

# 基于异构输入和改进集成学习的滚动轴承故障诊断

赵柄锡<sup>1</sup>, 虞磊<sup>1</sup>, 陈景阳<sup>1</sup>, 马梁<sup>2</sup>, 王俊<sup>3</sup>

- (1. 中国航发商用航空发动机有限责任公司, 上海 200240;  
2. 中国民航大学 天津民用航空器适航与维修重点实验室, 天津 300300;  
3. 中国科学院力学研究所 非线性力学国家重点实验室, 北京 100190)

**摘要:** 针对传统滚动轴承故障诊断无法利用多维故障信息以及仅关注总体正确率而较少考虑类别间诊断均衡性的问题, 构建了一种具有异构输入的滚动轴承集成学习故障诊断方法。为此, 首先发展了基于多域异构输入和特征融合的复合结构分类器 (hybrid structured network model, H-NET), 相比单网络结构模型增加了输入的多样性和特征稳健性; 其次, 针对传统 Adaboost 集成学习未考虑类别间分类均衡性的问题, 引入类别权重提出了 H-NET 训练策略, 将其与 Adaboost 算法融合建立了改进的集成学习方法。验证结果表明: 采用 H-NET 相对单网络结构模型可以提高故障诊断的正确率和均衡性; 同时, 基于改进后集成学习构建的故障诊断模型在保证总体正确率同时提升了强分类模型的稳健性。最后与文献中方法进行对比, 进一步表明了该方法的优越性。

**关键词:** 滚动轴承; 异构输入; 集成学习; 故障诊断

中图分类号: TH17

文献标志码: A

DOI:10.13465/j.cnki.jvs.2024.19.020

## Fault diagnosis of rolling bearings based on heterogeneous inputs and improved ensemble learning

ZHAO Bingxi<sup>1</sup>, YU Lei<sup>1</sup>, CHEN Jingyang<sup>2</sup>, MA Liang<sup>2</sup>, WANG Jun<sup>3</sup>

- (1. AECC Commercial Aircraft Engine Co., Ltd., Shanghai 200240, China; 2. Tianjin Municipal Key Lab for Civil Aircraft Airworthiness and Maintenance, Civil Aviation University of China, Tianjin 300300, China; 3. State Key Lab of Nonlinear Mechanics, Institute of Mechanics, Chinese Academy of Sciences, Beijing 100190, China)

**Abstract:** Here, aiming at problems of traditional rolling bearing fault diagnosis being unable to utilize multidimensional fault information as well as only focusing on overall correctness rate and less considering inter-class diagnostic balance, a rolling bearing ensemble learning fault diagnosis method with heterogeneous inputs was constructed. Firstly, a hybrid structured network model (H-NET) based on multi-domain heterogeneous inputs and feature fusion was developed, it could increase the diversity of inputs and robustness of features compared to a single network structure model. Secondly, aiming at the problem of traditional Adaboost ensemble learning not considering the balance of inter-class classification, H-NET training strategy was proposed by introducing class weights, it was integrated with Adaboost algorithm to establish an improved ensemble learning method. Finally, the verification results showed that compared to a single network structure model, using H-NET can improve the correctness rate and balance of fault diagnosis; meanwhile, the fault diagnosis model constructed based on improved ensemble learning can improve the robustness of strong classification model, and ensure the overall correctness rate; compared with the published methods in literature, the superiority of the proposed method is obvious.

**Key words:** rolling bearing; heterogeneous input; ensemble learning; fault diagnosis

滚动轴承被广泛用于旋转机械中, 支撑机械旋转体, 降低其运动过程中的摩擦因数并保证回转精度。实际运行中, 污染物、润滑不佳、装配超差等因素常引

发轴承损伤, 若缺乏有效的轴承故障技术使损伤持续发展, 将最终导致轴承非预期失效乃至引发事故。已有的统计表明, 在常见的旋转机械设备中, 与滚动轴承相关的故障占到了总故障的 30%~40%<sup>[1]</sup>, 因此, 为保证设备的安全、稳定运行, 发展有效的滚动轴承故障诊断技术至关重要。正常运行过程中滚动轴承的振动通

基金项目: 国家自然科学基金(12202229)

收稿日期: 2023-11-15 修改稿收到日期: 2024-03-12

第一作者 赵柄锡 男, 博士, 工程师, 1991 年生

常由外部激励导致,而在轴承发生损伤时,轴承本身变为激励源,由各组成部件(内圈、外圈、滚动体等)耦合作用产生时变激振力,改变轴承振动,而轴承信号中也包含了对应的故障特征,通过对轴承振动特征的提取和分析有助于轴承故障的定位和诊断,当前对滚动轴承故障诊断的研究多数基于振动信号<sup>[2-5]</sup>。通常直接采集得到的振动信号为一维时域信号,在此基础上的信号分析和特征提取常从时域、频域和时频域三个方面开展。传统时域分析主要采用统计方法,基于不同的统计指标对原始信号进行特征提取用于滚动轴承故障诊断<sup>[6-7]</sup>;与时域特征不同,频域特征揭示了信号中各成分的频率信息,通常包含了轴承各部件的自振与耦合频率,故障状态下信号中还会产生与故障部位及严重程度对应的频率。传统频域特征提取需要将振动信号由时域转换至频域下,常用方法包括频谱分析和包络谱分析,在该方面相关学者已开展了大量研究<sup>[8-11]</sup>。然而,实际滚动轴承振动信号一般包含了大量的非平稳时变成分,信号中各频率成分随着时间而变化。该情况下,上述介绍的时域和频域分析具有一定的局限性。时频域分析则很大程度上解决了该问题,常用的时频域解析方法包括短时傅里叶变换(short time Fourier transform, STFT)<sup>[12-13]</sup>、小波变换(wavelet transform, WT)<sup>[14-15]</sup>和经验模态分解(empirical mode decomposition, EMD)<sup>[16]</sup>等。

