

控制与决策

Control and Decision

基于PGAT模型的氧气顶吹转炉小样本故障诊断

曹洁, 陈泽阳, 王进花, 蒋栋年, 李亚洁

引用本文:

曹洁, 陈泽阳, 王进花, 蒋栋年, 李亚洁. 基于PGAT模型的氧气顶吹转炉小样本故障诊断[J]. *控制与决策*, 2023, 38(10): 2943–2952.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0084>

您可能感兴趣的其他文章

Articles you may be interested in

一种基于深度学习的时间序列预测方法

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

一种基于多层语义特征的图像理解方法

An image understanding method based on multi-level semantic features

控制与决策. 2021, 36(12): 2881–2890 <https://doi.org/10.13195/j.kzyjc.2020.0927>

基于协同聚类和权重注意力稀疏自编码网络的变化检测方法

Change detection approach based on cooperative clustering and weighted-attention sparse autoencoder

控制与决策. 2021, 36(10): 2442–2450 <https://doi.org/10.13195/j.kzyjc.2019.1633>

基于分类特征约束变分伪样本生成器的类增量学习

Class incremental learning based on variational pseudo-sample generator with classification feature constraints

控制与决策. 2021, 36(10): 2475–2482 <https://doi.org/10.13195/j.kzyjc.2020.0228>

小样本下多稀疏表示分类器的决策融合方法

Decision fusion of multiple sparse representation-based classifiers in case of small samples

控制与决策. 2021, 36(8): 1984–1990 <https://doi.org/10.13195/j.kzyjc.2019.1839>

基于PGAT模型的氧气顶吹转炉小样本故障诊断

曹洁¹, 陈泽阳¹, 王进花^{2†}, 蒋栋年², 李亚洁²

(1. 兰州理工大学 计算机与通信学院, 兰州 730050; 2. 兰州理工大学 电气工程与信息工程学院, 兰州 730050)

摘要: 针对现有的深度学习方法对小样本情况下的故障诊断精度不佳和图神经网络构造图的方式依赖其他算法的问题, 提出一种图的构造方法, 并基于该方法提出一种基于图注意力机制与先验知识库的 PGAT (prior knowledge-graph attention network) 模型. 将有标签样本和无标签样本按照固定的方式连接在一起, 通过引入图注意力机制计算出样本之间的相似程度, 使得新加入的样本不依赖于图的拓扑结构, 解决图卷积神经网络不易于扩展的问题. 在基准数据集和氧气顶吹转炉数据集上的实验表明, 在只有少量有效数据的条件下, 所提模型相较于其他模型具有更好的故障诊断精度.

关键词: 图卷积神经网络; 图注意力机制; 故障诊断; 小样本

中图分类号: TP277

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0084

引用格式: 曹洁, 陈泽阳, 王进花, 等. 基于 PGAT 模型的氧气顶吹转炉小样本故障诊断 [J]. 控制与决策, 2023, 38(10): 2943-2952.

Fault diagnosis of small sample of oxygen top-blowing converter based on PGAT model

CAO Jie¹, CHEN Ze-yang¹, WANG Jin-hua^{2†}, JIANG Dong-nian², LI Ya-jie²

(1. College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China; 2. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: Aiming at the problems that the existing deep learning methods have poor fault diagnosis accuracy in the case of small samples and the way of constructing graphs of graph neural networks depends on other algorithms, a graph construction method is proposed, and based on this method, a method based on the prior knowledge-graph attention network (PGAT) model of the graph attention mechanism and the prior knowledge base is proposed. The labeled samples and unlabeled samples are connected together in a fixed way, and the similarity between the samples is calculated by introducing the graph attention mechanism, so that the newly added samples do not depend on the topology of the graph, it also solves the problem that graph convolutional neural networks are not easy to expand. Experiments on the benchmark dataset and the oxygen top-blown converter dataset show that with only a small amount of valid data, it has better fault diagnosis accuracy than other models.

Keywords: graph convolutional neural network; graph attention mechanism; fault diagnosis; small sample

0 引言

顶吹熔炼系统 (top-blown smelting system) 作为一种在全世界范围内先进的有色金属冶炼系统, 具有尺寸紧凑、生产流程简单、投资低等诸多优点, 在熔炼金属铜、锡、铅、镍出渣, 处理熔渣等领域得到了广泛应用^[1]. 氧气顶吹转炉是顶吹熔炼系统的关键设备, 其安全性对于整个顶吹炉系统至关重要, 如果不能对设备故障进行早期预警, 并在故障发生时迅速定位故障, 则可能会产生无法估量的后果. 为了避免故

障造成的重大事故和巨大经济损失, 往往会使用人工的方式对设备进行预防性维护, 或者在系统中设置阈值对设备运行的状态进行监控. 然而, 人工维护的方式效率低下, 而设置阈值的方式又无法发现设备的早期微小故障. 基于上述原因, 越来越多的故障诊断方法被相继提出.

深度学习是一种强大的机器学习方法, 相较于传统的机器学习方法, 深度学习以其更加准确的分类精度受到越来越多研究人员的关注, 并且在许多领域表

收稿日期: 2022-01-11; 录用日期: 2022-05-17.

基金项目: 国家重点研发计划项目 (2020YFB1713600); 国家自然科学基金项目 (61763028, 62063020).

责任编辑: 赵春晖.

[†]通讯作者. E-mail: wjh0615@lut.edu.cn.

