

基于多尺度特征融合的图卷积神经网络 迁移学习故障诊断方法

曲晓荷¹, 雷志伟¹, 李 达¹, 丁 潇², 贺凯迅³, 钟 凯⁴

(1. 中国大唐集团科学技术研究总院有限公司 华东电力试验研究院, 安徽 合肥 230031;

2. 安徽大学 数学科学学院, 安徽 合肥 230601; 3. 山东科技大学 电气与自动化工程学院, 山东 青岛 266590;

4. 安徽大学 物质科学与信息技术研究院, 安徽 合肥 230601)

摘要:工业传感器信号本质上具有非欧几里得特性, 现有深度学习方法难以充分挖掘信号数据的真实性, 尤其在可变工况下。对此, 本研究设计了一种基于多尺度特征融合的图卷积神经网络迁移学习(TL-MSGCNs)故障诊断方法。首先, 从几何角度将原始数据转换为加权图, 以挖掘节点间隐藏的拓扑关联性。然后, 设计具有深层和浅层结构的图卷积神经网络提取多尺度特征并进行融合增强。最后, 通过迁移学习策略缓解因操作环境变化、设备老化等导致的源域和目标域间的分布差异。实验结果表明, TL-MSGCNs方法在故障诊断中具有显著优势。

关键词:图卷积神经网络; 加权图; 迁移学习; 多尺度特征融合; 故障诊断

中图分类号: TP277

文献标志码: A

Fault diagnosis method of transfer learning based multi-scale graph convolutional networks

QU Xiaohu¹, LEI Zhiwei¹, LI Da¹, DING Xiao², HE Kaixun³, ZHONG Kai⁴

(1. East China Electric Power Test and Research Institute, China Datang Corporation Science and Technology General Research Institute Ltd., Hefei 230031, China; 2. School of Mathematical Sciences, Anhui University, Hefei 230601, China;

3. College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China;

4. Institutes of Physical Science and Information Technology, Anhui University, Hefei 230601, China)

Abstract: Industrial sensor signals are essentially non-Euclidean, which makes typical deep learning approaches fail to gain the true insights of current industrial processes, especially under the variable working conditions. Based on this, this study designed a fault diagnosis method of transfer learning based multi-scale graph convolutional networks (TL-MSGCNs). Firstly, the raw data were transformed into weighted graph from a geometric perspective so that the hidden topological structure could be excavated effectively. Secondly, graph convolutional networks with deep and shallow layers were designed to extract multi-scale features, followed by feature fusion and enhancement. Finally, transfer learning was carried out to alleviate the distribution discrepancy of source and target domains caused by the change of operation environment, equipment aging and so on. The results show that TL-MSGCNs method performs good in fault diagnosis.

Key words: graph convolutional networks; weighted graph; transfer learning; multi-scale feature fusion; fault diagnosis

收稿日期: 2023-08-27

基金项目: 国家自然科学基金项目(62303015); 安徽省自然科学基金项目(2208085QF205)

作者简介: 曲晓荷(1991—), 女, 河南三门峡人, 高级工程师, 硕士, 主要从事建模仿真及应用研究。

钟 凯(1990—), 男, 安徽合肥人, 副教授, 博士, 主要从事故障检测与诊断的研究, 本文通信作者。

E-mail: kaizhong0402@ahu.edu.cn

随着工业系统规模扩大、复杂度日益提升^[1],基于深度学习的故障诊断技术迅速发展,并在波束成形分析、图像分类及工业信息处理^[2]等领域广泛应用。工业领域中,传感器采集的信号具有非欧几里得特性,这类信号蕴含着复杂的时空关联与拓扑依赖关系,通过深度学习技术可实现复杂故障检测与诊断。例如,Ren 等^[3]提出一种基于自动编码器(auto encoder, AE)与非负矩阵因式分解的深度非线性方法,用于处理化工过程中复杂故障的检测;Kumar 等^[4]设计了一种新型卷积神经网络(novel convolutional neural network, NCNN),通过抑制不必要的神经元激活,实现了小样本数据下的轴承缺陷诊断;Yuan 等^[5]提出基于时空注意力机制的长短期记忆网络(long short-term memory network, LSTM)来定位关键变量,显著提升了工业加氢裂化过程中沸点预测精度。然而,现有深度学习大多忽略了数据拓扑结构^[6],而拓扑信息对故障诊断具有重要补充价值。