上述信号分析及特征提取方法可以建立信号在不同域下的表征,具有较好的可解释性,但特征提取较浅,且对专业知识要求较高。随着轴承结构和运行环境的日益复杂,故障的产生和演变规律也随之发生变化,传统特征提取方法的局限性逐渐显露。近年来发展的人工智能方法,可以对复杂特征进行有效地提取,且不依赖于专业领域知识。Shen 等<sup>[17]</sup>提出了基于奇异值分解(singular value decomposition, SVD)和迁移学习的轴承故障诊断方法,其中采用 SVD 对原始信号进行特征提取,基于所得特征建立相似性准则用来定量判断网络之间迁移学习的可能性。Lu 等<sup>[18]</sup>为了增强提取特征对不同故障的敏感性,采用深度神经网络(deep neural network, DNN)对原始信号进行故障特征提取,在此基础上对滚动轴承进行了故障诊断。Zhao 等<sup>[19]</sup>针对轴承寿命退化特征的提取发展了深度学习特征提取方法。该方法首先采用自编码器(autoencoder, AE)对振动信号的时频变换结果进行压缩并将隐含层所得结果作为信号总体特征,在此基础上进行特征优化选取。

然而,当前基于人工智能的故障诊断还存在一些不足。一方面基于人工智能算法进行特征提取的有效性虽然被大量研究验证,但多数直接对原始时域信号

进行特征提取,相对于传统特征提取虽然增加了特征深度,但可解释性较差。由前述分析可知,传统时域、频域和时频域分析方法可以构建具有更高解释性的信号表征,因此为了增强特征提取的有效性,有必要将高解释性的传统特征提取方法与更深度的人工智能方法相结合,提升滚动轴承故障诊断效果;另一方面,根据前述介绍,原始信号在时域、频域和时频域均包含了丰富的特征,这些特征在尺度上并不统一,也较难融合。而当前滚动轴承故障诊断多采用单网络结构模型,从输入的角度,单模型通常只对应一种尺度下的输入,限制了输入的多样性,不利于故障诊断模型准确性和泛化性能的提升。集成学习算法的出现为后者提供了解决思路,其通过将多个弱监督模型进行组合得到一个强监督模型,该模型的预测结果由各个弱监督模型共同决定。相对单个弱监督模型,集成学习可以较大程度上避免诊断模型过拟合的发生,因而具有较强的泛化能力。Xu 等<sup>[20]</sup>采用决策树模型作为弱分类器,建立了随机森林强分类器模型进行特征提取并将所得特征作为强分类器的输入进行滚动轴承故障诊断。陈法法等<sup>[21]</sup>采用支持向量机(support vector machine, SVM)作为弱分类器,基于 AdaBoost 集成学习算法建立了用于滚动轴承早期故障诊断的强分类器,证明了集成学习算法可以提升最终的分类效果。然而,现有的集成故障诊断模型还存在以下不足:① 采用的弱分类器结构简单,难以提取到深层次的特征;② 多采用相同结构的弱分类器,输入尺度单一,无法全面利用不同维度的故障信息;③ 仅考虑总体分类效果,未考虑各类别分类的均衡性,可能导致强分类器对某一类样本适用性较差。

综合上述问题,本文基于深度学习模型构建了新型复合结构分类器(hybrid network model, H-NET),采用多域异构信息为输入;同时,还引入了类别权重及其训练策略对传统集成学习算法进行改进,提升集成学习故障诊断的均衡性,最后采用实例对上述方法进行了验证。

## 1 基础理论

### 1.1 包络谱

包络谱分析被广泛用于滚动轴承的故障诊断<sup>[22-24]</sup>,获取时域信号的包络谱主要分为两步,信号包络解调和包络频谱变换。前者采用 Hilbert 变换,后者采用快速傅里叶变换(fast Fourier transform, FFT)提取信号的包络谱信息。

设时域信号  $s(t)$ , 其 Hilbert 变换定义为

$$\hat{s}(t) = H\{s(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{s(\eta)}{t - \eta} d\eta \quad (1)$$