现出强大的性能^[2]. 卷积神经网络(CNN)是一种经典的端到端(end-to-end)的深度学习的方法,它可以从原始数据中自动提取特征并自动训练和优化参数. 由于传统CNN的输入是二维数据,当CNN首次被引入机械设备的故障诊断领域时,研究人员将采集到的振动信号处理为二维的图像作为CNN的输入. Sun等^[3]对振动信号进行时频变换和多小波变换(multi-wavelet transform),将振动信号转换为图片的形式作为CNN的输入;Jing等^[4]对振动信号进行傅里叶变换,将频谱信号输入CNN网络;Bai等^[5]通过构造频域的一阶马尔科夫矩阵,提出了一种新的频谱算法,以图像的形式表示振动信号的特征;Wu等^[6]提出了将1D-CNN(一维卷积神经网络)用于旋转设备的故障诊断方法,该方法相较于传统的CNN,省略了将振动信号变换为图的步骤,并且拥有更好的性能.

虽然CNN可以从多个传感器源中自动提取特征,但无法在不丢失关键信息的情况下提取空间和时间特征^[7]. 作为另一种传统的深度学习的方法,循环神经网络(RNN)是用于处理序列数据的神经网络,但是容易出现梯度消失或者梯度爆炸等问题. 为了解决这些问题,Hochreiter等^[8]提出了长短期记忆网络(LSTM),因为机械设备中所采集到的信号往往具有很强的时间和空间特征,所以LSTM被广泛地应用于故障诊断,并且取得了不错的效果^[7].

受图信号处理中对图信号卷积滤波定义的启发,近几年发展出了一套基于图卷积操作并不断衍生的图神经网络(GNN)理论. GNN^[9-10]是一种将深度学习与图模型相结合的方法,作为可以揭示深层拓扑信息的模型,已经广泛应用于诸多领域,如通信、生命科学和经济金融等^[11]. 传统的CNN不能以图数据作为输入信息,并且需要的数据量非常庞大. 而GNN将图作为模型的输入,丰富了输入信息,从而减少了对数据的需求量,使得GNN相较于CNN更加符合工业应用中的实际情况. Gori等^[9]和Scarselli等^[11]提出了GNN的概念之后,Li等^[12]提出了基于谱域的图卷积操作,该操作采用RNN的方式,利用节点的邻接点和边递归地更新状态,直到达到不动点. 近年来,又有更多的基于空域或谱域的图卷积神经网络模型的变体被提出^[13-15]. 为了对全局信息进行融合学习,又有学者提出了图的池化操作^[16-18]. 作为深度学习的一个分支,GNN在链路预测、推荐系统、节点分类和蛋白质结构推理等图形数据结构方面取得了优异的性能^[19]. Zhang等^[20]结合图卷积操作和图粗化操作,将图卷积网络应用于滚动轴承的声学故障诊断;Liao

等^[21]使用孪生神经网络提取输入变量的特征,利用KNN找到与样本最相似的 K 个邻居,并将它们连接起来构成图信号,最后使用图卷积网络对节点进行分类;Gao等^[22]将所有的振动信号样本构造成一个无向加权 K 邻近图,然后使用图卷积网络对节点进行分类;Yang等^[23]使用短时傅里叶变换处理振动信号,运用谱图理论提取时空图中的拉普拉斯矩阵的特征向量,通过这种方式,时空图被转换为一维向量以进一步构造图信号.

目前,图神经网络在故障诊断领域的应用通常需要依赖其他算法初步确定样本之间的关系,进而构建图. 针对现有深度学习的方法对小样本情况下的故障诊断精度不佳和图神经网络构造图的方式依赖其他算法的问题,提出PGAT(prior knowledge-graph attention network)模型. 主要工作如下:

1) 针对图卷积神经网络中图的构建存在依赖于其他算法的问题,提出一种基于已标注数据的图结构构建方法;

2) 针对有效数据匮乏的情况,建立一种已标记数据与待分类样本之间的关系模型,解决传统深度学习算法对数据量高度依赖的问题;

3) 提出利用图注意力网络训练出相似度函数,该函数可以计算任意两个样本之间的相似度,解决图卷积神经网络中图不易于扩展的问题.

1 图卷积神经网络基本理论

1.1 图信号处理

图的拓扑结构和节点上的特征共同构成了图结构数据,图结构数据又被称为图数据或图信号. 拉普拉斯矩阵是研究图结构性质的重要对象,也是图信号处理的基础. 拉普拉斯矩阵定义为

$$L = D - A.$$

其中: A 是图 G 的邻接矩阵, D 是 A 对应的度矩阵. 度矩阵是一个对角矩阵,对角线上的元素等于顶点的度,即

$$d_{ij} = \begin{cases} d(v_i), & i = j; \\ 0, & \text{otherwise.} \end{cases} \quad (1)$$

根据定义,度矩阵 D 和邻接矩阵 A 都是对称矩阵,所以拉普拉斯矩阵也是一个实对称矩阵. 根据实对称矩阵可被正交对角化,可得等式

$$L = VAV^T = \begin{bmatrix} \mathbf{v}_1 \\ \mathbf{v}_2 \\ \vdots \\ \mathbf{v}_N \end{bmatrix}^T \begin{bmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_N \end{bmatrix} \begin{bmatrix} \mathbf{v}_1^T \\ \mathbf{v}_2^T \\ \vdots \\ \mathbf{v}_N^T \end{bmatrix}. \quad (2)$$

其中: $V \in R^{N \times N}$ 是一个正交矩阵; \mathbf{v}_i 表示 L 的特征向量, 称其为图信号上的傅里叶基, 其对应的特征向量 λ_i 表示图信号的频率.