图卷积神经网络(graph convolutional networks, GCNs)作为典型图模型,将过程变量建模为节点,节点间相互作用建模为边,既能挖掘数据拓扑结构,又能描述数据间关联性,从而提升模型的故障诊断性能^[7]。近年来, Li 等^[8]提出多感受野图卷积神经网络(multi-receptive field graph convolutional networks, MRF-GCNs),通过融合不同尺度感受野特征来克服传统 GCNs 的局限性。Wu 等^[9]设计了过程拓扑卷积网络(process topology convolutional network, PTCN),提高了故障检测精度和模型可解释性。为了构建更全面的图模型, Yang 等^[10]引入了空间卷积网络,在旋转机械故障分类中表现优异。Chen 等^[11]融合测量数据和先验知识,提出一种基于 GCNs 新的故障诊断框架,并在牵引系统环路仿真平台中验证了其有效性。

尽管上述基于 GCNs 的故障诊断方法可有效挖掘拓扑信息,但是仍存在两个缺陷。一是无权图建模局限性:现有图神经网络多基于无权图,无法定量刻画样本间关联性,导致模型性能受限;二是浅层特征利用不足,传统 GCNs 多度依赖于从深度卷积层中提取的特征,忽略浅层卷积中丰富的局部过程信息。针对这些问题,本研究提出一种多尺度特征融合的图卷积神经网络迁移学习故障(transfer learning based multi-scale graph convolutional networks, TL-MSGCNs)诊断方法,主要贡献有:①将原始过程数据转换为加权图,以定量刻画样本间的拓扑关联性,并引入迁移学习策略缓解工况切换导致的域分布差异;②融合多尺度卷积网络的浅层局部和深层全局特征,形成增强特征表示,提高模型诊断精度;③通过替换模型中的 GCNs 模块, TL-MSGCNs 可快速适配其他故障诊断场景,具有较好的泛化性能。

1 背景知识

1.1 图模型介绍

图表示为 $G=(V, E)$, 其中 $V=\{v_1, v_2, \dots, v_n\}$ 表示 n 个节点, $E=\{e_{ij}=(v_i, v_j) | v_i, v_j \in V\}$ 表示连边, 图的邻接矩阵表示为 $A=(a_{ij})_{n \times n}$, 邻接矩阵元素 a_{ij} 如式(1):

$$a_{ij} = \begin{cases} 1, & (v_i, v_j) \in E; \\ 0, & (v_i, v_j) \notin E. \end{cases} \quad (1)$$

图上的拉普拉斯矩阵 $\bar{L}$ 如式(2):

$$\bar{L} = D - A. \quad (2)$$

式中: $\bar{L}$ 为对称矩阵; D 为对角矩阵, 且对角线上元素为 $D_{ii} = \sum_{j=1}^n a_{ij}$ 。

通常情况下, 对矩阵 $\bar{L}$ 进行归一化处理得到正则化的拉普拉斯矩阵

$$L = I - D^{-1/2} \bar{L} D^{-1/2}. \quad (3)$$

式中: I 为单位矩阵。对正则化拉普拉斯矩阵 L 进行矩阵分解:

$$L = U \Lambda U^{-1} = U \Lambda U^T. \quad (4)$$

式中: U 为矩阵 L 特征向量组成的矩阵, $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ 为矩阵 L 特征值组成的对角矩阵。

1.2 图卷积神经网络

在上述定义基础上,经典的图卷积神经网络定义为:

$$Y = \theta_0 X + \theta_1 (L - I_n) X = \theta_0 X - \theta_1 D^{-1/2} A D^{-1/2} X. \quad (5)$$

为了减少参数量,防止过拟合,首先取 $\theta' = \theta_0 = \theta_1$, 则式(5)可转化为:

$$\mathbf{Y} = \theta' (\mathbf{I}_n + \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2}) \mathbf{X}. \quad (6)$$

然后,基于 $\mathbf{I}_n + \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2} \rightarrow \tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2}$, 得到 GCNs 的正向转移算式为:

$$\mathbf{Z} = \sigma((\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2}) \mathbf{X} \theta). \quad (7)$$

式中: $\mathbf{X}$ 为原始输入数据; $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_n$; $\tilde{\mathbf{D}}$ 为参数矩阵, $\tilde{D}_{ii} = \sum_{j=1}^n \tilde{a}_{ij}$, $\theta \in \mathbf{R}^{c \times d}$; $\sigma(\cdot)$ 为激活函数。

