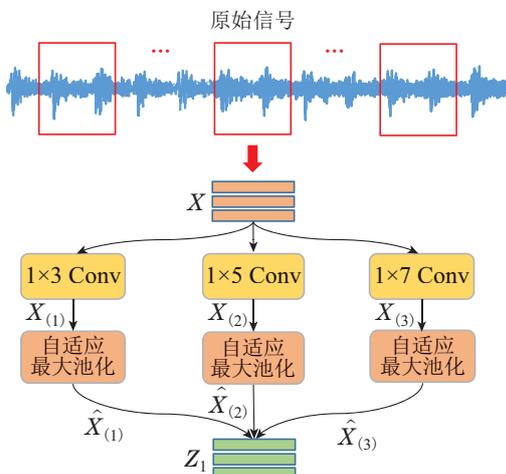


图 2 多尺度CNN特征提取器

Fig. 2 Multi-scale CNN feature extractor

图结构的重构,其中时空特征提取器由一个多尺度CNN和一个GCN组成.图重构过程如图3所示.值得注意的是,通过实验确定,在STMR-GCN模型中,时空特征提取及图重构次数设置为2.下面是具体的细节.

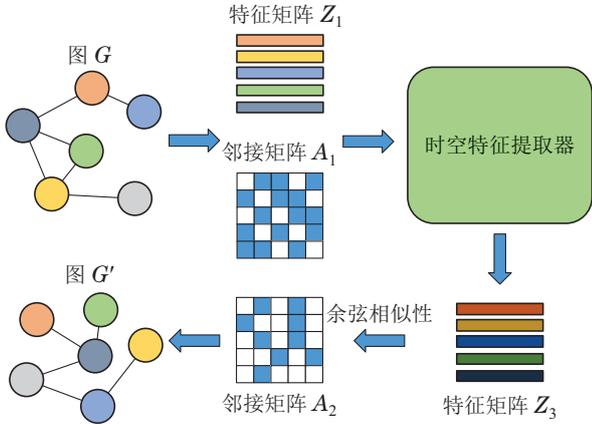


图3 基于时空特征提取的图重构

Fig. 3 Graph reconstruction based on spatial-temporal feature extraction

对于更新后的节点特征矩阵 Z_1 ,通过计算余弦相似性来刻画任意两个节点对 (v_i, v_j) 之间的相似性,即

$$s_{ij} = \frac{x_i \cdot x_j}{\|x_i\| \cdot \|x_j\|}, \quad (12)$$

其中 $x_i, x_j \in \mathbb{R}^d$ 分别是 (v_i, v_j) 的特征向量.考虑两种策略构建邻接矩阵:阈值 ε 和topk,定义如下:

$$\begin{cases} A_{ij} = 1, & \text{如果 } s_{ij} > \varepsilon, \\ A_{ij} = 0, & \text{其他,} \end{cases} \quad (13)$$

$$\begin{cases} A_{ij} = 1, & \text{如果 } j \in \arg \text{topk}(A_{i,:}), \\ A_{ij} = 0, & \text{其他,} \end{cases} \quad (14)$$

其中:下标 $i, j \in [1, n]$,阈值 ε 是一个超参数, $\arg \text{topk}(\cdot)$ 保留节点 i 的前 k 个相似度最大的邻居.值得注意的是, topk得到的邻接矩阵是非对称的.通常来说,阈值策略更为简单直观,但全局阈值难以调控,往往会使得不同节点的边数量有较大差距,导致图的连通性较差.而topk策略能够控制边的数量,保证图的连通性,因此本文采用topk策略构建邻接矩阵 A_1 .则故障样本可建模为图模型 $G = (Z_1, A_1)$,将其输入到GCN层以提取数据中的空间信息,即

$$Z_2 = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A}_1 \tilde{D}^{-\frac{1}{2}} Z_1 W_1), \quad (15)$$

其中: \tilde{A}_1 是归一化邻接矩阵, \tilde{D} 是 \tilde{A}_1 的度矩阵, W_1 是可学习的参数矩阵.为了进一步确保学习到的邻接矩阵的准确性,通过时空特征提取器学习节点表示,记为 Z_3 ,并进行第2次重构,得到邻接矩阵 A_2 ,则重构后的图模型可记为 $G' = (Z_3, A_2)$.最后将 Z_3 和 A_2 输入到GCN层中进行故障分类.具体地,最后的输出可表示为

$$Y = \text{softmax}(\tilde{D}^{-\frac{1}{2}} \tilde{A}_2 \tilde{D}^{-\frac{1}{2}} Z_3 W_2), \quad (16)$$

其中: Y 是预测结果,softmax为激活函数, W_2 是可学习的参数矩阵.