式中,  $\hat{s}(t)$  为原始信号经 Hilbert 变换后所得信号,本

质是对原始信号进行了全通移相。基于上述变换结果,原时域信号的解析形式可表示为

$$s_A(t) = s(t) + j\hat{s}(t) = A(t)e^{j\psi(t)} \quad (2)$$

式中:变换后的解析信号  $s_A(t)$  为复数形式; $A(t)$  为瞬时幅值即包络; $\psi(t)$  为包络的瞬时相位。对上述所得瞬时幅值应用 FFT 将其映射至连续的频谱空间可得

$$A(\omega) = \int_{-\infty}^{\infty} A(t)e^{-j\omega t} dt \quad (3)$$

## 1.2 小波变换

小波变换用于非稳定信号的时频分析,可分为离散小波变换(discrete wavelet transform, DWT)和连续小波变换(continuous wavelet transform, CWT),本文采用后者进行时频域转换。设一维振动信号  $s(t)$ ,其在伸缩因子  $a(a > 0, a \in \mathbb{R}^+)$  和平移因子  $b(b \in \mathbb{R}^+)$  下的连续小波变换可表示为

$$c_s(a, b) = s * \psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} s(t) \cdot \overline{\psi_{a,b}\left(\frac{t-b}{a}\right)} dt \quad (4)$$

式中: $*$  为卷积符号; $\psi_{a,b}(\cdot)$  为小波函数族;上划线“ $\overline{\quad}$ ”表示共轭; $c_s$  为连续小波系数。小波函数族可由小波母函数  $\psi(t)$  得到

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (5)$$

从式(5)可以看出,不同于傅里叶变换中变量只有频率  $\omega$ ,小波变换具有伸缩因子  $a$  和平移因子  $b$ ,因此具有良好的时间和频率分辨率,更有利于提取信号局部时频特征。

## 1.3 卷积神经网络(convolutional neural network, CNN)

CNN 通过局部感受野、权重共享和降采样三种策略,降低了网络模型的复杂度,广泛应用于图像分类等领域,其主要结构包括卷积层、池化层和全连接层等。

(1) 卷积层。卷积层由一组卷积单元构成,通过执行卷积操作提取输入的局部特征。假设第  $l$  层为卷积层,  $M_j$  为第  $l$  层第  $j$  个卷积核在第  $l-1$  层的覆盖范围,则第  $j$  个卷积核的输出可表示为

$$a_j^l = \sigma\left(\sum_{i \in M_j} x_i^{l-1} * w_{ij}^l + b_j^l\right) \quad (6)$$

式中: $w_{ij}^l$  为第  $l$  层第  $j$  个卷积核第  $i$  个位置上的值; $*$  为卷积符号; $b_j^l$  为卷积核对应的偏置大小; $\sigma(\cdot)$  为激活函数,常用激活函数有 Sigmoid、Tanh 和 Relu 等。

(2) 池化层。池化层通常放置在卷积层之后,用于保留重要特征并降低网络的参数数量。目前主要的池化方法是均值池化和最大池化。基于上一层输出  $x_n^{l-1}$ ,池化过程表示为

$$x_n^l = \text{pool}(x_n^{l-1}, p, s) \quad (7)$$

式中: $x_n^l$  为  $x_n^{l-1}$  池化后的输出;pool( $\cdot$ ) 为下采样操作(取最大值或平均值); $p$  和  $s$  则分别为池化区域和移动步长。

(3) 全连接层。全连接层通常置于网络的最后,其作用是基于前序网络层提取的深度特征输出最后的分类或回归结果。第  $l$  层全连接层的输出  $x^l$  可计算为

$$x^l = \sigma(w^l x^{l-1} + b^l) \quad (8)$$

式中: $x^{l-1}$  为上一层(第  $l-1$  层)全连接层的输出或量化的卷积层输出; $w^l$  和  $b^l$  分别为权重矩阵和偏置向量。

除上述标准层外,一些用于提升网络性能的特殊层如批归一化层、随机失活层等也常用于卷积神经网络构建,此处不再赘述。

## 2 故障诊断框架

### 2.1 同源异构输入构造

滚动轴承故障信息在时域、频域和时频域均具有一定表征。为了充分利用振动信号包含的故障信息,分别在上述三个维度下进行输入构造,具体如下:

(1) 时域输入采用将原始时域信号直接分段的构造方式,分段长度综合考虑硬件计算能力以及样本的信息携带量,将样本长度取为 256,即时域输入为一维形式;

(2) 频域输入构造考虑到轴承故障的调幅特征,采用基于 Hilbert 变换的包络谱分析,其变换过程参见式(1)~式(3),所得频率序列对称分布,一般取其一一半作为原时域信号的包络谱。单次包络谱分析基于的时域数据长度与上述时域输入一致,得到的包络谱则为时域输入的一半,即频域输入为一维形式,长度为时域输入的一半,均为 128;

(3) 时频域输入构造采用连续小波变换,同样基于上述时域输入。采用 Morlet 小波基,变换过程参考式(4)~式(5),其中频域被 256 等分,最终所得小波系数矩阵维度为  $256 \times 256$ ,将所得矩阵进行灰度处理并生成二维灰度图形作为时频域输入。因此时频域输入为二维形式,且时域、频域维度相同,均为 256。