因此,一个标准两层 GCNs 模型用于图上的节点分类,可表示为:

$$\hat{\mathbf{Y}} = f(\mathbf{X}, \mathbf{A}) = \text{Softmax}(\hat{\mathbf{A}} \text{ReLU}(\hat{\mathbf{A}} \mathbf{X} \mathbf{W}^0) \mathbf{W}^1). \quad (8)$$

式中: $\hat{\mathbf{A}} = \tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2}$, Softmax 为归一化函数, ReLU 为激活函数。

2 TL-MSGCNs 故障诊断方法

TL-MSGCNs 方法总体流程如图 1 所示,主要包括三个部分:①挖掘节点之间隐藏的拓扑关联性,自动构建 k 邻近(k nearest neighbors, kNN)图;②在源域建立深浅层 GCNs 模型,并得到模型参数;③将源域中训练好的模型微调后迁移到目标域以完成故障诊断任务。




图 1 TL-MSGCNs 故障诊断方法流程

Fig. 1 Flowchart of TL-MSGCNs fault diagnosis method

2.1 kNN 图构建

对于给定的样本数据 $\mathbf{X} = (x_{ij})_{n \times m}$ (n 为样本数量, m 为变量数量), 对 $\mathbf{X}$ 进行数据标准化:

$$\tilde{\mathbf{X}} = \text{normalize}(\mathbf{X}). \quad (9)$$

为了充分挖掘样本间的潜在拓扑关联性,将样本看作图中的节点,利用样本间的相似性刻画连边关系。为了简化描述,首先,利用样本间的欧式距离表示节点间的相似性:

$$w_{ij} = \text{Dis}(\tilde{x}_i, \tilde{x}_j) = \sqrt{(\tilde{x}_{i1} - \tilde{x}_{j1})^2 + (\tilde{x}_{i2} - \tilde{x}_{j2})^2 + \dots + (\tilde{x}_{im} - \tilde{x}_{jm})^2}. \quad (10)$$

式中: $\mathbf{W} = (w_{ij})_{n \times n}$ 为节点间的相似性矩阵, $\text{Dis}(\tilde{x}_i, \tilde{x}_j)$ 表示节点 v_i 和 v_j 之间的距离。

接下来,构建节点间的 kNN 图,其核心思想是对每一个节点 v_i , 挑选与其相似性最大的 p 个节点, 创建连

边关系。用 $k_{\text{NN}}(v_i)$ 表示节点 v_i 的 p 个最近邻居集合, kNN 图的邻接矩阵记作 $\mathbf{k}_{\text{NN-A}}$, 其中每一个元素为:

$$b_{ij} = \begin{cases} 1, & v_j \in k_{\text{NN-A}}(v_i) \\ 0, & \text{其他。} \end{cases} \quad (11)$$

2.2 多尺度特征融合

传统深度 GCNs 模型会丢弃浅层的特征信息, 因此本研究提出多尺度特征融合机制以增强特征表示, 具体如图 2 所示。多尺度特征融合的核心思想是通过浅层与深层图卷积协同提取节点特征, 并融合二者形成增强的特征表示。具体而言, 浅层图卷积的功能是聚合 $l(l < 3)$ 阶邻居信息并提取浅层节点特征; 深度图卷积是聚合 $l(l \geq 3)$ 阶相邻信息, 并提取深度节点的特征。

首先, 定义 l 层图卷积操作:

$$\mathbf{H}^{l+1} = \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}^l \mathbf{W}^l). \quad (12)$$

式中: $\tilde{\mathbf{A}}$ 是图邻接矩阵, $\tilde{\mathbf{D}}$ 是元素为 $\tilde{D}_{ii} = \sum_{j=1}^n \tilde{a}_{ji}$ 的对角矩阵, $\mathbf{W}^l$ 是可训练的权重矩阵, $\mathbf{H}^{l+1}$ 是对 l 层图进行卷积后的节点特征表示。

然后, 设 $\mathbf{H}_0 = \tilde{\mathbf{X}}$, 则聚合 l 阶邻居信息后的输出为:

$$\mathbf{H}_1^{l_1+1} = \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}_1^{l_1} \mathbf{W}_1^{l_1}), \quad (13)$$

$$\mathbf{H}_2^{l_2+1} = \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}_2^{l_2} \mathbf{W}_2^{l_2}). \quad (14)$$