拉普拉斯矩阵的特性可以运用于图信号处理. 图信号处理^[24]是离散信号处理理论在图信号领域的应用, 其通过对傅里叶变换、滤波等信号处理基本概念的迁移, 来研究对图信号的压缩、变换、重构等信号处理的基础任务. 传统的傅里叶变换是函数在复指数上的展开, 其定义为

$$\hat{f}(\xi) = \langle f, e^{2\pi i \xi t} \rangle = \int_{\mathbf{R}} f(t) e^{-2\pi i \xi t} dt. \quad (3)$$

类比傅里叶变换, 图傅里叶变换可以将图信号由空域 (spatial domain) 转换到频域 (frequency domain). 图 G 顶点上任意信号 $f \in R^N$ 的图傅里叶变换可以定义为 \hat{f} 在图拉普拉斯特征向量上的展开, 即

$$\hat{f}(\lambda_i) = \langle f, \mathbf{v}_i \rangle = \sum_{i=1}^N f(i) \mathbf{v}_i(i), \quad (4)$$

其中 $f(i)$ 和 $\mathbf{v}_i(i)$ 分别表示图信号 f 和特征向量 \mathbf{v}_i 的第 i 个值. 为了方便起见, 将图信号 f 的图傅里叶变换写成矩阵形式

$$\hat{f} = V^T f. \quad (5)$$

1.2 图滤波器

由于图滤波器与图卷积操作有很强的相关性, 接下来介绍图滤波器的基础知识. 在图信号中, 将图滤波器定义为调制图信号各频率的操作. 设滤波器 $H \in R^{N \times N}$, 则滤波操作可以表示为

$$\hat{f}' = H \hat{f} = \sum_{i=1}^N (h(\lambda_i) \hat{f}(i)) \mathbf{v}_i = \begin{bmatrix} \mathbf{v}_1 \\ \mathbf{v}_2 \\ \vdots \\ \mathbf{v}_N \end{bmatrix}^T \begin{bmatrix} h(\lambda_1) & & & \\ & h(\lambda_2) & & \\ & & \ddots & \\ & & & h(\lambda_N) \end{bmatrix} \begin{bmatrix} \hat{f}(1) \\ \hat{f}(2) \\ \vdots \\ \hat{f}(N) \end{bmatrix}. \quad (6)$$

$h(\lambda_i)$ 表示一个以频率 λ_i 为输入的函数, 该函数会决定各个频率分量的变化. 从式(6)可以推导出滤波器的矩阵表达形式为

$$H = V \Lambda_h V^T. \quad (7)$$

根据泰勒公式, 函数 $h(\lambda_i)$ 可以通过多项式函数近似逼近, 由此可以得到拉普拉斯矩阵多项式展开形式

$$H = h_0 L^0 + h_1 L^1 + \dots + h_n L^n = \sum_{k=0}^n h_k L^k. \quad (8)$$

将式(8)代入(6)可得

$$\hat{f}' = \sum_{k=0}^n h_k L^k \hat{f}. \quad (9)$$

如果将 $L^k \hat{f}$ 记作 $\hat{f}^{(k)}$, 则式(9)可以简化为

$$\hat{f}' = \sum_{k=0}^n h_k \hat{f}^{(k)}. \quad (10)$$

从式(10)的形式上看, \hat{f}' 可以表示为 $k+1$ 组图信号的加权和. 计算图信号 $\hat{f}^{(k)}$, 只需要图信号 $\hat{f}^{(k-1)}$ 的所有节点的一阶邻居参与, 所以从初始图信号 $\hat{f}^{(0)}$ 出发, $\hat{f}^{(k)}$ 的计算需要 k 阶邻居参与. 这种性质被称为图滤波器的局部性.

1.3 图卷积操作

受图信号处理的启发, 图卷积运算被定义为

$$f * g = V^{-1}((V^T f) \odot (V^T g)). \quad (11)$$

其中: V^{-1} 表示图的傅里叶逆变换, \odot 表示哈达玛积. 对式(12)进行推导, 有

$$\begin{aligned} f * g &= V^{-1}((V^T f) \odot (V^T g)) = \\ &V(\text{diag}(\hat{f})(V^T g)) = \\ &(V \text{diag}(\hat{f}) V^T) g. \end{aligned} \quad (12)$$

令 $H_{\hat{f}} = V \text{diag}(\hat{f}) V^T$, 则 $f * g = H_{\hat{f}} g$. 从这种形式上看, 两组图信号的图卷积操作总可以等价于图滤波操作. 根据滤波器设计不同, 图卷积神经网络可以分为基于空域的图卷积神经网络(如 GraphSAGE、GAT)和基于谱域的图卷积神经网络(如 ChebNet、GCN). PGAT 模型是一种基于空域的图卷积神经网络, 它显式地利用图信号的拓扑结构, 聚合节点邻居的特征, 节点的特征每更新一次就聚合了更高一阶邻居的特征.

2 基于先验知识库和图注意力机制的图卷积神经网络

为了解决图的构造依赖于其他算法和无法扩展的问题, 提出基于图注意力机制和先验知识库的 PGAT 模型.

2.1 图注意力网络

图注意力网络(GATs)是一种基于空域模型, 图注意力机制(GAT)是该网络用来构造图滤波器的方法. 图注意力机制^[14,25]可以通过对节点不同邻居的权重分配, 提高图神经网络的拟合能力. 如果两个节点由具有较大权重的边相连, 则它们很可能相似^[24].