模型的损失函数定义如下:

$$\mathcal{L}(Y, P; W) = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^c Y_{i,j} \log(P_{i,j}) + \frac{\lambda}{2} \|W\|_2^2, \quad (17)$$

其中: n 代表样本数, c 为类别数, $Y_{i,j}$ 表示第 i 个样本属于第 j 类的概率, $P_{i,j}$ 表示模型预测第 i 个样本为第 j 类的概率, λ 为惩罚因子, W 为模型的参数.

4 实验结果和分析

本节主要通过东南大学(Southeast University, SEU)机械数据集和真实的磨煤机数据集对STMR-GCN进行验证.首先,对数据集进行简单介绍并说明实验设置;然后,对实验结果进行具体的分析;最后,进行消融实验及参数敏感性分析.

4.1 数据集介绍及实验设置

1) 东南大学(SEU)机械数据集:东南大学机械数据集包含两种旋转组件:轴承和齿轮.实验在传动系统动态模拟器上进行,实验台包括一个电机、一个制动器、控制器模块和两个经过测试的齿轮箱. SEU数据集可划分为2个子数据集:SEU轴承数据集和SEU齿轮箱数据集,每个子数据集包括两个工况下的4种故障和1种正常状态,详细描述见表1.

表1 样本类型描述

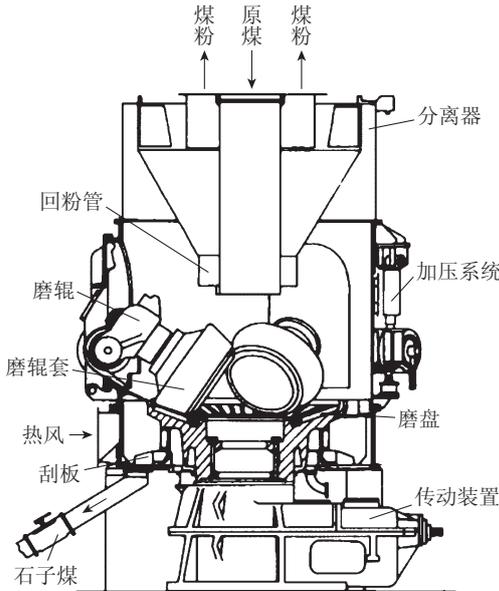
Table 1 Description of sample types

组成	轴承	齿轮箱
类型描述	轴承处于健康状态 滚动体故障 内圈故障 外圈故障 内外圈混合故障	齿轮箱处于健康状态 齿轮脚裂纹 齿轮脚缺失 齿轮齿根裂纹 齿轮表面磨损

2) 磨煤机数据集:磨煤机数据来源于华东某电力公司,其锅炉采用中速磨正压直吹式制粉系统.图4给出了MP265G磨煤机的实物照片与仿真图.



(a) 磨煤机实物图



(b) 磨煤机仿真图
图 4 磨煤机示意图

Fig. 4 Diagram of MP265G coal mill

磨煤机在运行过程中共收集到32种故障, 包括磨煤机振动高, 引风机轴承振动等, 本文选择其中10种故障进行实验测试, 详细描述如表2所示.

表 2 磨煤机故障类型描述

Table 2 Description of the fault types in coal mill

序号	类型描述	序号	类型描述
1	滤网差压高	6	风速异常
2	燃烧器烧通	7	粉管泄漏
3	油泵振动异常	8	加载力变小
4	液压油泄露	9	风机振动异常
5	炉膛处喷火	10	液压压力异常

3) 实验设置: 本文首先对信号数据进行最大最小归一化处理. SEU数据集的特征维度为1024. 磨煤机故障数据集特征维度为172. SEU数据集包括轴承数据集和齿轮箱数据集, 在每个子数据集上进行10类故障分类, 每个类别包含500个样本. 磨煤机数据集的实验任务为10类故障分类问题, 每类500个样本, 训练集和测试集的比率为6:4, 随机进行数据分割. 为了获得更准确的结果, 每次实验进行5次取平均值作为模型的结果. 该框架使用Pytorch Geometric(PyG)库实现, 迭代训练200次; 学习率采用衰减学习率, 初始学习率设置为0.015, 并在实验中使用Adam优化器进行优化.