式中: l_1 和 l_2 分别表示浅层图卷积和深层图卷积的层数, $\mathbf{H}_1^{l_1+1}$ 和 $\mathbf{H}_2^{l_2+1}$ 分别为浅节点和深节点嵌入表示。本研究采用拼接的形式进行特征融合,

$$\mathbf{H} = [\mathbf{H}_1^{l_1+1}, \mathbf{H}_2^{l_2+1}] = [\sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}_1^{l_1} \mathbf{W}_1^{l_1}), \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}_2^{l_2} \mathbf{W}_2^{l_2})]. \quad (15)$$

最后, 提取的融合特征通过全连接层的 Softmax 函数输出分类结果, 具体为:

$$\hat{\mathbf{Y}} = \text{Softmax}(\text{FC}(\mathbf{H})). \quad (16)$$

式中: $\hat{\mathbf{Y}}$ 是分类结果, $\mathbf{H}$ 是增强的特征表示, FC 是全连接层。使用交叉熵函数作为分类损失,

$$C_E = - \sum_{q=1}^c \sum_{i \in V_{\text{train}}} Y_{qi} \ln \hat{Y}_{qi}. \quad (17)$$

式中: C_E 为交叉熵, c 是类别数, $\hat{Y}_{qi}$ 是第 i 个节点属于类别 q 的概率。通过梯度下降策略训练模型, 并利用反向传播算法更新网络的权重参数。

2.3 迁移 GCNs 模型

迁移学习是解决从源域到目标域迁移诊断问题的有效方法。对于给定的标记源域数据 $\tilde{\mathbf{D}}_s = \{\tilde{\mathbf{X}}_s, \mathbf{Y}_s\}$ 和未标记目标域数据 $\tilde{\mathbf{D}}_t = \{\tilde{\mathbf{X}}_t, \mathbf{Y}_t\}$, 迁移学习的目的是用 $\tilde{\mathbf{D}}_s$ 和 $\tilde{\mathbf{D}}_t$ 学习模型预测目标样本的标签, 并使预测的标签 $\hat{\mathbf{Y}}_t$ 尽可能等于目标域的真实标签。TL-MSGCNs 故障诊断方法的伪代码如算法 1 所示。

3 仿真实验与分析

3.1 实验设置

为验证 TL-MSGCNs 方法的有效性, 分别在田纳西-伊斯曼(Tennessee-Eastman, TE)仿真过程和真实柴油机工作过程数据集上开展实验。实验代码基于 Python 3.8 与 PyTorch 1.12 框架开发, 运行环境为配




图 2 多尺度特征融合示意图

Fig. 2 Schematic diagram of multi-scale feature fusion

备 Intel Xeon Gold 6246 CPU 和 48 G 内存的服务器。所有模型训练周期(epoch)设置为 200,初始学习率设为 0.001,使用 Adam 优化器更新参数。90% 的数据作为训练集,其余 10% 的数据用作测试集。为了消除随机性影响,将 10 次实验的平均值作为最终结果。

3.2 TE 过程

3.2.1 数据集构建

TE 过程是 Downs 和 Vogel 建立的标化工基测试平台,包含反应器、冷凝器、循环压缩机、分离器和汽提塔五个部分。每个样本包含 53 个变量,其中有 12 个操纵变量和 41 个测量变量,涵盖 21 种预设故障工况。本实验选取正常工况和前 9 种故障工况数据构建跨域迁移诊断任务来验证 TL-MSGCNs 方法。

3.2.2 图网络构建

采用 kNN 算法($l=5$)构建稀疏图网络,源域和目标域中构建的图有 4 000 个节点,初始特征为 52 个。网络架构包含:①浅层特征提取器。浅层为单层图卷积,输出维度为 512;②深层特征提取器。深层为三层图卷积,每层维度为 512;③特征融合模块。级联浅层和深层特征,融合特征维度为 1 024;④分类器。全连接层(fully connected, FC)作为分类器,机构为{128, 64, 10},用来实现故障分类。

图 3 为 TE 过程的 kNN 图可视化结果,可以看出,大部分属于同一类别的样本都聚在一起,形成小的社团。因此,通过 GCNs 模型可以充分挖掘不同样本之间的相互作用,并且识别不同的故障模式,同类故障样本在嵌入空间呈现显著聚类特性,验证了加权图模型在捕获样本关联特征方面的有效性。




图 3 TE 过程的 kNN 图

Fig. 3 kNN graph of TE process

3.2.3 实验结果与分析

选取 TE 过程中的前 9 种故障和正常状态来定量验证本研究所提方法的优越性,分类结果如表 1 所示。

算法 1: TL-MSGCNs

输入:源域和目标域图 $G_s=(V_s, E_s)$ 和 $G_t=(V_t, E_t)$,

归一化数据 $\tilde{G}_s=(\tilde{V}_s, \tilde{E}_s)$ 和 $\tilde{G}_t=(\tilde{V}_t, \tilde{E}_t)$