上述输入基于相同的原始时域信号,但不同域下构造的输入尺度互不相同,因此三者为同源异构关系。输入构造过程示意图,如图 1 所示。

时频变换方法对揭示轴承故障特征的作用已经被广泛验证,上述方法结合领域先验知识,通过将原始信号稀疏化处理获取其异构表达形式,使神经网络提取的特征更具有针对性,一定程度上增加了模型的可解释性。

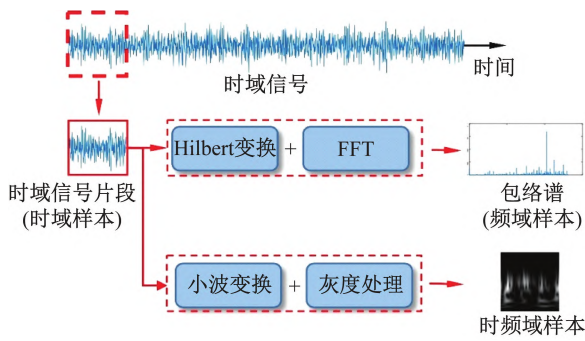


图 1 同源异构输入构造示意图

Fig. 1 Schematic diagram of homologous heterogeneous inputs construction

## 2.2 复合结构分类器

### 2.2.1 分类器结构

考虑融合各异构输入包含的故障特征,构造了基于特征融合和卷积神经网络的复合结构分类器(H-NET),包含了3个输入和1个输出,其中3个输入分别对应了三类异构样本,输出则为样本对应的分类结果,如图2所示。

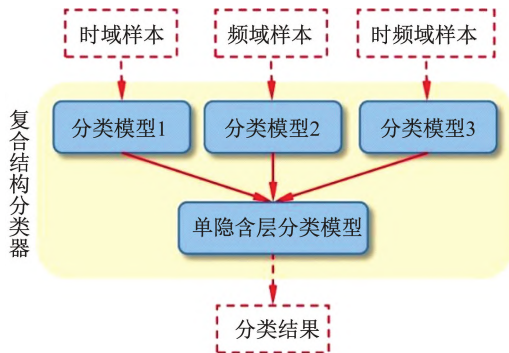


图 2 H-NET 分类器结构

Fig. 2 Structure of H-NET classifier

H-NET 分类器包含了三个主分类模型(分类模型 1、2 和 3)和一个单隐含层模型。网络结构方面,三个主分类模型均采用卷积神经网络,分别用于时域、频域和时频域特征提取,提取位置为与输出相连的全连接层。各主分类模型具体结构与对应输入维度配合,即一维输入对应一维卷积神经网络,二维输入同理。将各主分类模型提取的特征融合,进入单隐含层进行分类,其本质是通过自我学习得到每个特征最佳权重。即单个输入为  $x$ ,相应的主分类模型提取特征序列  $F$  可表示为

$$F = \{q_1, q_2, \dots, q_n\} = f(x) \quad (9)$$

式中: $q$  为故障特征; $n$  对应特征提取层的单元数目; $f()$  为主分类模型从输入层至 softmax 层之前的网络前向传播过程。各异构输入所得特征融合后可表示为

$$F_{tot} = \{q_1^T, q_2^T, \dots, q_n^T, q_1^F, q_2^F, \dots, q_n^F, q_1^{TF}, q_2^{TF}, \dots, q_n^{TF}\} \quad (10)$$

式中: $F_{tot}$  为融合后的总特征向量;上标 T、F 和 TF 分别

代表时域、频域和时频域。

采用同源异构输入下的融合特征进行故障诊断得到单隐含层分类模型,最后,将前述所得的所有模型组合建立最终的 H-NET 分类器。该过程利用了神经网络以故障诊断正确率为导向进行训练的原理,提取与故障深度关联的特征。

### 2.2.2 分类器训练策略

构建 H-NET 分类器时引入类别权重,通过调整目标类别的预测损失改变模型预测的均衡性,并由此建立了 H-NET 的训练策略。设训练样本集共含有  $N_s$  个样本,预测类别总数为  $m$ ,类别权重  $W_c = \{c_1, c_2, \dots, c_m\}$ ,则调整后的损失函数变为

$$L_w = \frac{1}{2 N_s} \sum_{i=1}^m \sum_{j=1}^{N_s} c_i (\hat{y}_{ij} - y_{ij})^2 \quad (11)$$

式中: $L_w$  在表示引入类别权重后的训练损失; $y_{ij}$  和  $\hat{y}_{ij}$  分别表示第  $j$  个样本属于第  $i$  个类别的真实概率值和预测概率值。

上述在损失函数中引入类别权重,相比调整前的损失函数,主要是为调整各类别诊断效果提供工具,进而实现 H-NET 训练策略。由于训练过程是沿着损失函数降低方向进行,通过设置差异化的类别权重,可以改变弱勢类别样本在训练过程中的比重,进而调整模型训练方向。在上述基础上,为了降低 H-NET 分类器对各类别预测正确率的差异,提出了以下 H-NET 训练策略:

首先构造 H-NET 的初始模型,对 3 个主分类模型分别进行训练。设第  $j$  个主分类模型对第  $i$  类样本预测正确率为  $a_{ij}$ ,临界类别正确率差值为  $\Delta A_{th}$ ,则通过下述步骤对各类别权重进行调整:

