

DOI: 10.19650/j.cnki.cjsi.J2107732

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^{*}

余晓霞, 汤宝平, 魏 静, 邓 蕾

(重庆大学机械传动国家重点实验室 重庆 400044)

摘 要:针对强背景噪声条件下航空发动机附件机匣故障难以诊断的问题,提出了自适应图卷积神经网络(AGCNet)航空发动机附件机匣故障诊断方法。将航空发动机附件机匣振动信号通过小波包进行分解,并将小波包系数矩阵定义为包含节点与边的图。在图卷积神经网络中构建自适应图卷积核,基于切比雪夫多项式设计了一种自适应图卷积操作,通过自适应图卷积核对应图中节点与边进行特征提取,增强模型在强噪声条件下的泛化性。最后利用全连接层进行特征抽取,进而实现航空发动机附件机匣故障。应用案例表明所提自适应图卷积神经网络模型(AGCNet);在强背景噪声条件下对航空发动机附件机匣故障平均诊断精度为86.42%,均高于LeNet、ResNet以及GCNet模型。能够有效识别故障,可应用于航空发动机附件机匣故障诊断。

关键词: 航空发动机附件机匣;自适应图卷积神经网络;强背景噪声;故障诊断

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 510.40

Fault diagnosis for aero-engine accessory gearbox by adaptive graph convolutional networks under intense background noise conditions

Yu Xiaoxia, Tang Baoping, Wei Jing, Deng Lei

(State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044, China)

Abstract: An adaptive convolutional graph neural network fault diagnosis method is proposed to diagnose aero-engine accessory gearbox faults under intense background noise conditions. Wavelet packet coefficient matrixes, which decompose from the gearbox's vibration signals by wavelet packets, are defined as graphs containing nodes and edges. An adaptive graph convolution operation is designed based on Chebyshev polynomials, the adaptive graph convolutional kernel is constructed in the graph convolutional networks to improve the fault feature extraction ability of nodes and edges, and enhance the generalization of the model under strong noise conditions. Finally, the fully connected layer is used for feature extraction to achieve fault diagnosis of aero-engine accessory gearbox. The application case shows that the proposed the adaptive graph convolutional networks has an average diagnostic accuracy of 86.42% for aero-engine accessory magazine fault diagnosis under strong background noise, which is higher than LeNet, ResNet and GCNet models, and can effectively identify faults and be applied to aero-engine accessory magazine fault diagnosis.

Keywords: aero-engine accessory gearbox; adaptive graph convolution networks; strong background noise; fault diagnosis

0 引 言

航空发动机附件机匣是飞机传动系统中的重要部件^[1-2]。随着机匣的服役时间延长,性能缓慢退化,机匣发生事故风险逐渐增大。如何准确诊断航空发动机附件机匣故障对军用飞机的运维至关重要^[3]。

目前航空发动机附件机匣故障诊断的方法主要分为信号处理和数据驱动两大类^[4-5]。其中基于信号处理的故障诊断方法需要大量的专业知识,并需要分析航空发动机附件机匣的故障机理;此类方法操作复杂、专家经验要求高,难以实现快速高效的故障诊断。基于数据驱动机匣故障诊断方法不考虑机匣内部的故障机理,而是直接从状态监测数据(如:振动加速度、温度、油液颗粒等)

收稿日期:2021-04-08 Received Date: 2021-04-08

^{*} 基金项目:重庆市自然科学基金(cstc2019jcyj-zdxmX0026)、国家重点研发计划(2020YFB1709800)、国家自然科学基金(51775065)项目资助

中提取能够反映机匣故障的隐含信息,进而实现航空发动机附件机匣故障智能诊断^[6-7]。其中基于深度学习的数据驱动故障诊断方法由于其能深度提取机匣中的隐藏故障特征和自动进行故障分类而被常应用于航空发动机附件机匣故障诊断^[8]。