输出:故障诊断结果 $\hat{Y}_t$

- 1) 获取邻接矩阵 $A_s \leftarrow G_s$ 和 $A_t \leftarrow G_t$
- 2) 构建迁移学习框架 TL-MSGCNs 模型
- 3) **for** each i in epochs **do** # 源域训练
 - 4) $\hat{Y}_s \leftarrow \text{MSGCN}(A_s, \tilde{X}_s, Y_s)$
 - 5) Adam 算法更新参数
- 6) **end for**
- 7) 源域参数迁移到目标域并进行微调
- 8) **for** each i in epochs **do** # 目标域训练
 - 9) $\hat{Y}_t \leftarrow \text{MSGCN}(A_t, \tilde{X}_t, Y_t)$
 - 10) Adam 算法更新参数
- 11) **end for**
- 12) 故障诊断和分类 $\hat{Y}_t \leftarrow \text{TL-MSGCN}(G_t)$
- 13) **function:** MSGCNs(A, X, Y):
 - 14) 步骤 1)浅层特征提取
 - 15) $H_1^{l_1+1} = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H_1^{l_1} W_1^{l_1})$
 - 16) 步骤 2)深层特征提取
 - 17) $H_2^{l_2+1} = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H_2^{l_2} W_2^{l_2})$
 - 18) 步骤 3)深层和浅层特征融合
 - 19) $H = [H_1^{l_1+1}, H_2^{l_2+1}]$
 - 20) 步骤 4)获取 FC 层的输出
 - 21) $\hat{Y} = \text{Softmax}(\text{FC}(H))$
 - 22) 步骤 5)设置损失函数
 - 23)
$$C_E = - \sum_{q=1}^c \sum_{i \in V_{\text{train}}} Y_{qi} \ln \hat{Y}_{qi}$$
 - 24) **end function**

表 1 中, MS-GCNs、ST-GCNs、DT-GCNs 和 TL-GCNs 分别表示多尺度 GCN、浅层迁移 GCNs、深层迁移 GCNs 和去掉多尺度模块的迁移 GCNs。从表 1 可以看出, TL-MSGCNs 方法在 5 种故障中取得最好的分类精度, 也获得最高的平均分类精度 84%。具体来说, 与前 5 种不采用迁移学习的方法相比, 后 3 种结合迁移策略的方法整体上表现出更好的故障诊断效果, 表明迁移学习策略可以提高不同工况下的故障诊断精度。此外, 对于微小故障(故障 3 和故障 9), TL-MSGCNs 方法也具有较高的诊断精度, 其主要原因是特征融合策略能够为微小故障诊断提供更丰富的特征信息。

表 1 不同方法对 TE 过程的故障分类精度

Table 1 Fault classification accuracy of TE process by different methods

%

故障类型	kNN	RF	ANN	GCNs	MS-GCNs	ST-GCNs	DT-GCNs	TL-GCNs	TL-MSGCNs
正常	100	100	100	100	100	100	100	100	100
故障 1	80	85	85	77	82	85	80	83	83
故障 2	97	96	96	95	94	95	96	94	98
故障 3	38	53	52	53	62	65	70	65	68
故障 4	32	51	65	53	66	68	65	66	72
故障 5	63	52	70	50	56	53	64	67	71
故障 6	100	100	100	100	100	100	99	100	99
故障 7	92	75	82	70	75	74	76	73	79
故障 8	100	85	92	92	94	89	92	92	93
故障 9	14	33	48	58	66	68	68	70	77
平均值	72	73	79	75	80	80	81	81	84

图 4 展示了 TL-MSGCNs 方法在 TE 过程中源域和目标域的混淆矩阵, 其中大部分在源域中分类不佳的故障在经过迁移学习后可以在目标域中被很好地分类(混淆矩阵对角线数据), 尤其是故障 4 和故障 5 在源域中被误分, 但在目标域中分类准确率分别达到 72% 和 71%, 比源域中高出 20% 以上, 进一步证实了 TL-MSGCNs 方法的有效性。