**步骤 1** 计算各类别平均预测正确率

$$a_i = \frac{1}{3} \sum_{j=1}^3 a_{ij}, i = 1, 2, \dots, m \quad (12)$$

**步骤 2** 计算类别间故障诊断的正确率偏差

$$\Delta A = \sqrt{\frac{1}{m(m-1)} \sum_{j,k=1}^m (a_j - a_k)^2}, j \neq k \quad (13)$$

**步骤 3** 若  $\Delta A > \Delta A_{th}$ ,对最高、最低正确率对应类别权重进行调整

$$\max_j(c_{i_{max}j}) = \max_j(c_{i_{max}j}) \cdot (1 - \alpha_{max} \cdot \Delta A) / Z_{i_{max}} \quad (14)$$

$$\min_j(c_{i_{min}j}) = \min_j(c_{i_{min}j}) \cdot (1 + \alpha_{min} \cdot \Delta A) / Z_{i_{min}} \quad (15)$$

式中: $c_{ij}$  为第  $i$  个主分类器对第  $j$  类别的权重; $i_{max}$  和  $i_{min}$  分别为最大、最小平均预测正确率对应类别序号, $\alpha_{max}$  和  $\alpha_{min}$  分别对应最大、最小权重更新步长因子; $Z_{i_{max}}$  和  $Z_{i_{min}}$  为最大和最小规范化因子

$$Z_{i_{max}} = \sum_j c_{i_{max}j}, Z_{i_{min}} = \sum_j c_{i_{min}j} \quad (16)$$

若  $\Delta A \leq \Delta A_{th}$ ,则采用已有类别权重进行后续模型

训练,无需进行调整。

**步骤4** 根据式(14)~(15)确定需要调整的主分类模型,并采用调整后的类别权重在现有网络参数下进行重新训练。之后重复步骤1~3,直至各类别间故障诊断结果偏差  $\Delta A < \Delta A_{th}$ 。

上述类别权重调整策略利用主分类模型之间的互补性,保证各类别至少在一个主分类模型上具有较好的预测效果,从而保证融合特征包含了各类别的重要特征,以此提高 H-NET 最终预测结果的类别均衡性。

需要指出的是,上述训练策略在提升模型准确率和均衡性的同时,还可能带来由于反复训练造成的时间成本增加问题。针对该问题,一方面,时间成本的增加本质是因为需要提升模型的故障诊断均衡性(目前多数方法并没有关注该方面),本文提出的训练方法则为该寻优过程提供了自动调节策略(即调节类别权重),相比人工超参数寻优来实现此目标,实际可能会有更高的效率;另一方面,增加的时间成本主要与硬件配置、模型深度以及临界阈值等因素有关,实际在应用时可视具体条件调整上述因素,例如采用简单的主分类模型结构或增加临界阈值,来得到权衡后的最佳效果。

## 2.3 改进的集成学习

### 2.3.1 AdaBoost 集成学习算法

AdaBoost 集成学习算法解决了各弱分类器权重分配、更新和组合预测问题。基于 AdaBoost 算法构建强分类器过程如下:

设训练样本集  $S$  为

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (17)$$

式中,  $x_i \in X, y_i \in Y = \{1, \dots, C\}$ ,  $X$  和  $Y$  分别为样本集和标签集。首先对样本集权重  $W_1$  初始化为  $W_1(i) = 1/N_s$ , 其中  $i = 1, \dots, N_s, N_s$  为总样本数。训练第 1 个弱分类器  $h_1$  对样本集进行分类,完成如下映射

$$X \times Y \rightarrow [0, 1] \quad (18)$$

计算样本集在该弱分类器  $h_1$  上的加权误差率

$$\varepsilon_1 = \frac{1}{2} \sum_{i,y \in B} W_1(i,y) (1 - h_1(x_i, y_i) + h_1(x_i, y)) \quad (19)$$

式中,  $B = \{(i, y) : i = 1, \dots, N_s, y \neq y_i\}$ 。

则该弱分类器权重为

$$\alpha_1 = \frac{\varepsilon_1}{1 - \varepsilon_1} \quad (20)$$

之后对样本权重按下式进行更新

$$W_2(i, y) = (W_1(i, y) / Z_1) \cdot \alpha_1^{w_1} \quad (21)$$

其中

$$w_1 = \frac{1}{2} (1 - h_1(x_i, y_i) + h_1(x_i, y)) \quad (22)$$

$$Z_1 = \sum_i W_1(i, y) \cdot \beta_1^{w_1} \quad (23)$$

至此完成第 1 个弱分类器的添加,通过预设置弱分类器数量  $T$ ,按照上述步骤依次进行添加,最终得到强分类器

$$h_{fn} = \arg \max_{y \in Y} \sum_{i=1}^T \left( \ln \frac{1}{\alpha_i} \right) \cdot h_i(x, y) \quad (24)$$