由于航空发动机附件机匣结构复杂且运行工况恶劣,附件机匣各部件振动信号耦合,特征信息常处于强背景噪声下,致使机匣故障难以识别。如何在强背景噪声条件下实现航空发动机附件机匣的智能诊断是一个具有挑战性的难题。基于深度学习的机匣故障诊断方法的准确度大多依赖于大量无干扰的振动信号,而在强背景噪声下训练出的故障诊断模型泛化能力较差。如 Zhang 等^[9]采用归一化模型中权重等方式,实现了强背景噪声下旋转机械的故障诊断。Wang 等^[10]提出了一种 WPA-ANN 模型,该模型利用离散小波包对振动信号进行预处理,并采用神经网络对其进行特征提取与故障识别,降低了背景噪声对信号的干扰,提高了航空发动机故障诊断精度。Dong 等^[11]将振动信号转化为图,并提取了图的节点与边的特征,降低了背景噪声对故障特征提取的干扰。目前国内外学者对强背景噪声条件下航空发动机附件机匣故障诊断等相关问题基于深度学习理论已提出了一些模型,但所提故障诊断模型抗干扰能力差,对测试样本的识别精度有进一步提升空间。

图卷积网络^[12]通过构建图节点与边的方式提高了模型的抗噪声能力,克服了强背景噪声条件下由于模型泛化性能差导致故障识别精度降低的问题,可以应用于强背景噪声条件下航空发动机附件机匣故障诊断。然而,航空发动机附件机匣内部结构复杂,故障特征信息复杂多变,传统的图卷积核难以高效提取图中的节点与边的特征。因此,本文提出了一种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。由于机载航空发动机附件机匣振动信号难以获取,采用台架实验的机匣振动数据进行分析。利用所提出的自适应图卷积核充分提取机匣的故障特征信息,增强模型泛化能力,提高航空发动机附件机匣的故障诊断准确度。

1 基于振动信号的图卷积

图卷积主要包括空域卷积和频域卷积。其中,空域卷积借鉴了卷积神经网络中的卷积操作,直接对图进行卷积^[13]。空域卷积操作易于理解,但缺乏一定的理论基础。频域卷积具有坚实的理论基础,它是通过图傅里叶变换和图傅里叶逆变换等操作进行图卷积^[14]。本文所构建的自适应图卷积网络主要基于频域图卷积理论。

1.1 图的构建方法

本文将航空发动机附件机匣的振动信号进行小波包

分解,然后将小波包系数矩阵定义为具有节点和边的图。其中,一张图可以表示为 $G = (V, E, W)$, 其中 V 表示图中节点, E 表示两个节点之间的边, W 表示两个顶点之间边的权重^[15]。此外,图还可以用拉普拉斯矩阵表示,即为 $L = D - A$, 其中 D 和 A 分别代表度矩阵和邻接矩阵。拉普拉斯矩阵可以按如下方式进行特征分解

$$L = U \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix} U^{-1} = U \Lambda U^{-1} \quad (1)$$

式中: $U = (\vec{u}_1, \vec{u}_2, \dots, \vec{u}_n)$ 是由单位特征向量组成的矩阵; Λ 是由拉普拉斯矩阵的特征值组成的对角矩阵。因为 U 是正交矩阵(即 $UU^T = E$), 所以拉普拉斯矩阵的特征分解也可以写成如下形式:

$$L = U \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix} U^T = U \Lambda U^T \quad (2)$$

由于拉普拉斯矩阵具有以上两个性质,图卷积操作得以快速在频域中实现。

1.2 频域图卷积

所提自适应图卷积神经网络主要基于频域卷积理论,其核心思想是将图信号进行图傅里叶变换,在频谱域进行卷积,然后再对信号进行图傅里叶逆变换^[16]。其中,图傅里叶变换操作如下:

$$F(\lambda_l) = \hat{f}(\lambda_l) = \sum_{i=1}^N f(i) u_l^*(i) \quad (3)$$

式中: f 是图的 N 维分量, $f(i)$ 与图中节点一一对应; $u_l(i)$ 表示第 l 个特征向量的第 i 的分量; $u_l^*(i)$ 表示 $u_l(i)$ 的共轭向量。图傅里叶变换矩阵形式为 $\hat{f} = U^T f$ 。与之相对应的图傅里叶逆变换为:

$$f(i) = \sum_{l=1}^N \hat{f}(\lambda_l) u_l(i) \quad (4)$$

所以图上傅立叶逆变换的矩阵为 $f = U^T \hat{f}$ 。根据卷积定理(即函数 $f(t)$ 和 $g(t)$ 两者的卷积是其函数傅立叶变换乘积的逆变换),所以图卷积如下所示:

$$(f * g)_c = U \begin{pmatrix} g(\lambda_1) & & \\ & \ddots & \\ & & g(\lambda_n) \end{pmatrix} U^T f \quad (5)$$