设 GATs 的输入为节点特征的集合 $\mathbf{s}^l = \{\mathbf{n}_1^l, \mathbf{n}_2^l, \dots, \mathbf{n}_N^l\}$, $\mathbf{n}_i^l \in R^{F^l}$. 其中: N 表示节点的数量, F 表

示节点的特征维度, l 表示模型的层数. 为了获取节点特征的隐藏层, 图注意力层会对节点的特征进行线性变换, 其权重矩阵为 $W \in R^{F^{l+1} \times F^l}$, 得到隐藏层的特征集合为 $\mathbf{s}^{l+1} = \{\mathbf{n}_1^{l+1}, \mathbf{n}_2^{l+1}, \dots, \mathbf{n}_N^{l+1}\}$. 假设源节点为 v_i , v_i 到目标节点 v_j 的权重系数定义为

$$e_{ij} = a(W\mathbf{n}_i^l, W\mathbf{n}_j^l). \quad (13)$$

其中: $j \in \mathcal{N}_i$, \mathcal{N}_i 是节点 v_i 的邻居节点的集合; $a(\cdot)$ 是计算两个节点相似度的函数. 事实上, 可以计算图中任意一个节点到 v_i 的权重系数, 但是为了简化计算将其限制在一阶邻居内. 为了更好地衡量相似程度, 还要对源节点与其邻居节点的权重系数做归一化处理, 有

$$\alpha_{ij} = \text{soft max}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in \mathcal{N}_i} \exp(e_{ik})}. \quad (14)$$

设 $a(\cdot)$ 为单层的反向传播神经网络, 其参数为权重向量 $\mathbf{a} \in R^{2F^{l+1}}$. 为了增加模型的非线性, 采用 LeakyReLU 函数^[26]. 根据经验, LeakyReLU 能够使模型更快地收敛^[27]. 式(14)可以进一步细化为

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(\bar{\mathbf{a}}^T [W\mathbf{n}_i^l \| W\mathbf{n}_j^l]))}{\sum_{k \in \mathcal{N}_i} \exp(\text{LeakyReLU}(\bar{\mathbf{a}}^T [W\mathbf{n}_i^l \| W\mathbf{n}_k^l]))}, \quad (15)$$

其中 $\|$ 代表连接操作.

因为该模型中所有节点都是共享权重矩阵 W 的, 所以新加入的节点同样也可以根据式(15)计算出其权重系数, 并且新加入的节点不依赖于图的拓扑结构. 在计算出权重系数之后, 节点根据下式对信息进行聚合:

$$\mathbf{n}_i^{l+1} = \sigma \left(\sum_{j \in \mathcal{N}_i} \alpha_{ij} W\mathbf{n}_j^l \right). \quad (16)$$

为了进一步稳定注意力机制的学习过程, 引入多头注意力机制, 即设置 K 组相互独立的注意力机制, 除最后一层外, 将每一个头聚合得到的向量拼接起来, 如下所示:

$$\mathbf{n}_i^{l+1} = \frac{1}{K} \sigma \left(\sum_{k=1}^K \sum_{j \in \mathcal{N}_i} \alpha_{ij}^k W^k \mathbf{n}_j^l \right). \quad (17)$$

特别地, 使用多头图注意力机制的最后一层应该将 K 个头的信息进行聚合, 并且使用线性整流函数 (ReLU) 增加其非线性. 选取平均化的方式对多头信息进行聚合, 有

$$\mathbf{n}_i^{l+1} = \sigma \left(\frac{1}{K} \sum_{k=1}^K \sum_{j \in \mathcal{N}_i} \alpha_{ij}^k W^k \mathbf{n}_j^l \right). \quad (18)$$

2.2 采用图卷积神经网络的缺陷

文献[28]对基于GCN的故障诊断流程做出了总结. 基于GCN方法的输入仅仅是原始数据, 不包括任

何先验知识. 数据输入模型之后, 计算原始数据的各类时频特征, 然后根据选定的算法计算样本之间的相似度. 如果两个样本的相似度大于预设的阈值, 则将它们相连. 上述传统方法存在两个显著问题: 1) 图的构建依赖于其他算法; 2) 根据上述方法构建出的图难以扩展.

文献[21-22]都是先采用KNN算法确立样本之间的关系, 进而构造出图的结构, 但是这样会依赖于 K 值的选取. 文献[22]对 K 的取值做了相应的研究, 不同的 K 值会对模型的诊断精度造成较大的影响. 一般根据文献[22]的经验取 K 值为 $\log_2 N$, 但是随着新样本的不断加入, 最佳 K 值也会发生变化. 文献[28]采用基于模型的方法和图神经网络相结合, 先建立关于故障的数学模型, 根据该模型初步确定样本之间的关系. 该方法的问题在于, 故障诊断的精度会依赖于模型的建立. 文献[23]采用手动的方式构造图信号, 以10个相同标签的样本为一组, 同组样本之间相互连接. 该方法潜在包含了一个假设: 已知所有样本的标签, 由于实际应用中不可能知道所有样本的标签, 该方法构造图的方式存在明显的缺陷. 针对上述问题, 提出PGAT模型.

3 PGAT模型的故障诊断算法流程

图1展示了基于PGAT模型的算法流程. 本节主要介绍故障诊断每一个步骤的细节, 诊断步骤主要分为图信号处理、构建图的结构、构建PGAT模型和故障诊断.