4.2 诊断结果可视化与分析

由于参数的选择和模型的结构对整体性能有重大的影响, 为了获得最佳的诊断性能, 本文对模型进行了多次调整, 最终模型的详细结构及参数如表3所示. 符号Conv表示卷积层, Gconv表示图卷积层, (1 × 3)表示卷积核大小为3.

表 3 模型详细结构表

Table 3 Detailed structure of the model

序号	层名称	详细结构	输入尺寸	输出尺寸
1	卷积层	Conv1d(1×3)		
		Conv1d(1×5)	1×1024/	1×768/
		Conv1d(1×7)	1×172	1×96
		AdaptiveMaxpool		
2	图卷积层	GCNConv	1×768/	1×512
			1×96	
3	卷积层	Conv1d(1×3)		
		Conv1d(1×5)	1×512	1×384
		Conv1d(1×7)		
		AdaptiveMaxpool		
4	图卷积层	GCNConv	1×384	1×64
		GCNConv		
5	全连接层	—	1×64	1×10
6	Softmax层	—	1×10	1×10

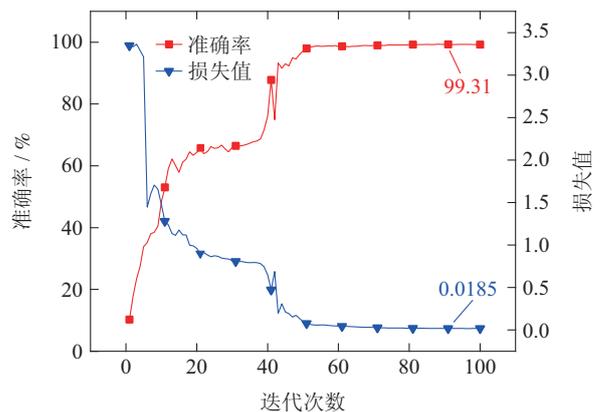
在本文中, 采用诊断精度(ACC)作为评价模型性能的标准, ACC可以定义为

$$ACC = \frac{1}{n} \sum_{i=1}^n [\hat{y}_i = y_i], \quad (18)$$

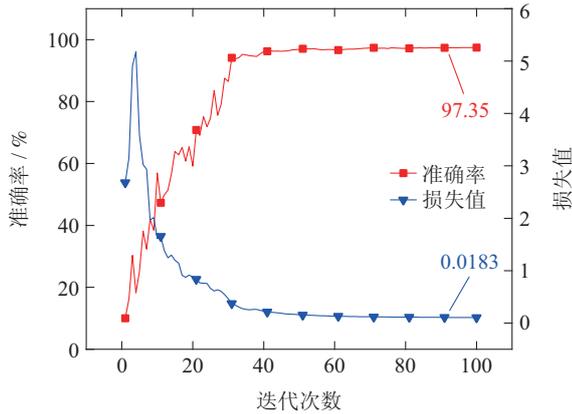
其中: n 为样本个数, \hat{y}_i 是模型对第 i 个样本的预测输出, y_i 表示真实标签, $[\cdot]$ 为指示函数.

为了可视化STMR-GCN模型的训练收敛过程, 图5展示了所提模型在3个数据集上的训练损失变化及测试准确率曲线. 从图5可以看出, 在最开始的几次迭代中, 模型的损失会出现较大的震荡, 这是由于参数随机初始化导致的, 经过一段时间的训练后, 准确率曲线与损失曲线逐渐趋于平稳, 并且最终收敛.