式中: $f * g$ 表示函数 $f(t)$ 和 $g(t)$ 的卷积; $U^T f$ 表示 f 的傅里叶变换; g 表示卷积核。

根据拉普拉斯矩阵自身特性,则有 $(f * h)_c = U((U^T h) \odot (U^T f))$, 其中 $\odot$ 为哈达马积,表示两个维度相同的向量进行对应位置的逐元素乘积运算。所以图卷积网络的输出可以表示如下:

$$y_{output} = \sigma(U g_\theta(\lambda) U^T x) \quad (6)$$

式中: x 为输入特征; $\sigma(\cdot)$ 为激活函数; $g_\theta(\lambda)$ 为卷积核。

2 自适应图卷积神经网络机匣故障诊断模型

2.1 自适应图卷积神经网络

通过对航空发动机附件机匣振动信号进行采集,采用 db1 小波包对其分解,并将小波包系数矩阵定义为包含节点与边的图。通过所提的自适应图卷积核提取图中节点与边进行特征提取,最终采用 softmax 层实现航空发动机附件机匣的故障诊断。

如图 1 所示,所提自适应图卷积网络一共有 6 层,其中包含两层自适应图卷积层,两层图池化层,以及两层全连接层。其中,自适应图卷积层主要用于图节点与边的特征提取,全连接层主要用于特征压缩与故障分类。式(6)图卷积操作的计算量非常大,计算消耗量为 $O(n^2)$ 。为了减少训练中卷积核参数的计算量,常采用切比雪夫多项式拟合图卷积核。切比雪夫多项式可以执行递归运算,从而可以减少卷积过程中的计算量。具体公式如下:

$$g_{\theta}(\Lambda) = \sum_{k=0}^{K-1} \beta_k T_k(\tilde{\Lambda}) \quad (7)$$

式中: β_k 表示 Chebyshev 多项式的系数, $\tilde{\Lambda} = 2\Lambda/\lambda_{\max} - I$ 。

$$g_{\theta}(\Lambda) = \begin{pmatrix} \sum_{j=0}^K \theta_j \lambda_1^k & & \\ & \ddots & \\ & & \sum_{j=0}^K \theta_j \lambda_K^k \end{pmatrix} = \sum_{j=0}^K \theta_j \Lambda^k \quad (8)$$

基于拉普拉斯矩阵自身特性,则有 $U g_{\theta}(\Lambda) U^T = U \sum_{j=0}^K \theta_j \Lambda^k U^T = \sum_{j=0}^K \theta_j U \Lambda^k U^T = \sum_{j=0}^K \theta_j L^k$; 因此,在切比雪夫多项式的基础上本文设计了一种自适应图卷积操作,具体如下:

$$y_{\text{output}} = \sigma(U g_{\theta}(\Lambda) U^T x) = \sigma\left(U \sum_{j=0}^K \theta_j \Lambda^k U^T x\right) = \sigma\left(\sum_{j=0}^K \theta_j U \Lambda^k U^T x\right) = \sigma\left(\sum_{j=0}^K \theta_j L^k x\right) \quad (9)$$

式中: x 是由小波系数矩阵定义所得的特征输入图; $\sigma(\cdot)$ 表示激活函数; K 为多项式中自适应参数。




图1 自适应图卷积神经网络航空发动机附件机匣故障诊断模型
Fig. 1 Fault diagnosis model for aero-engine accessory gearbox by adaptive graph convolutional networks

2.2 机匣故障诊断流程

针对强背景噪声条件下航空发动附件机匣故障难以诊断的问题,构建自适应图卷积神经网络对航空发动机附件机匣进行故障诊断,其流程如图 2 所示。




图2 航空发动机附件机匣故障诊断

Fig. 2 The process of aero-engine accessory gearbox fault diagnosis

通过信号采集系统对台架上的航空发动机附件机匣进行振动信号数据采集,采用 db1 小波包对振动信号进行分解,并将分解所得的小波包系数矩阵定义为图节点和边,最后采用所提出的自适应图卷积神经网络对航空发动机附件机匣进行故障诊断。