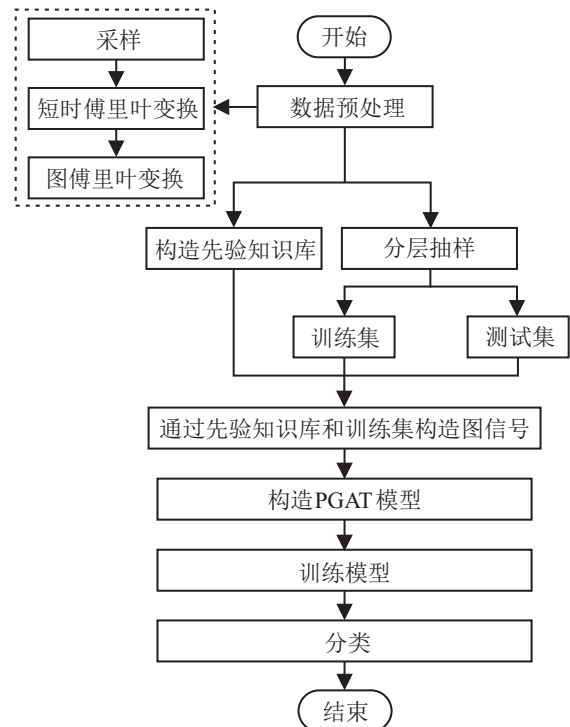


图1 PGAT的算法流程

3.1 图信号处理

如果输入为振动信号,对输入的原始信号采样,取 N 个点作为一个样本. 所有样本经由短时傅里叶变换,得到 k 段频谱. 将 k 段频谱看成 k 个节点,每对节点相互连接构成完全图,这就构成了一组图信号,图信号的结构如图2所示. 根据式(2),拥有 k 个节点的图信号可以分解为一组傅里叶基和对应的频率. 将得到的频率拼接成一个一维的向量

$$\vec{n} = [\lambda_1 \quad \lambda_2 \quad \dots \quad \lambda_N]$$

作为样本的特征向量.




图2 由 k 段频谱构建的图信号

3.2 构建图的结构

构建图是基于部分历史数据的标签已知的情况下. 取不同标签下的样本各 M 个,将具有相同标签的样本相互连接,形成一个簇,然后将其余样本分别与

先验知识库中的样本进行连接,如图3所示. 通过该方式构造的图,实际上是一种以待分类样本为中心的星形结构. 该结构的优点在于: 1)所有的样本按照既定的规则相互连接,避免了图的构建对其他算法的依赖; 2)由于构建出的图是一种星形结构,该结构将使用算法搜寻样本之间潜在的几何结构问题转化成了对比先验知识与未知样本之间相似程度的问题,避免了使用结构搜索算法或者预先计算样本相似程度的计算开销.

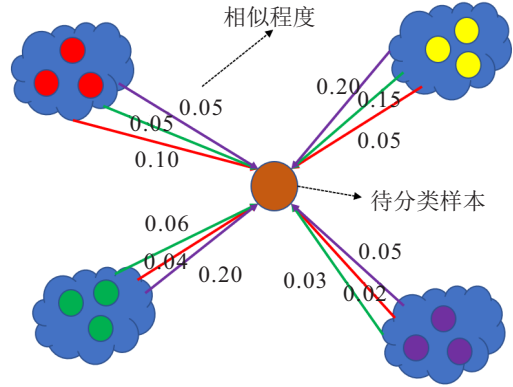


图3 图的结构

3.3 构建PGAT模型

如图4所示,PGAT模型由3个多头图注意力层与激活函数交替堆叠而成. 模型的输出使用Softmax函数转换成概率形式,并通过交叉熵计算损失. 网络选用Adam算法优化模型的参数.




图4 PGAT模型结构

3.4 故障诊断

PGAT模型经过训练,可以得到一个相似度计算函数 $a(\cdot)$. 该函数的核心是权重矩阵 W ,根据该权重矩阵,无标签样本通过式(15)计算与先验知识库之间的权重系数. 该系数可以看成两者之间的相似程度,如图3所示. 通过式(17)加权得到样本的隐藏特征,最后经由Softmax函数计算出样本所属类别的概率.

当有新的样本加入时,首先按照3.1节处理信号,并将样本与先验知识库中的所有样本相连. 该做法的优势在于,新样本的加入不会影响已有的结构,并且除了先验知识库内的样本,其他样本不会对新样本产生影响.

4 实验验证

本节先在帕德伯恩轴承数据集^[29]上验证PGAT模型的可行性,然后在实际工况下的氧气顶吹转炉数据集上验证本文所提出方法的有效性.

4.1 帕德伯恩数据集上的实验

4.1.1 数据的描述与实验设置

采集德国帕德伯恩轴承数据的试验台由电机、扭矩测量器、轴承测试模块、变速飞轮和负载电机组成. 为了确保实验的可比性,通过表转速、负载扭矩和径向力使得试验台分别在表1的4种不同工况下运行. 实验将不同损坏类型的滚动轴承安装在轴承测试模块中,并以64 kHz的频率采集实验数据. 数

数据集总共包含26种故障轴承和6种健康轴承的数据,其中故障包含12种人工损伤^[4].

表1 实验参数

No.	转速 /rpm	负载扭矩 /N·m	径向力 /N	数据集名称
0	1500	0.7	1000	N15_M07_F10
1	900	0.7	1000	N09_M07_F10
2	1500	0.1	1000	N15_M01_F10
3	1500	0.7	400	N15_M07_F04

在该数据集中,同步采集电机电流和振动信号,以收集轴承健康信息.因此,一方面,电机电流信号或振动信号可以单独用于轴承诊断和对比研究;另一方面,利用该数据集可以研究基于多传感器信息融合的诊断^[2].本文只使用数据集中的振动信号作为故障诊断依据.