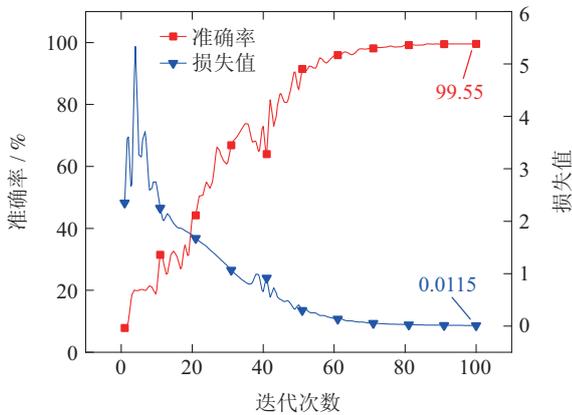
为了展示所提的STMR-GCN对故障数据的可分性, 利用混淆矩阵给出了3个实验数据集的详细诊断结果, 如图6所示. 从图6可以看出, 所提出的方法在3个数据集上都仅有较少样本分类错误, 可以达到预想的分类效果.



(a) SEU轴承数据集



(b) SEU齿轮箱数据集

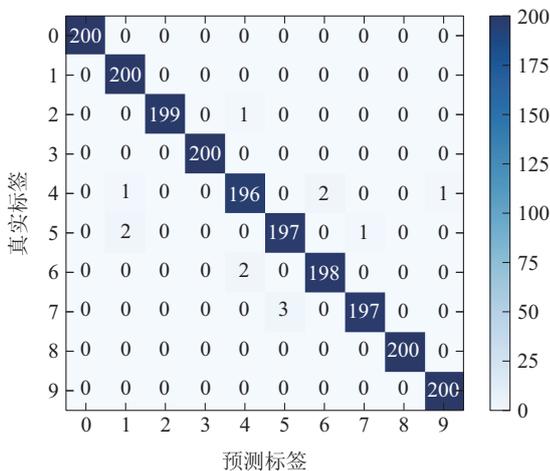


(c) 磨煤机数据集

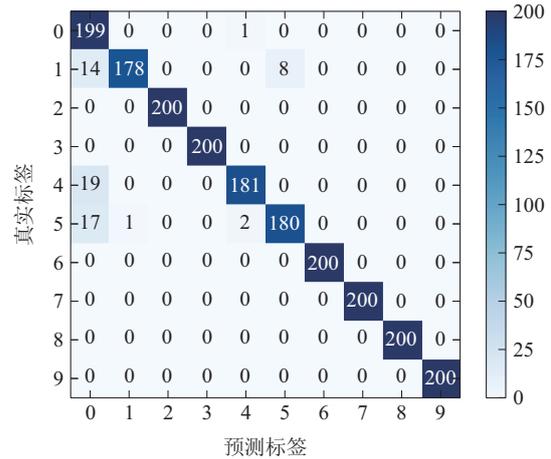
图5 不同数据集的训练损失及测试准确率曲线

Fig. 5 Train loss and test accuracy curves of different datasets

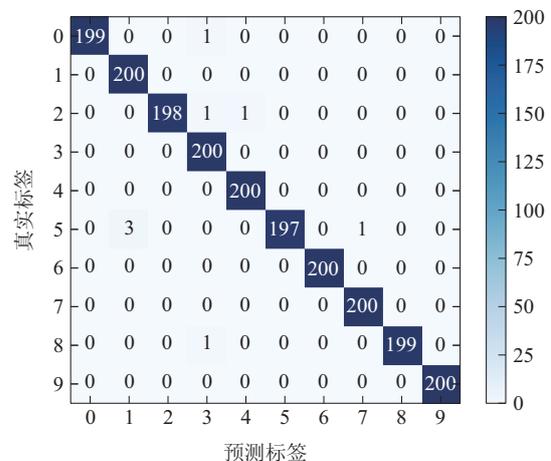
为了更深的解释模型的特征提取能力,通过t分布随机邻居嵌入(t-distributed stochastic neighbor embedding, t-SNE)方案可视化了原始特征矩阵和最后一层学习到的特征的简化平面图,如图7所示.从图7的6个子图中均可以看出,在模型分类前,3个数据集的特征分布较为混乱且互相之间有较大程度的重合,分类后各类别有较高的区分度,说明所提的模型在3个数据集上均具有较好的故障分类性能.