3 实验验证

3.1 实验设计

为验证所提 AGCNet 模型的准确性,本文采用了传动系统故障诊断模拟实验台 (drivetrain diagnostics simulator test rig, DDS) 产生的 8 类健康状态下的振动数据对所提模型进行验证。DDS 实验台主要由三向交流电机、两级行星齿轮箱、两级平行轴齿轮箱和可编程电磁制动器等部分组成,其实验平台及故障部件安装位置如图 3 所示。




图3 传动系统故障诊断模拟试验台

Fig. 3 Drivetrain diagnostics simulator test rig

实验过程中一共模拟了齿轮箱的 8 种工作状态,其中包括齿轮与轴承的 7 类典型故障,具体如表 1 所示。本文采用 DDS 实验台所产生的故障数据对所提模型的有效性进行验证;在所提模型能够准确识别各类故障后,然后将模型应用于航空发动机附件机匣的故障诊断。

表 1 齿轮箱 8 种健康状态
Table 1 Eight health conditions of gearbox

类别标签	健康状态描述	测试样本/训练样本
1	正常	900/500
2	齿轮点蚀	900/500
3	齿轮偏心	900/500
4	齿轮缺齿	900/500
5	轴承滚动体故障	900/500
6	轴承内圈故障	900/500
7	轴承外圈故障	900/500
8	轴承复合故障	900/500

通过安装在轴承座处的加速度传感器对各类故障振动信号进行采集,其中采集机箱为 NI9188,采集卡为 NI9234,采样频率 25 600 Hz,采样长度为 1 400 K,单次故障测试次数为 4 次。实验过程中,驱动电机的旋转频率在 48 s 内从 20 Hz 线性加速到 36 Hz。将每次所测样本分割为 350 个,4 次共 1 400 个样本;取 900 个作为训练样本,500 个作为测试样本。

3.2 模型参数设置

所提 AGCNet 模型的优化器为 Adam,学习率为 0.001,迭代次数为 60,批次大小为 64,全连接层的丢弃率为 0.6,激活函数为 Relu 函数。第一自适应图卷积层的节点个数为 2 816,边的数量为 8 542,第二自适应图卷积层的节点个数为 1 408,边的数量为 2 081,第一全连接层神经元个数为 512,第二层全连接为输出层,神经元个数为具体样本类别数。为证明所提方法的在强背景噪声下的故障识别能力,对原始振动信号添加了 1 db 的噪声,并与未添加噪声的实验结果进行对比。

3.3 实验结果

为验证所提 AGCNet 模型的故障诊断优良性能,将其与 LeNet^[17]、ResNet(34 层)^[18]和 GCNet^[19]等模型进行对比分析。所有对比模型均采用参考文献中所公开的代码,模型的输入特征均为原始振动信号经过小波包变换后的小波系数矩阵。为保证实验结果的准确性,对每个模型均进行 5 次试验,并取其识别精度的均值和标准差作为最终结果,实验结果如表 2 所示。

表 2 DDS 实验台故障模型识别精度对比结果
Table 2 Comparison of the accuracy of DDS test rig database

方法	平均值±标准差/%	
	未添加噪声	1 db 噪声
LeNet	93.14±2.37	75.77±3.21
ResNet	97.67±1.15	83.22±1.32
GCNet	98.03±1.07	84.16±0.97
所提方法	99.47±0.74	86.37±1.15

实验结果表明:在未添加噪声条件下所提 AGCNet 模型的平均识别精度为 99.47%,分别高于 LeNet、ResNet 以及 GCNet 模型 6.33%、1.80%和 1.44%;在添加强度 1 db 噪声条件下,所提方法的平均识别精度为 86.37%,分别高于 LeNet、ResNet 以及 GCNet 等模型 10.60%、3.15%和 2.21%。此外,所提方法故障识别精度的标准差也小于其他 3 类模型。相比于 LeNet 和 ResNet 所提模型将小波系数矩阵定义为图,能够同时提取图中节点与边的特征,而 LeNet 与 ResNet 只能提取节点特征。在相同条件下所提模型能够提取更多的特征,所以 AGCNet 模型相对于 LeNet 与 ResNet 识别精度更高。所提模型的故障诊断精度高于 GCNet 的原因是:所涉及的自适应卷积核能够自动学习卷积核多项式的大小,进而提高了模型的故障特征提取能力,进而提高了模型故障诊断精度。