选取试验台No.0工况下的数据集,分别采集健康和3种经过不同人工损坏轴承的实验数据,每种损伤分别有内圈和外圈两个位置,数据集的选取情况如表2所示.对于这些数据文件,取2048个点作为一个样本,最终每种轴承状态都有120个样本.根据1.1节所述的方式获取图信号的频率,每个样本可以提取到由33个频率组成的特征向量.得到样本的特征之后,

表2 被选中数据文件的详细描述

轴承损伤方式	位置	数据集文件
无损伤	-	N15_M07_F10_K002_1~9
放电加工	内圈	N15_M07_F10_KI01_1~19
放电加工	外圈	N15_M07_F10_KA01_1~19
人工钻孔	外圈	N15_M07_F10_KA07_1~19
手动电动雕刻	内圈	N15_M07_F10_KI03_1~20
手动电动雕刻	外圈	N15_M07_F10_KA05_1~19

表3 不同 S_n 下模型的诊断精度

S_n	10	20	30	40	50
精度	96.53% ± 0.023	96.37% ± 0.019	96.40% ± 0.01	97.20% ± 0.018	97.23% ± 0.015

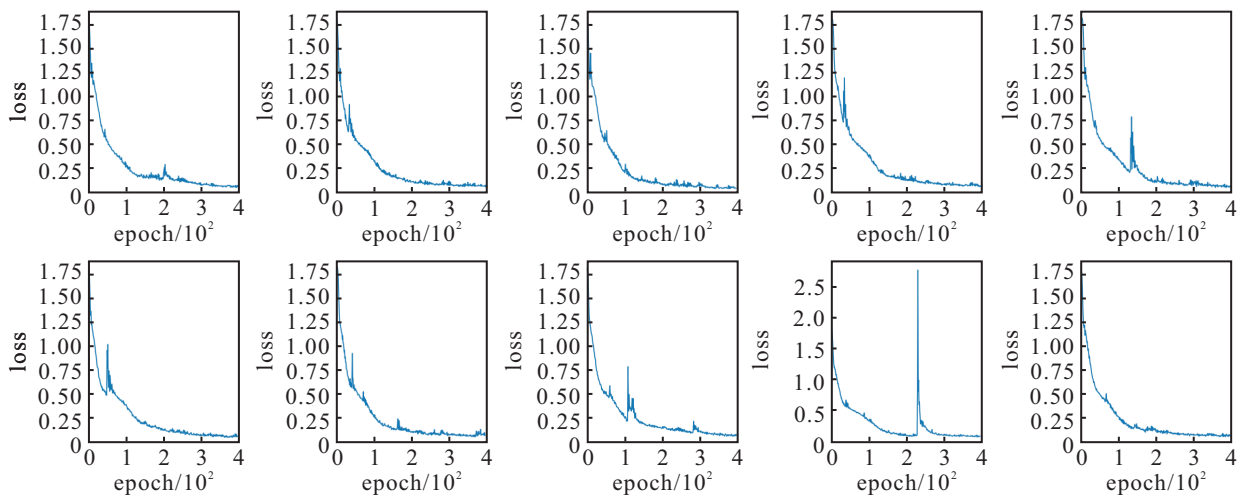


图5 交叉验证下epoch与loss的关系

在每种轴承状态的样本中分别取40个样本组成先验知识库,剩下的样本按照9:1的比例划分训练集和测试集.

PGAT模型中存在一些关键的参数需要设置,包括学习率、图注意力层的heads数量、各层的输入通道数量in_channel和输出通道数量out_channel.这些参数对模型的性能有着巨大影响.实验的参数设置参考文献[23].学习率lr = 0.015,采用多头图注意力机制,令heads = 3,第1层模型的(in_channel, out_channel)设置为(33, 30),第2层为(90, 25),第3层为(75, 6).注意,因为heads = 3,下一层的in_channel应该等于上一层的out_channel乘以3.

4.1.2 小样本条件下的实验结果与性能比较

将本文提出的方法在德国帕德伯恩数据集上进行验证,并与其他先进的深度学习算法进行对比,如一维卷积神经网络(1D-CNN)^[6]、长短时记忆网络(LSTM)、SSGN^[22]和SuperGraph-GCN^[23].采用K折交叉验证法验证算法的有效性.为了找到每个簇中样本的最佳数量,对先验知识库中的样本数量 $S_n \in [10, 50]$ 在 $K = 10$ 的条件下做对比实验.如表3所示,随着每个簇中样本数量的增加,模型的精确度确实得到了缓步提升.但是由于簇中样本的增加会显著增加模型的训练时间,在时间与精度的权衡之下取40个样本作为先验知识库.

图5展示了 $S_n = 40$ 时epoch与loss的关系,在大多数情况下模型都能在300个epoch之内达到稳定.为了进一步分析在 $S_n = 40$ 条件下模型的性能,绘制模型的混淆矩阵如图6所示.

从混淆矩阵中可以发现PGAT模型对人工钻孔的分类精度较差. 在 K 折交叉验证下, 模型会将第3种故障(人工钻孔)误分成健康状态. 相反地, 模型也会将健康状态的轴承误分成第3种故障. 其他的故障在本文的模型上都能达到100%的准确率. 如图6的混淆矩阵所示, 将第3种故障误分成健康状态(第1、2、3、6、7、8、9张图, 从左至右按顺序编号)的概率分别为6%、25%、17%、4%、26%、4%和25%; 将健康状态的轴承误分为第3种故障的(第1、3、4、5、8张图)误分率为10%、7%、28%、18%和18%. 除了会误分人工钻孔故障之外, 模型几乎能完美地划分其他类别的轴承故障.

图7和图8展示了 $S_n = 30$ 和 $S_n = 50$ 的混淆矩

阵, 与 $S_n = 40$ 的情况几乎一致, 都对人工钻孔故障分类性能不佳. 尝试增加人工钻孔故障的先验知识库中的样本数量来解决这个问题, 但是模型的性能反而大幅度下降并且出现了更多的误分.