由上式可以看出,集成后的强分类器本质上通过加权投票方式得到最终的分类结果。

### 2.3.2 改进集成学习算法

本文采用 H-NET 分类模型作为集成学习的弱分类器,并引入前述建立的 H-NET 分类器训练策略对上述集成学习算法进行改进。由于集成学习引入了样本权重,式(11)中训练损失相应变为

$$L_w = \frac{1}{2N_s} \sum_{i=1}^m \sum_{j=1}^{N_s} c_i s_j (\hat{y}_{ij} - y_{ij})^2 \quad (25)$$

式中,  $c$  和  $s$  分别为类别权重和样本权重。

在单个 H-NET 分类器训练时,保持样本的权重不变,对类别权重进行更新,完成 H-NET 训练后的剩余步骤与改进前一致。设目标弱分类器数目为  $n_{th}$ ,则采用 H-NET 弱分类器模型的集成学习流程,如图 3 所示。

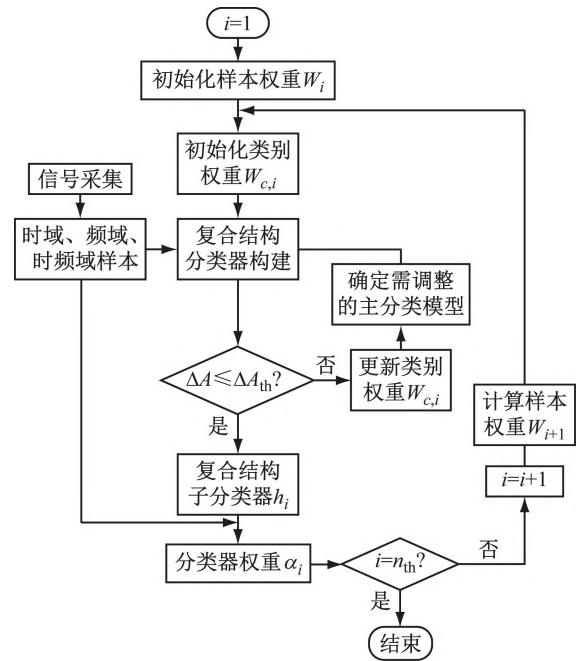


图3 改进的集成学习模型构建流程图

Fig. 3 Improved integrated learning model building flowchart

## 3 案例分析

### 3.1 数据介绍与样本构造

本文采用美国凯斯西储大学(Case Western Reserve University, CWRU)滚动轴承试验数据集<sup>[25]</sup>,对上述方法进行演示和验证。试验装置如图4所示,考察轴承分别位于电机的风扇端和驱动端,其中驱动端轴承采样频率为 12 kHz 和 48 kHz,风扇端轴承采样频率为 12 kHz,本文采用 12 kHz 采样频率下的驱动端数据用于

故障诊断研究。




图 4 美国凯斯西储大学滚动轴承试验装置图

Fig. 4 The test rig for rolling bearing test from Case Western Reserve University

实际验证过程中发现,当诊断的故障之间差异较大时(例如转速、故障类型和故障点直径均不同),无论采用单网络结构模型还是本文提出的 H-NET,所构建的集成故障诊断模型均能得到较高的正确率 (> 98%),无法体现两者之间的差异。因此,本章选定同一故障类型和运行转速但是不同故障点直径大小下的数据进行故障诊断,目的是增加故障间的相似性从而增加诊断难度。最终选定的数据集包含了 4 种故障类别(C1 ~ C4)和 1 种正常类别(C5),相关描述如表 1 所示。

表 1 本文故障诊断采用数据的相关信息

Tab.1 The data used for fault diagnosis

标签	转速/ ( $r \cdot \min^{-1}$ )	负载/hp	故障位置	故障点直径/ mm
C1				0.177 8
C2				0.355 6
C3	1 797	0	内圈	0.533 4
C4				0.711 2
C5			—	—

表 2 三类异构输入对应的主分类模型结构参数

Tab.2 The structural parameters of the main classification model corresponding to the three types of heterogeneous inputs

模型	T-NET	F-NET	TF-NET
第 1 层	输入层(256 × 1, 1)	输入层(128 × 1, 1)	输入层(256 × 256, 1)
第 2 层	卷积层(13 × 1, 8)	卷积层(7 × 1, 12)	卷积层(15 × 15, 5)
第 3 层	池化层(4 × 1, 8)	池化层(3 × 1, 12)	池化层(4 × 4, 5)
第 4 层	卷积层(7 × 1, 14)	卷积层(7 × 1, 12)	卷积层(11 × 11, 8)
第 5 层	池化层(2 × 1, 14)	池化层(5 × 1, 12)	池化层(2 × 2, 8)
第 6 层	卷积层(7 × 1, 10)	全连接层(1 × 5, 1)	卷积层(7 × 7, 10)
第 7 层	全连接层(1 × 5, 1)	Softmax 层(1 × 5, 1)	全连接层(1 × 5, 1)
第 8 层	Softmax 层(1 × 5, 1)	—	Softmax 层(1 × 5, 1)

随后,建立单隐含层全连接网络结构如表 3 所示。

表 3 单隐含层全连接网络结构参数

Tab.3 Parameters of a fully connected network structure with a single hidden layer