(a) SEU轴承数据集



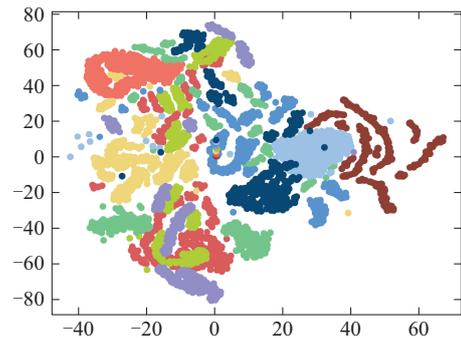
(b) SEU齿轮箱数据集



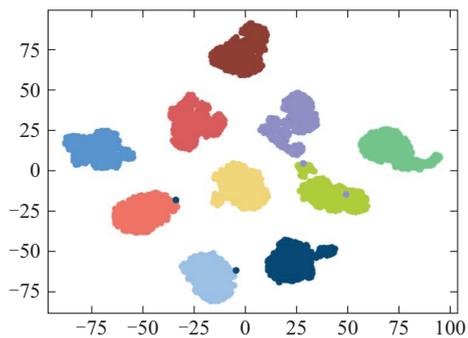
(c) 磨煤机数据集

图6 不同数据集的混淆矩阵

Fig. 6 Confusion matrices of different datasets



(a) SEU轴承数据集投影前特征分布



(b) SEU轴承数据集投影后特征分布

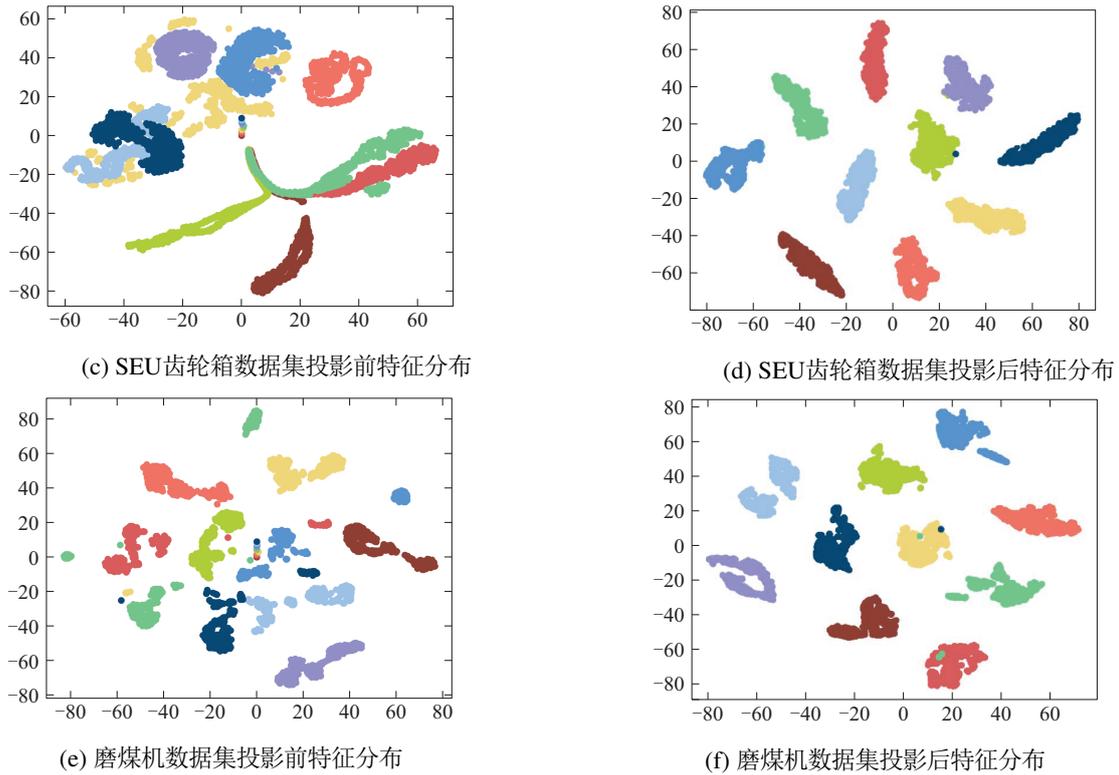


图 7 不同数据集的t-SNE可视化结果

Fig. 7 t-SNE visualization results of different datasets

4.3 对比实验

为了验证所提方法的有效性和优越性, 本文将该模型与一些现有方法进行了比较. 用于比较的方法包括: 多层感知机(multi layer perceptron, MLP)、切比雪夫网络(ChebyNet)、高阶图卷积网络(Ho-GCN)^[15]、多感受野图卷积网络(MRF-GCN)^[16]、多尺度图卷积网络(multi-scale convolutional neural network integra-

ted with GCN, MSCNN-GCN).