为了进一步验证PGAT模型的有效性, 采用 t-SNE^[30] 算法对数据进行降维. 从图9和图10可以看出, 使用PGAT模型后, 数据的可分性得到了提升. 在图10中, 粉色节点和深蓝色节点分别代表人工钻孔样本和正常样本, 可以清晰地看到两种类别之间有一定的重合部分. 这也进一步表明了PGAT模型对这两类故障分类性能不佳, 但是对其他类型的故障分类性能较好, 造成这种现象的原因可能是先验知识的选取对模型的性能产生了影响. 由于模型工作的原理是




图6 $S_n = 40$ 的混淆矩阵




图7 $S_n = 30$ 的混淆矩阵




图8 $S_n = 50$ 的混淆矩阵




图9 未经过PGAT模型之前样本的t-SNE降维图




图10 经过PGAT模型之后样本的t-SNE降维图

通过注意力机制对比样本之间的相似程度,如果先验知识库中的样本彼此相似,则会将这种影响带入模型中. 根据上述分析,先验知识库中的样本质量会很大程度上影响PGAT的分类精度,解决这一缺陷是未来工作的重点之一.

本文使用几种较为先进的深度学习方法(1D-CNN、LSTM、SSGN和SuperGraph-GCN)在相同的数据集与样本数量(每种轴承状态采集120个样本)下与PGAT的方法作对比,结果如图11所示(右上角的标签表示样本数量). 1) 1D-CNN: 1D-CNN对样本的数量非常敏感,在样本量发生变化的情况下,模型的诊断精度会发生抖动且模型的综合性能较差.

2) LSTM: 相较于1D-CNN, LSTM模型的诊断精度较好,但是当样本数量由600个下降到498时,诊断精度发生了断崖式下跌. 3) SSGN: 该模型的诊断精度随着样本数量的减少变化较为平稳,但是该模型依赖于KNN算法. 在SSGN模型中, K 值的选取会对模型的诊断精度有较大的影响,文献[22]对该问题做了相应的研究. 4) SuperGraph-GCN: 虽然该方法达到了100%的诊断精度,但是其提出的构造图信号的方式存在明显的缺陷,因为实际应用中不可能知道所有数据的标签. 综上所述,PGAT模型相较于各类方法在小样本的条件下都有明显的优势,且模型解除了与其他算法之间的耦合.




图11 PGAT与其他算法的精度对比

4.2 氧气顶吹转炉数据集上的实验

在4.1节中,使用基准数据集验证了PGAT模型的有效性. 本节使用从金川集团有限公司采集的氧气顶吹转炉运行数据来验证PGAT在实际应用中的可行性. 因为实际工况下没有采集设备的振动信号,并且GCN模型适用于端到端的训练,所以仅对数据进行归一化处理. 具体采集到的数据参数如表4所示. 实际数据仅根据金川公司系统中设置的阈值标

注是否发生异常,所以本文使用列表中的数据进行二分类. 总共采集169个样本,其中异常样本为25个,采样频率为1小时一次. 由于异常数据的历史数据不足40个,每个先验知识库中包含20个样本.

表4 氧气顶吹转炉参数列表

参数名称		单位
炉底温度	1#热电偶	°C
	2#热电偶	°C
	3#热电偶	°C
喷枪静压		kPa
高位水箱液位		%
余热锅炉	水位	mm
	压力	MPa
顶吹炉熔体面		mm
烟气残氧		%
低镍硫温度		°C
尾料温度		°C
喷枪风背压		kPa
1#电场入口温度		°C
2#电场入口温度		°C
余热锅炉蒸发量		t/h
氧气	压力	kPa
	流量	Nm ³ /h
管道压力		kPa
背压		kPa
流量		m ³ /h
燃烧风管压		kPa
内管风流量		m ³ /h
套筒氧流量		m ³ /h

在相同样本数量下,使用传统的机器学习算法(KNN、SVM)与PGAT进行比较,如图12所示. PGAT的精度为86.7%,KNN的精度为81.5%,SVM的精度为82.4%. 因此验证了PGAT模型在实际工况下氧气顶吹转炉故障诊断的有效性,可解决在故障样本缺乏的情况下实现对顶吹炉的故障诊断问题.




图12 PGAT与传统机器学习方法比较

5 结论

针对有色金属冶炼系统中的氧气顶吹转炉缺乏故障样本的诊断问题,本文提出了PGAT模型. 通过建立历史数据与待分类样本之间的关系模型,解决了传统深度学习算法对数据量高度依赖的问题;利

用图注意力层参数共享的特性,通过图注意力机制得到无标签样本与先验知识库中样本的相似程度,解决了图卷积神经网络建模中不能引入新的参数实现图模型的扩展问题,实现了图神经网络的自适应动态建模;图卷积操作会依赖于事先确定的样本之间的关系,PGAT模型将这种关系限制在先验知识库与样本之间,所以新加入的样本仅需考虑样本与先验知识库之间的关系,解决了图卷积神经网络对其他算法的依赖.

分别在基准数据集和实际工况下的氧气顶吹转炉数据集上验证了所提方法的有效性,实验表明,在小样本情况下,有效提高了诊断准确性,相比其他算法具有明显的优势. 但是从实验来看,该方法对人工钻孔这种故障的识别精度不高,可能是提取振动信号特征的方法对模型产生了影响,改进这个缺陷也是未来工作研究的重点之一. 在实际工况下的氧气顶吹转炉数据集上的实验表明,该方法在实际应用中也能在一定程度上检验出设备运行的异常状况,且诊断精度比KNN高出5.2%,比SVM高出4.3%.