层名称	输入层	隐含层	输出层
神经元数目	15	10	5

基于 2.1 节进行样本构造,其中每个标签下生成的三类异构样本数量大致相同,均为 500 个左右。某个信号片段下生成的三类异构样本,如图 5 所示。




图 5 基于某信号片段建立的(时域、频域和时频域)异构样本  
Fig. 5 Heterogeneous samples (time-domain, frequency-domain, and time-frequency domain) based on one signal segment

### 3.2 故障诊断模型构建

针对各异构输入分别建立主分类模型(时域模型 T-NET、频域模型 F-NET、时频域模型 TF-NET),模型结构如表 2 所示,其中每个卷积层后附加 BN 层和 Relu 激活层,且最后一个全连接层之前设置有 50% 概率的 DP 层。训练采用随机梯度下降算法,小批量设置为 128,学习率初始值均设置为 0.009,每 10 次迭代变为原来的 90%,最小学习率均设置为 0.001。

### 3.3 故障诊断与分析

#### 3.3.1 H-NET 与单网络结构模型对比

本节对比 H-NET 分类器相对传统单网络结构分类器(即单个主分类模型)在故障诊断方面的差异。为了验证 H-NET 模型相比单网络结构分类器(即单个主分类模型)在提升故障诊断正确率和均衡性方面的有效

性,同时考察上述正确率及均衡性的提升随融合前特征有效性的变化,按照正确率将故障诊断网络分为三个等级(L1 ~ L3),如表4所示,分别在不同等级下分别进行故障诊断差异对比。不同等级的网络生成通过在训练过程控制网络模型正确率来实现,具体原则为:①若训练过程中,各主分类模型在验证集上能达到对应等级正确率范围,则停止各主分类模型训练,保留模型;②若存在单个主分类模型受限于自身原因无法达到要求的等级,则保证各主分类模型正确率平均值达到对应等级。

表4 不同等级网络模型对应的故障诊断正确率数值范围

Tab.4 Numerical range of fault diagnosis accuracy corresponding to different levels of network models

指标	L1	L2	L3
正确率	50% ~ 70%	70% ~ 85%	85% ~ 100%

表5列举了不同等级下各单模型网络(T-NET、F-NET和TF-NET)和H-NET对应的故障诊断正确率。

表5 不同正确率等级下的各单网络结构模型和H-NET所得故障诊断结果对比

Tab.5 Comparison of fault diagnosis results obtained by single-structure networks and H-NET under different accuracy levels

正确率等级	T-NET	F-NET	TF-NET	H-NET
L1	60.71	58.61	62.32	78.78
L2	83.40	77.94	81.89	93.07
L3	86.13	82.11	93.05	98.53

观察表5中结果可以看出,每个正确率等级下H-NET的故障诊断性能均优于组成其结构的三个单网络结构模型(主分类模型)。通过计算可知,L1~L3三个

表6 不同数量单结构网络准确率等级降低对H-NET准确率的影响

Tab.6 The impact of decreasing accuracy levels of single structure networks with different numbers on the accuracy of H-NET

指标	模型	单个网络等级降低			两个网络等级降低			三个网络等级降低		
等级变化	T-NET	—	—	L4→L2	—	L4→L2	L4→L2	L4→L2	L4→L2	L4→L3
	F-NET	—	L4→L2	—	L4→L2	—	L4→L2	L4→L2	L4→L3	L4→L2
	TF-NET	L4→L2	—	—	L4→L2	L4→L2	—	L4→L3	L4→L2	L4→L2
绝对降低量/%	T-NET	—	—	25.42	—	22.94	22.94	22.94	22.94	1.86
	F-NET	—	34.44	—	34.44	—	34.44	34.44	15.11	34.44
	TF-NET	22.94	—	—	25.42	25.42	—	4.24	25.42	25.42
	平均	7.65	11.48	8.47	19.95	16.12	19.13	20.54	21.16	20.57
H-NET	变化前/%	98.53								
	变化后/%	95.26	90.95	93.78	87.8	95.05	90.36	86.34	84.85	91.89
	降低量/%	3.27	7.58	4.75	10.73	3.48	8.17	12.19	13.68	6.64

除上述外,对单网络结构模型和H-NET模型在不同类别上诊断效果的均衡性进行对比,其中采用标准差作为定量评价指标,计算结果如表7所示。对表7中结果进一步计算可知,在三个等级下采用H-NET模

等级下单网络结构模型平均分类正确率分别为60.55%、81.08%和87.10%,其对应的H-NET模型相对单网络结构模型平均正确率在三个等级下分别提升18.23%、11.99%和11.43%,证明了H-NET模型在提高故障诊断精度方面的效果;同时还可以看出,正确率提升幅度随单网络结构模型正确率的增加而降低,原因是随着单网络结构模型诊断效果的提升,不同单网络结构模型提取的特征差别逐渐减小,特征之间的互补性降低,进而减弱了特征融合对故障诊断正确率的提升。