为充分说明所提模型对 DDS 实验台故障的诊断结果,采用 t-SNE 降维^[20]方法对所有模型中全连接层的输出结果进行可视化表征。在未加噪声和 1db 噪声条件下各模型全连接层 t-SNE 降维结果如图 4 和 5 所示。

由图 4、5 可知,相比于 LeNet、ResNet 和 GCNet 等模型,所提 AGCNet 可以充分提取小系数矩阵中的故障特征,能够有效识别出 8 类健康状况的类间差异,提高故障识别精度。

为详细分析所提模型对各类故障的识别情况,利用已经训练完成的模型对测试数据进行识别,最终以混淆矩阵的形式进行输出,在未加噪声与 1db 噪声条件下各模型混淆矩阵输出结果如图 6 和 7 所示。

由图 6 与 7 可知,在相同输入条件下所提 AGCNet 对 8 类故障测试样本的诊断精度均高于 LeNet、ResNet 和 GCNet 等模型。通过对训练样本的学习,所提 AGCNet 模型能够准确识别实验台各类故障,说明所提模型能够应用于航空发动机附件机匣的故障诊断。




图4 未加噪声条件下各模型全连接层 t-SNE 降维结果

Fig. 4 The t-SNE results of fully connected layer of different methods under no noise condition






图5 1 dB 噪声条件下各模型全连接层 t-SNE 降维结果

Fig. 5 The t-SNE results of fully connected layer of different methods under 1 db noise condition






图 6 未加噪声条件下各模型混淆矩阵输出结果

Fig. 6 Confusion matrixes of different methods under no noise condition




图 7 1 db 噪声条件下各模型混淆矩阵输出结果

Fig. 7 Confusion matrixes of different methods under 1 db noise condition

4 机匣故障诊断

4.1 数据采集

通过第 3 节的分析可知,所提 AGCNet 模型能够充分提取故障特征,实现齿轮箱的故障诊断。所以,将所提 AGCNet 模型应用于航空发动机附件机匣故障诊断。由于航空发动机附件机匣的特殊保密性,本文只采用机匣的正常状态和齿轮故障状态两组振动信号进行故障诊

断。需要说明的是:在实际航空发动机附件机匣故障智能诊断应用中,通常会以故障注入与实际案例等方式收集多类故障样本,从而实现航空发动机附件机匣故障的智能诊断。为充分模拟航空发动机附件机匣在机载条件下的实际工作状态,采用航空发动机附件机匣专用实验台对机匣进行试验。实验过程中附件机匣的安装方式与其在航空发动机上的安装方式完全相同,且驱动机匣工作的转数与转矩与机载航空发动机附件机匣相同,运行工况相似。本文所采用的两组振动信号是由一台正常状

态机匣和一台故障状态(齿轮故障)机匣台架实验测试所得。测试系统主要包含3个PCB352C03单向加速度传感器、一块NI9234同步采集卡、一个NI9188采集机箱以及一套SP-DSA动态信号分析系统。测试时将加速度传感器安装在航空发动机附件机匣靠近加力泵处,具体测点位置如图8所示。




图8 航空发动机附件机匣测点

Fig. 8 Measuring points of aero-engine accessory gearbox

实验过程中,按照飞机实际预定运行工况对航空发动机附件机匣进行加载,并依照航空发动机最大转数0.4%的间隔进行加速(从最大转数的40%升速到100%)。其中,振动传感器采样频率为25 600 Hz,采样长度为200 K,最终采集到振动信号一共151组。

分别对航空发动机正常机匣和进行测试,以正常机匣的第一轮测试结果作为正常样本,以故障机匣发生故障前一轮测试结果作为故障样本。分别对正常与故障状态下的151组振动信号进行频谱分析,如图9(a)与(b)所示。