图 4 TE 过程的混淆矩阵

Fig. 4 Confusion matrix of TE process

3.3 真实的柴油机工作过程

3.3.1 数据集描述

目前,发电厂的柴油机是应急电力的主要动力供应,也是设备持续运行的动力心脏。然而,由于其结构复杂、工况切换频繁,发生故障的可能性较高,约占所有故障的 70%~85%^[12]。本实验数据来自 MAN 公司生产的 6S35ME-B9 柴油发动机,其原理如图 5 所示。所有传感器测量值采集于 2016 年 5 月 13~14 日工作过程,在不同负载条件和推进条件下的采样间隔均为 10 s,其中包含 15 种不同类型的变量,详见表 2。




图 5 6S35ME-B9 柴油机原理图及布置图
Fig. 5 Schematic diagram and layout of 6S35ME-B9 diesel engine

表 2 柴油机的传感器监测变量

Table 2 List of monitored sensor variables of diesel engine

传感器变量	变量描述	单位
V_1	柴油机功率	kW
V_2	排气歧管压力	bar
V_3	压力机流量	kg/cm ²
V_4	压力机出口温度	℃
V_5	压力机出口压力	bar
V_6	中冷器后温度	℃
V_7	耗油量	g/(kW·h)
V_8	中冷器后压力	bar
V_9	换气压力	bar
V_{10}	换气温度	℃
V_{11}	中冷器压差	bar
V_{12}	排气温度	℃
V_{13}	排气管压力	bar
V_{14}	涡轮增压器入口温度	℃
V_{15}	涡轮增压器出口温度	℃

注:1 bar=100 kPa。

3.3.2 图网络构建

采用 kNN 算法($l=5$)构建稀疏图网络,源域和目标域中构建的图有 450 个节点,初始特征为 15 个。网络架构包含:①浅层特征提取器。浅层为单层图卷积,输出维度为 128;②深层特征提取器。深层为两层图卷积,每层维度为 128;③特征融合模块。级联浅层和深层特征,融合特征维度为 256;④分类器。全连接层作为分类器,其结构为{64,3},用来实现故障分类。

3.3.3 实验结果分析

利用正常运行状态、排气管堵塞(故障 1)和空气冷却器冷却不足(故障 2)验证方法有效性。在 50%推进力工况(源域)和 75%推进力工况(目标域)的运行条件下各选取 200 个样本, k 设置为 5,浅层、深层和全连接层的个数分别设置为 1、2 和 2。表 3 列出了柴油机故障的 10 次平均分类结果。从表 3 可以看出,传统机器学习方法(ANNs、kNN、RF)的分类精度不够理想;相比之下,基于 GCNs 的深度学习方

表 3 不同方法对柴油机的故障分类精度

Table 3 Fault classification accuracy of diesel engine by different methods

方法	Min-acc/%	Max-acc/%	Avg-acc/%	时间/s
TL-MSGCNs	82.26	90.24	86.74	40
TL-GCNs	80.65	85.50	82.85	25
ST-GCNs	77.61	87.82	81.74	10
DT-GCNs	81.94	89.47	83.39	30
MS-GCNs	80.26	86.82	82.35	40
GCNs	78.21	84.65	80.76	20
ANNs	74.18	83.59	77.90	10
kNN	68.34	76.99	73.22	<1
RF	70.73	77.81	74.73	<1

法(TL-GCNs、ST-GCNs、DT-GCNs 和 MS-GCNs)能够表征过程数据丰富

的内在信息,其性能得到一定程度的提升。而 TL-MSGCNs 方法的最小分类准确率(Min-acc)82.26%、最大分类准确率(Max-acc)92.4%和平均分类准确率(Avg-acc)86.74%,均高于对比方法。虽然 TL-MSGCNs 的计算时间不是最快的,但多出的时间相对于现在的软、硬件计算能力来说是完全可以接受的。

图 6 给出了 TL-MSGCNs 方法对柴油机数据中 3 种故障模式的混淆矩阵。具体来说,对于正常工况,虽然经过迁移学习后,目标域的分类准确率为 82%,低于源域的分类准确率 88%,但 82%的分类准确率可以满足柴油机实际运行和维护的需要。故障 1 和故障 2 在目标域的分类准确率都高于源域,说明迁移学习在多工况柴油机故障诊断中是有效的。




图 6 柴油机工作过程的混淆矩阵

Fig. 6 Confusion matrix of diesel engine working process

同样地,从图 7 中的 t-分布领域嵌入结果可以看出,源域中的 3 种模式分布比较接近,且有少量重叠部分。然而,在目标域中 3 种模式之间的距离很远且几乎没有重叠,验证了 TL-MSGCNs 方法强大的迁移学习性能和特征增强能力。