参考文献(References)

- [1] 薛宇涛. 顶吹熔炼系统寿命预测及维修策略研究[D]. 昆明: 昆明理工大学, 2018: 22-23.
(Xue Y T. Life prediction study and maintenance strategy of top blowing smelting system[D]. Kunming: Kunming University of Science and Technology, 2018: 22-23.)
- [2] Jiao J Y, Zhao M, Lin J, et al. A comprehensive review on convolutional neural network in machine fault diagnosis[J]. Neurocomputing, 2020, 417: 36-63.
- [3] Sun W F, Yao B, Zeng N Y, et al. An intelligent gear fault diagnosis methodology using a complex wavelet enhanced convolutional neural network[J]. Materials: Basel, Switzerland, 2017, 10(7): 790.
- [4] Jing L Y, Zhao M, Li P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox[J]. Measurement, 2017, 111: 1-10.
- [5] Bai Y L, Yang J W, Wang J H, et al. Image representation of vibration signals and its application in intelligent compound fault diagnosis in railway vehicle wheelset-axlebox assemblies[J]. Mechanical Systems and Signal Processing, 2021, 152: 107421.
- [6] Wu C Z, Jiang P C, Ding C, et al. Intelligent fault diagnosis of rotating machinery based on one-dimensional convolutional neural network[J]. Computers in Industry, 2019, 108: 53-61.
- [7] Shi J C, Peng D K, Peng Z X, et al. Planetary gearbox fault diagnosis using bidirectional-convolutional LSTM networks[J]. Mechanical Systems and Signal Processing, 2022, 162: 107996.
- [8] Hochreiter S, Schmidhuber J. Long short-term

- memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [9] Gori M, Monfardini G, Scarselli F. A new model for learning in graph domains[C]. *Proceedings of 2005 IEEE International Joint Conference on Neural Networks*. Montreal, 2005: 729-734.
- [10] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model[J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [11] 白铂, 刘玉婷, 马驰骋, 等. 图神经网络[J]. *中国科学: 数学*, 2020, 50(3): 367-384.
(Bai B, Liu Y T, Ma C C, et al. Graph neural network[J]. *Scientia Sinica: Mathematica*, 2020, 50(3): 367-384.)
- [12] Li Y, Tarlow D, Brockschmidt M, et al. Gated graph sequence neural networks[J/OL]. 2015, arXiv: 1511.05493.
- [13] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering[J]. *Advances in Neural Information Processing Systems*, 2016, 29: 3844-3852.
- [14] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks[J/OL]. 2017, arXiv: 1710.10903.
- [15] Hamilton W L, Ying R, Leskovec J. Inductive representation learning on large graphs[C]. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook, 2017: 1025-1035.
- [16] Ying Z, You J, Morris C, et al. Hierarchical graph representation learning with differentiable pooling[C]. *Advances in Neural Information Processing Systems*. Red Hook, 2018: 4805-4815.
- [17] Lee J, Lee I, Kang J. Self-attention graph pooling[C]. *Proceedings of the 36th International Conference on Machine Learning*. California, 2019: 3734-3743.
- [18] Ma Y, Wang S H, Aggarwal C C, et al. Graph convolutional networks with EigenPooling[C]. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York, 2019: 723-731.
- [19] Asif N A, Sarker Y, Chakraborty R K, et al. Graph neural network: A comprehensive review on non-euclidean space[J]. *IEEE Access*, 2021, 9: 60588-60606.
- [20] Zhang D C, Stewart E, Entezami M, et al. Intelligent acoustic-based fault diagnosis of roller bearings using a deep graph convolutional network[J]. *Measurement*, 2020, 156: 107585.
- [21] Liao W L, Yang D C, Wang Y S, et al. Fault diagnosis of power transformers using graph convolutional network[J]. *CSEE Journal of Power and Energy Systems*, 2021, 7(2): 241-249.
- [22] Gao Y Y, Chen M, Yu D J. Semi-supervised graph convolutional network and its application in intelligent fault diagnosis of rotating machinery[J]. *Measurement*, 2021, 186: 110084.
- [23] 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.
- [24] Shuman D I, Narang S K, Frossard P, et al. The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains[J]. *IEEE Signal Processing Magazine*, 2013, 30(3): 83-98.
- [25] Brody S, Alon U, Yahav E. How attentive are graph attention networks?[J/OL]. 2021, arXiv: 2105.14491.
- [26] Maas A L, Hannun A Y, Ng A Y, et al. Rectifier nonlinearities improve neural network acoustic models[C]. *Proceedings of the 30th International Conference on Machine Learning*. Atlanta, 2013: 3.
- [27] Wang X L, Ye Y F, Gupta A. Zero-shot recognition via semantic embeddings and knowledge graphs[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, 2018: 6857-6866.
- [28] 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*, 2022, 52(9): 9157-9169.
- [29] Lessmeier C, Kimotho J, Zimmer D, et al. Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification[C]. *PHM Society European Conference*. Bilbao, 2016: 5-8.
- [30] van der Maaten L, Hinton G. Visualizing data using t-sne[J]. *Journal of Machine Learning Research*, 2008, 9(11): 2579-2605.

作者简介

曹洁(1966—), 女, 教授, 博士生导师, 从事智能交通、计算机控制技术和智能信息处理等研究, E-mail: caoj@lut.edu.cn;

陈泽阳(1996—), 男, 硕士生, 从事故障诊断、深度学习等研究, E-mail: 396810358@qq.com;

王进花(1979—), 女, 副教授, 博士, 从事智能信息处理、多源信息融合和复杂系统建模与仿真等研究, E-mail: wjh0615@lut.edu.cn;

蒋栋年(1984—), 男, 副教授, 博士, 从事故障诊断与容错控制等研究, E-mail: jiangdn@lut.edu.cn;

李亚洁(1981—), 女, 副教授, 博士, 从事复杂工业系统故障诊断与容错控制等研究, E-mail: liyaj@lut.edu.cn.