为了进行公平比较, 在相同的条件下对上述所有模型进行实验测试. 此外, 对所有方法训练5次, 以避免随机性. 采用训练阶段的最佳模型进行测试, 并将测试精度作为评价指标. 表4给出了各方法在测试数据集上的最大准确率、最小准确率、平均准确率和标准差的对比结果.

表 4 不同方法的诊断结果

Table 4 Diagnosis results of different models

数据集	模型	最大准确率/%	最小准确率/%	平均准确率/%	标准差/%
SEU轴承数据集	MLP	84.20	72.65	80.51	4.55
	ChebyNet	91.20	87.05	88.94	1.72
	Ho-GCN	92.25	89.35	90.79	1.14
	MRF-GCN	97.80	96.85	97.45	0.62
	MSCNN-GCN	93.95	92.10	92.80	0.74
	STM-R-GCN	99.40	99.00	99.25	0.15
SEU齿轮箱数据集	MLP	85.75	81.75	84.01	1.78
	ChebyNet	91.15	86.85	89.50	1.70
	Ho-GCN	92.15	88.35	90.30	1.50
	MRF-GCN	96.35	95.65	96.01	0.30
	MSCNN-GCN	93.20	91.15	92.31	0.80
	STM-R-GCN	97.75	96.80	97.24	0.34
磨煤机数据集	MLP	55.45	46.30	51.44	4.04
	ChebyNet	92.15	86.45	90.40	2.31
	Ho-GCN	94.35	91.25	92.62	1.23
	MRF-GCN	95.25	93.75	94.59	0.67
	MSCNN-GCN	98.75	97.60	98.24	0.45
	STM-R-GCN	99.70	99.55	99.63	0.06

从表4可以看出,由于MLP只有两个隐藏层,无法有效地提取出特征,因此效果最差。ChebyNet, Ho-GCN使用原始特征数据构建图模型,虽然较MLP的效果有一定提升,但由于先验信息不够准确,仍然未达到最优诊断精度;MRF-GCN考虑了多感受野信息,在3个数据集上分别达到了97.45%,96.01%和94.59%的准确率。STMR-GCN在多尺度CNN的帮助下进行图重构,在提取了时间信息的同时学习到了更好的图结构,因此性能最佳。此外两次图重构使得模型能够学习到更为精准的连边关系,因而诊断精度有大幅度的提升。

为了可视化模型在各类别上的具体诊断精度,以SEU轴承数据集为例,用所提的方法与其他方法进行对比构建雷达图,如图8所示。通过图8可以看出,相较于其他方法,所提的STMR-GCN模型在各类别上均有较高的诊断精度,说明STMR-GCN模型更为稳定和有效。类似的结果也可以在磨煤机数据集上得到,由于篇幅原因,此处就不再次展示。

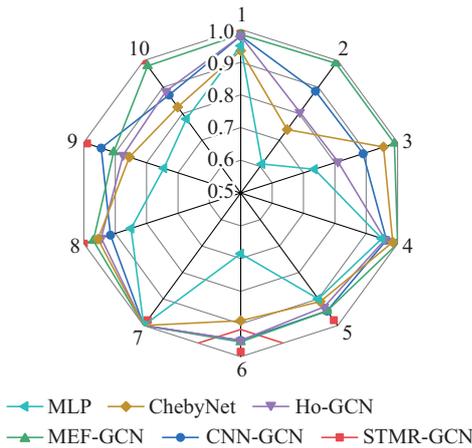


图8 不同方法对各类别故障的诊断精度

Fig. 8 Diagnostic accuracy of faults by different methods

4.4 消融实验与参数敏感性分析

为了验证STMR-GCN模型各部分的有效性,对模型进行消融实验。用于对比的模型包括MSCNN(仅包含多尺度CNN结构)、GCN(仅使用图卷积网络提取空间信息)、CNN-GCN(使用单一尺度卷积核提取时间信息)。各模型的诊断精度如表5所示。