图 7 柴油机源域和目标域的 T-SNE 图

Fig. 7 T-SNE diagram of source domain and target domain of marine diesel engine

3.4 参数敏感性分析

3.4.1 网络层数的影响

网络层数直接影响 GCNs 的性能。一般而言,深层 GCNs 模型相比浅层 GCNs 模型能够聚合更远邻居的信息,但随着层数增加,模型可能因过平滑问题(over-smoothing)导致分类性能下降。实验设定中,浅层 GCNs 的层数固定为 1,深层 GCNs 和全连接层的层数分别在 1~4 内调整。如图 8 所示,横坐标(a, b, c)分

别对应浅层、深层和全连接层的层数,当深层和全连接层均为 3 层时,TE 数据集的平均分类准确率最高,达到 85.2%;而柴油机数据集的最佳层数组合为(1,2,2),准确率达 89.5%。




图 8 网络层数的参数敏感性

Fig. 8 Parameter sensitivity of network layers

3.4.2 GCNs 嵌入维度的影响

为了研究 GCNs 内嵌维度的影响,对 TL-MSGCNs 方法进行不同浅层和深层数的组合实验,如图 9 所示。实验结果表明,TE 和柴油机数据集分别在嵌入维度为 512 和 128 时,TL-MSGCNs 方法的性能达到最佳。随着嵌入维度继续增加,在 TE 数据集的准确率有所下降,这可能是由高维特征冗余引起的维度灾难所致。相比之下,TL-MSGCNs 方法的在柴油机运行故障的分类精度上对嵌入维数不敏感。

3.4.3 kNN 模型中 k 的影响

为了研究参数 k 对性能的影响,对 TL-MSGCNs 方法进行不同浅层和深层数的组合实验,结果如图 10 所示。从图 10 可以看出,当 $k \in [1, 5]$ 时,TL-MSGCNs 方法的精度呈先升后降趋势,且当 $k=5$ 时 TE 和柴油机数据集分别达到峰值。该现象符合 kNN 的典型特性:当 k 较小时(如 $k=1$),节点拥有的邻居较少,信息不足,易受噪声干扰; k 值过大时(如 $k=9$),节点邻居数较多,引入无关邻域信息,导致决策边界模糊。

3.5 讨论与分析

3.5.1 计算复杂度分析

标准图卷积层的计算复杂度为 $O(K|\epsilon|)$ 。本研究使用 $K=1$ 的图卷积核,其计算复杂度为 $O(K)$ 。特征融合操作包含两个不同层数的图卷积层。本研究中,浅层 GCNs 为 1 层,深层 GCNs 为 3 层,浅层 GCNs 卷积参数为 $W_{01} \in \mathbf{R}^{N \times d}$,计算复杂度为 $O(|\epsilon|Nd)$;深层 GCN 卷积参数分别为 $W_{02} \in \mathbf{R}^{N \times d_1}$ 、 $W_{12} \in \mathbf{R}^{d_1 \times d_2}$ 、 $W_{22} \in \mathbf{R}^{d_2 \times d}$,总的计算复杂度为 $O(|\epsilon|(Nd_1d_2d + Nd))$ 。因此,融合后的计算复杂度为 $O(|\epsilon|(Nd_1d_2d + Nd))$,与标准 GCNs 一致。因此,多尺度融合设计未带来额外计算量。





图9 嵌入维数的参数敏感性

Fig. 9 Parameter sensitivity of embedded dimension

图10 参数 k 的敏感性Fig. 10 Sensitivity of parameter k

3.5.2 泛化性能分析

由于 GCNs 是最基本的图模型之一,并且近年来有许多改进的版本被提出。为了验证所提方法的泛化性能,将基础 GCNs 替换为 GAT^[13]、GraphSage^[14] 和 ClusterGCNs^[15],其他模块或策略均保持不变。不同方法在 TE 和柴油机数据集上的 10 次实验的平均诊断精度如图 11 所示。结果表明,基于图的代表性方法




图11 不同图模型的10次实验的平均诊断精度

Fig. 11 Average diagnosis accuracy from ten trials by different graph models

的故障诊断性能均优于基本的 GCNs 模型。在此基础上,对改进的图模型实施迁移学习和多尺度信息融合策略,TL-MSGCNs 方法可以很容易被推广到其他更强大的图神经网络模型,展示了较好的模型泛化性能。