图9 机匣正常与故障状态下频率分析结果

Fig. 9 Frequency analysis results of aero-engine accessory gearbox under normal and fault conditions

由图9(a)与(b)可知,在航空发动机附件机匣正常与故障两种状态条件下,由于机匣内部结构复杂,各旋转部件振动信号耦合,在强背景噪声条件下振动信号频谱相似度极高,附件机匣故障诊断极其困难。因此采用所提AGCNet模型对航空发动机附件机匣进行故障诊断。

4.2 结果分析

针对航空发动机附件机匣的振动信号预处理方式与第3.1节相同。所有模型参数设置除最后的输出神经元个数为2,其余参数均与3.2节相同。分别选取两台机匣在发动机核心转数工况(转数的80.0%~91.2%)下的振动数据作为训练与测试样本。其中,训练样本为900个,测试样本为500个。通过对每个模型进行5次重复实验,最终所得各模型的航空发动机故障诊断精度如表3所示。

表3 不同模型对机匣故障识别精度对比结果

Table 3 Comparison results of different models of aero-engine accessory gearbox database fault diagnosis

方法	平均值±标准差/%
LeNet	76.37±3.81
ResNet	81.33±2.06
GCNet	82.12±1.49
AGCNet	86.42±1.17

由表3可知,在强背景噪声条件下所提AGCNet模型对航空发动机附件机匣故障诊断精度分别高于LeNet、ResNet以及GCNet模型10.05%、5.09%和4.30%。产生此现象的原因是:航空发动机附件机匣结构复杂,内部旋转部件振动信息耦合,LeNet和ResNet难以高效提取故障信息;而图卷积网络通过对小波系数矩阵的图定义,抑制了噪声对故障特征提取的干扰;并且所提自适应卷积核可以自动调节卷积核中的多项式长度,进一步提高故障诊断精度。所以,所提AGCNet模型对航空发动机附件机匣故障的识别精度高于其它模型。

为有效观察各模型对航空发动机附件机匣的故障诊断效果,采用t-SNE算法对各模型的全连接层进行可视化,具体结果如图10所示。

由图10可知,所提AGCNet模型对航空发动机附件机匣故障识别效果均高于LeNet、ResNet以及GCNet模型。其中,两类样本没有完全区分的原因是在部分工况下航空发动机附件机匣的故障信息被噪声掩盖,所提模型虽然能抑制一部分噪声,却难以完全消除噪声对特征提取的影响。但总体来说,所提模型在强背景噪声下能够对故障进行诊断,基本满足实际航空发动机附件机匣故障诊断需求。




图 10 强背景噪声下机匣各模型全连接层 t-SNE 降维结果

Fig. 10 The t-SNE results of fully connected layer of different methods under strong background noise condition

5 结 论

本文所提 AGCNet 模型对 DDS 试验台故障振动数据在未添加噪声条件下的平均识别精度为 99.47%, 在添加强度 1 dB 噪声条件下的平均识别精度为 86.37%; 在强背景噪声条件下对航空发动机附件机匣故障平均诊断精度为 86.42%, 均高于 LeNet、ResNet 以及 GCNet 等模型, 可以有效用于机匣的故障诊断。