从表5可以看出MSCNN忽略了样本间的空间信息,因此仅达到了90.25%的诊断精度;同样地,GCN由于没有考虑时间信息,诊断效果不佳;相比较而言,CNN-GCN在提取时-空特征的同时进行了重构,诊断性能优越,但在进行时间特征提取时只使用了单一尺度的卷积核,因此仍未达到最优诊断精度。

为了探索图模型重构次数 m 对模型性能的影响,将图重构次数从0到3,其中重构次数为0对应使用原始信号构建邻接矩阵,对应3个数据集的实验结果图9

所示。从图9可以看出,随着图重构次数 m 的增加,模型的测试精度先上升再下降。测试结果表明,图重构可以提高模型的性能。而多次重构会导致过拟合,使得模型学习到错误的连边信息,从而降低模型的性能。此外,随着 m 值的增加,训练时间大大增加,模型的稳定性下降。从结果来看,当 $m=2$ 时,模型获得最佳性能。因此,将图重构次数 m 设置为2,以获得最好的诊断结果。

表5 各模型的诊断精度

Table 5 Diagnostic accuracy of each model

数据集	模型	平均准确率/%
SEU轴承数据集	MSCNN	90.25
	GCN	88.94
	CNN-GCN	96.76
	STMR-GCN	99.25
SEU齿轮箱数据集	MSCNN	88.55
	GCN	89.50
	CNN-GCN	93.35
磨煤机数据集	STMR-GCN	97.24
	MSCNN	92.38
	GCN	90.40
磨煤机数据集	CNN-GCN	96.58
	STMR-GCN	99.63

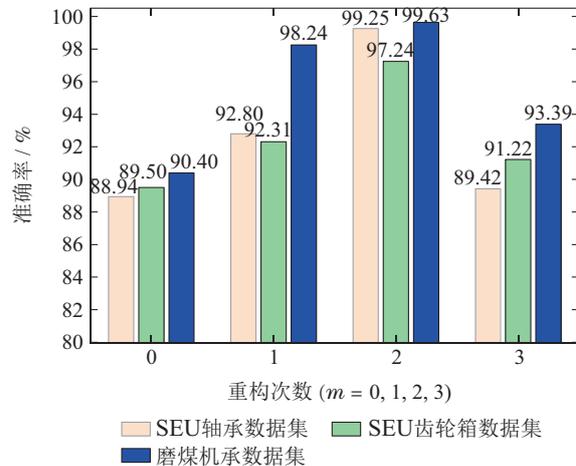


图9 不同 m 值下的模型性能

Fig. 9 Model performance with different m value

5 结论

由于原始信号中存在噪声和冗余信息,利用这种先验信息构建出的图模型不够精准,本文针对这一问题提出了STMR-GCN方法,使用多尺度CNN提取特征并去除样本中的噪声和冗余信息,再使用经过特征提取得到的特征图构建图模型,输入到GCN中进一步挖掘样本中的空间信息,最后进行故障分类。在SEU轴承数据集和SEU齿轮箱数据集上分别达到了99.25%和97.24%的平均诊断精度,在真实磨煤机

数据集上达到了 99.63% 的诊断精度. 实验结果表明, STMR-GCN 模型有较好的效果. 在实际工业环境中, 故障数据及标签的获取有时是十分困难的, 因此如何减少训练样本量及利用较少标签进行诊断是未来的研究工作.