4 结论

本研究提出一种多尺度特征融合的加权图模型故障迁移诊断方法,通过多尺度特征融合与跨域迁移机制弥补了传统 GCNs 在感受野受限和域适应能力不足方面的缺陷,为解决工程实践中数据特征提取不全面、不同域数据分布差异大等问题提供了可行方案。在 TE 与真实柴油机工作状态数据集上的实验表明,TL-MSGCNs 方法分别取得 84.2% 和 86.7% 的平均精度。

值得注意的是,本研究基于 kNN 的图构建策略并假设每个节点都有相同数量的邻居,这与复杂系统图模型的无标度特性相悖。未来的工作将侧重于探索更先进的图构建策略,如多层网络或动态网络,以适应更复杂的工业过程数据。此外,将提出的方法嵌入商业自动化软件系统也值得研究。

参考文献:

- [1] 李元,刘雨田,冯立伟.基于斯皮尔曼相关分析的非线性动态过程特征提取与故障检测[J].山东科技大学学报(自然科学版),2023,42(2):98-107.
LI Yuan,LIU Yutian,FENG Liwei.Feature extraction and fault detection of non-linear dynamic process via Spearman correlation analysis[J].Journal of Shandong University of Science and Technology(Natural Science),2023,42(2):98-107.
- [2] 唐鹏,彭开香,董洁.一种新颖的深度因果图建模及其故障诊断方法[J].自动化学报,2022,48(6):1616-1624.
TANG Peng,PENG Kaixiang,DONG Jie.A novel method for deep causality graph modeling and fault diagnosis[J].Acta Automatica Sinica,2022,48(6):1616-1624.
- [3] REN Z L,ZHANG W S,ZHANG Z Z.A deep nonnegative matrix factorization approach via autoencoder for nonlinear fault detection[J].IEEE Transactions on Industrial Informatics,2019,16(8):5042-5052.
- [4] ANIL K,VASHISHTHA G,GANDHI C P,et al.Novel convolutional neural network (NCNN) for the diagnosis of bearing defects in rotary machinery[J].IEEE Transactions on Instrumentation and Measurement,2021,70:1-10.
- [5] YUAN X F,LI L,SHARDT Y A,et al.Deep learning with spatiotemporal attention-based LSTM for industrial soft sensor model development[J].IEEE Transactions on Industrial Electronics,2020,68(5):4404-4414.
- [6] WU Z H,PAN S R,CHEN F W.A comprehensive survey on graph neural networks[J].IEEE Transactions on Neural Networks and Learning Systems,2019,32(1):4-24.
- [7] ZHONG K,HAN B,HAN M,et al.Hierarchical graph convolutional networks with latent structure learning for mechanical fault diagnosis[J].IEEE/ASME Transactions on Mechatronics,2023,28(6):3076-3086.
- [8] LI T F,ZHAO Z B,SUN C,et al.Multi-receptive field graph convolutional networks for machine fault diagnosis[J].IEEE Transactions on Industrial Electronics,2021,68(12):12739-12749.
- [9] WU D Y,ZHAO J S.Process topology convolutional network model for chemical process fault diagnosis[J].Process Safety and Environmental Protection,2021,150(5):93-109.
- [10] YANG C Y,ZHOU K B,LIU J.Supergraph:Spatial-temporal graph-based feature extraction for rotating machinery diagnosis[J].IEEE Transactions on Industrial Electronics,2022,69(4):4167-4176.
- [11] CHEN Z W,XU J M,PENG T,et al.Graph convolutional network-based method for fault diagnosis using a hybrid of measurement and prior knowledge[J].IEEE Transactions on Cybernetics,2021,52(9):9157-9169.
- [12] 钟凯,韩敏,韩冰.基于动态特性描述的变量加权型分散式故障检测方法[J].自动化学报,2021,47(9):2205-2213.
HONG Kai,HAN Min,HAN Bing.Dynamic feature characterization based variable-weighted decentralized method for fault detection[J].Acta Automatica Sinica,2021,47(9):2205-2213.
- [13] WANG H B,WANG Z Y,CHEN J W,et al.Graph attention network model with defined applicability domains for screening PBT chemicals[J].Environmental Science & Technology,2022,56(10):6774-6785.
- [14] LIU J L,ONG G P,CHEN X Q.Graph SAGE-based traffic speed forecasting for segment network with sparse data[J].IEEE Transactions on Intelligent Transportation Systems,2020,23(3):1755-1766.
- [15] CHIANG W L,LIU X Q,SI S,et al.Cluster-GCN:An efficient algorithm for training deep and large graph convolutional networks[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Anchorage, Aug. 4-8,2019:257-266.

(责任编辑:齐敏华)