本文方法通过自适应图卷积核对机匣振动信号的图节点与边的特征提取, 增强了模型的抗噪声能力, 有效地提高了航空发动机附件机匣故障识别精度。

参考文献

- [1] 向刚, 韩峰, 周虎, 等. 数据驱动的航天器故障诊断研究现状及挑战[J]. 电子测量与仪器学报, 2021, 35(2): 1-2.
XIANG G, HAN F, ZHUO H, et al. Data-driven method for spacecraft fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 1-2.
- [2] WEI Z, ZHANG S, JAFARI S, et al. Gas turbine aero-engines real time on-board modelling: A review, research challenges, and exploring the future [J]. Progress in Aerospace Sciences, 2020, 121: 1-3.
- [3] LU F, JIANG J, HUANG J, et al. Dual reduced kernel extreme learning machine for aero-engine fault diagnosis [J]. Aerosp Sci Technol, 2017, 71: 742-750.
- [4] 王海霞, 袁惠群, 冯鑫. 发动机附件机匣振动分析与故障排除方法 [J]. 振动. 测试与诊断, 2013, 33(z1): 206-209.
- [5] MOLLA W, AMBRI Z, KARIM A, et al. Materials today: Proceedings review on gas turbine condition based diagnosis method [J]. Mater Today Proc, 2021, 7: 1-2.
- [6] 康守强, 刘哲, 王玉静, 等. 基于改进 DQN 网络的滚动轴承故障诊断方法 [J]. 仪器仪表学报, 2021, 42(3): 201-212.
KANG SH Q, LIU ZH, WANG Y J, et al. A fault diagnosis method of rolling bearing based on the improved DQN network [J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 201-212.
- [7] 吕枫, 王义, 阮胡林, 等. 深度嵌入关系空间下齿轮箱标记样本扩充及其半监督故障诊断方法 [J]. 仪器仪表学报, 2021, 42(2): 55-65.
LYU F, WANG Y, RUAN H L, et al. Labeled sample augmentation based on deep embedding relation space for semi-supervised fault diagnosis of gearbox [J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 55-65.
- [8] ZHANG H, CHEN X, DU Z, et al. Nonlocal sparse model with adaptive structural clustering for feature extraction of aero-engine bearings [J]. Sound Vib, 2016, 368: 223-248.
- [9] ZHANG Z, LI S, WANG J, et al. Enhanced sparse

- filtering with strong noise adaptability and its application on rotating machinery fault diagnosis [J]. Neurocomputing, 2020, 398:31-44.
- [10] WANG Y S, LIU N N, GUO H, et al. An engine-fault-diagnosis system based on sound intensity analysis and wavelet packet pre-processing neural network [J]. Eng Appl Artif Intell, 2020, 94: 2-5.
- [11] DONG X, LI G, JIA Y, et al. Multiscale feature extraction from the perspective of graph for hob fault diagnosis using spectral graph wavelet transform combined with improved random forest [J]. Meas J Int Meas Confed, 2021, 176:3-9.
- [12] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020. 32:4-24.
- [13] HENAFF M, BRUNA J, LECUN Y. Deep convolutional networks on graph-structured data [J]. Computer Science, 2015:1506.
- [14] LEVIE R, MONTI F, BRESSON X, et al. Cayleynets: Graph convolutional neural networks with complex rational spectral filters [J]. IEEE Transactions on Signal Processing, 2018, 67(1): 97-109.
- [15] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering [J]. Arxiv Preprint, 2010, ArXiv:1606.09375.
- [16] WANG X, YE Y, GUPTA A. Zero-shot recognition via semantic embeddings and knowledge graphs [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6857-6866.
- [17] ZHANG Y, GAO J, ZHOU H. Breeds classification with deep convolutional neural network [C]. Proceedings of the 2020 12th International Conference on Machine Learning and Computing, 2020: 145-151.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [19] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks [J]. Arxiv Preprint, 2016, ArXiv:1609.02907.
- [20] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9: 2579-2605.

作者简介



余晓霞, 2016 年于重庆理工大学获得学士学位, 2019 年于重庆理工大学获得硕士学位, 现为重庆大学博士研究生, 主要研究方向为机械故障诊断。

E-mail: xiaoxiayull@hotmail.com

Yu Xiaoxia received his B. Sc. degree and M. Sc. degree both from Chongqing University of Technology in 2016 and 2019, respectively. He is currently pursuing the Ph. D. degree in mechanical engineering at Chongqing University. His main research interests include mechanical fault diagnosis.



汤宝平 (通信作者), 1996 年于重庆大学获得硕士学位, 2003 年于重庆大学获得博士学位, 现为重庆大学教授、博士生导师, 主要研究方向为无线传感器网络、机电装备安全服役与寿命预测、测试计量技术及仪器。

E-mail: bptang@cqu.edu.cn

Tang Baoping (Corresponding author) received his M. Sc. and Ph. D. both from Chongqing University in 1996 and 2003, respectively. He is currently a professor and a Ph. D. advisor at Chongqing University. His research interest includes wireless sensor networks, mechanical and electrical equipment security service and life prediction, and measurement technology and instruments.