参考文献:

- [1] ZHONG Kai, XU Mingxing, HAN Min. Integrated local fisher discriminant analysis based fault classification. *Control Theory & Applications*, 2021, 38(4): 489 – 495.
(钟凯, 徐明星, 韩敏. 基于集成局部费舍尔判别分析的故障分类. 控制理论与应用, 2021, 38(4): 489 – 495.)
- [2] CHEN H, JIANG B, STEVEN X, et al. Data-driven fault diagnosis for traction systems in high-speed trains: A survey, challenges, and perspectives. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(3): 1700 – 1716.
- [3] ZHAO Z, LI T, WU J, et al. Deep learning algorithms for rotating machinery intelligent diagnosis: An open source benchmark study. *ISA Transactions*, 2020, 107: 224 – 255.
- [4] ZHANG Siyuan, JI Hongquan, LIU Yang. Bearing fault diagnosis based on ISCNN-LightGBM. *Control Theory & Applications*, 2024, 38(1): 59 – 65.
(张思源, 纪洪泉, 刘洋. 基于ISCNN-LightGBM的轴承故障诊断. 控制理论与应用, 2024, 38(1): 59 – 65.)
- [5] ZHANG Y, LI X, GAO L, et al. Intelligent fault diagnosis of rotating machinery using a new ensemble deep auto-encoder method. *Measurement*, 2020, 151: 107232.
- [6] WANG H, LI S, SONG L, et al. An enhanced intelligent diagnosis method based on multi-sensor image fusion via improved deep learning network. *IEEE Transactions on Instrumentation and Measurement*, 2019, 69(6): 2648 – 2657.
- [7] HAO S, GE F, LI Y, et al. Multisensor bearing fault diagnosis based on one-dimensional convolutional long short-term memory networks. *Measurement*, 2020, 159: 107802.
- [8] LI T, ZHOU Z, LI S, et al. The emerging graph neural networks for intelligent fault diagnostics and prognostics: A guideline and a benchmark study. *Mechanical Systems and Signal Processing*, 2022, 168: 108653.
- [9] ZHAO Z, LI T, WU J, et al. Deep learning algorithms for rotating machinery intelligent diagnosis: An open source benchmark study. *ISA Transactions*, 2020, 107: 224 – 255.
- [10] ZHANG K, CHEN J, HE S, et al. Triplet metric driven multi-head GNN augmented with decoupling adversarial learning for intelligent fault diagnosis of machines under varying working condition. *Journal of Manufacturing Systems*, 2022, 62: 1 – 16.
- [11] YANG C, ZHOU K, LIU J, et al. SuperGraph: Spatial-temporal graph-based feature extraction for rotating machinery diagnosis. *IEEE Transactions on Industrial Electronics*, 2021, 69(4): 4167 – 4176.
- [12] CHEN D, LIU R, HU Q, et al. Interaction-aware graph neural networks for fault diagnosis of complex industrial processes. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 34(9): 6015 – 6028.
- [13] XIE Z, CHEN J, FENG Y, et al. Semi-supervised multi-scale attention-aware graph convolution network for intelligent fault diagnosis of machine under extremely-limited labeled samples. *Journal of Manufacturing Systems*, 2022, 64: 561 – 577.
- [14] ZHAO B, ZHANG X, WU Q, et al. A novel unsupervised directed hierarchical graph network with clustering representation for intelligent fault diagnosis of machines. *Mechanical Systems and Signal Processing*, 2023, 183: 109615.
- [15] KISHAN K C, LI R, CUI F, et al. Predicting biomedical interactions with higher-order graph convolutional networks. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2021, 19(2): 676 – 687.
- [16] LI T, ZHAO Z, SUN C, et al. Multi receptive field graph convolutional networks for machine fault diagnosis. *IEEE Transactions on Industrial Electronics*, 2020, 68(12): 12739 – 12749.

作者简介:

- 王庆昕 硕士研究生, 目前研究方向为信号处理与故障诊断, E-mail: qingxinwang@stu.ahu.edu.cn;
- 张先杰 博士研究生, 目前研究方向为复杂网络和数据挖掘, E-mail: zhangxianjie@stu.ahu.edu.cn;
- 张海峰 教授, 博士生导师, 目前研究方向为复杂网络和网络科学的理论和应用, E-mail: haifengzhang1978@gmail.com;
- 钟 凯 副教授, 硕士生导师, 目前研究方向为工业过程状态监控与故障诊断, E-mail: kaizhong0402@ahu.edu.cn;
- 陈宏田 副教授, 硕士生导师, 目前研究方向为数据驱动故障诊断与容错控制, E-mail: hongtian.chen@ieee.org;
- 韩 敏 教授, 博士生导师, 目前研究方向为复杂系统建模与预测等, E-mail: minhan@dlut.edu.cn.