此外,H-NET由多个单结构网络组合而成,每个单结构网络性能都会影响到H-NET的最终预测结果。为考察H-NET模型诊断效果在组成它的单个单结构模型性能变化时的稳定性,以最高准确度等级(L4)下H-NET诊断准确率(98.53%,见表5)为基准,探究当一个或多个单结构网络模型准确率降低时对应的H-NET准确率的变化,其中每种数量下均设计了三种方案。采用“→”表示由一个准确度等级降至另一个等级,“/”表示对应的单结构网络模型不变,最后所得结果如表6所示。

根据上述结果可以看出:H-NET模型正确率随着组成它的单结构模型准确率降低而降低,但是前者正确率始终大于单结构网络中的最高值;进一步计算可知,对应1~3个单网络正确率降低情况下,单结构网络平均正确率的绝对降低量分别为9.20%、18.40%和20.76%,H-NET则分别为5.20%、7.46%和10.84%,后者分别为前者的56.52%、40.54%和52.21%,由此可见后者的正确率降低幅值远低于前者,因而具有更高的稳定性。

型所得不同类别预测的差异相对各单网络结构模型的平均值分别降低了73.27%、49.76%和82.11%,即显著提高了不同类别预测结果的均衡性。

综上所述,本文构建的H-NET模型不仅可以提高

总体故障预测正确率,还可以降低不同类别预测结果的差异。

表 7 单网络结构和 H-NET 所得不同类别故障诊断正确率的标准差

Tab.7 Standard deviation of the accuracy of different types of fault diagnosis obtained by single-structure network and H-NET

正确率等级	T-NET	F-NET	TF-NET	H-NET
L1	25.37	54.00	32.72	9.99
L2	5.89	43.89	22.33	12.07
L3	7.63	14.69	8.28	1.82

3.3.2 改进前、后集成学习对比

本部分基于 H-NET 构建弱分类器,在此基础上分别应用传统集成可学习和改进后的集成学习算法构建强分类器进行故障诊断,对改进前后集成学习算法得到的强分类器所得故障诊断结果差异进行对比分析。表 8 对比了改进前、后集成学习算法所得强分类器总体预测正确率、平均类别预测差值(ΔA)以及不同类别预测正确率的标准差:

表 8 改进前、后强分类器的正确率、正确率偏差和标准差变化  
Tab.8 Improve the correctness, accuracy bias, and standard deviation variation of the front and back strong classifiers

指标	状态	弱分类器数目				
		1	2	3	4	5
正确率/%	改进前	88.45	97.97	98.05	94.45	95.39
	改进后	89.39	96.04	96.75	96.19	96.81
标准差/%	改进前	12.62	11.48	9.88	11.72	15.09
	改进后	9.25	9.31	9.88	9.53	9.88
ΔA/%	改进前	11.95	7.66	6.23	6.85	17.08
	改进后	5.18	4.27	3.76	3.22	2.09

为了更直观地观察,将表 8 中的总体正确率和标准差,如图 6 所示。




图 6 改进前、后强分类器预测正确率和类别间标准差的变化  
Fig. 6 Improved prediction accuracy and changes in standard deviation between categories by strong pre- and post-classifiers

对比可知:改进后的集成学习算法在提高总体正

确率和降低类别预测差异之间进行了一定的平衡,表现为最终所得强分类器预测类别差异较改进前降低了 81.3%,伴随预测正确率较改进前有小幅降低(改进前、后的最高故障诊断正确率分别为 98.05% 和 96.75%,但均高于组成强分类器的各弱分类器),证明了本文改进方法的有效性;其次可以看出,类别间差异的降低使得强分类器诊断效果随弱分类器数量变化更加稳定,当弱分类器数目由 2 个变化为 5 个过程中,改进前和改进后算法所得强分类器诊断正确率最大变化分别为 3.60% 和 0.71%,即提升了强分类器的稳健性。

此外,将本文述构造的分类器与文献[26]中基于遗传算法和粗糙集理论构建的强分类器所得结果进行对比,其中两者均采用了相同的数据集,对比结果如表 9 所示。

表 9 本文与文献[26]构造的弱分类器及集成强分类器故障诊断结果对比

Tab.9 The comparison of fault diagnosis results of the weak classifier and the integrated strong classifier constructed in Ref. [26] are compared

对比来源	弱分类器 1	弱分类器 2	弱分类器 3	强分类器
文献[26]	81.25	81.25	83.75	88.75
本文	89.39	88.67	91.05	96.75

观察表 9 中结果,两者均证明了强分类器故障诊断效果要优于其包含的单个弱分类器,同时本文构造的具有多域异构输入的 H-NET 弱分类器优于文献中基于遗传算法和粗糙集理论构建的弱分类器,在此基础上建立的强分类器亦如此。在上述基础上,本文结果还与该文献中基于主成分分析的概率神经网络(principal component analysis-probabilistic neural networks, PCA-PNN)和粒子群算法优化的支持向量机(particle swarm optimization-support vector machine, PSO-SVM)两种方法以及文献[27]中基于集成学习和统计特征的 ETC(Extra Tree Classifier)故障诊断方法,在相同数据集下所得故障诊断结果进行了对比,结果如表 10 所示,结果进一步证明了本文方法的优越性。

表 10 本文与文献中故障诊断方法所得结果对比

Tab.10 The comparison of the results obtained by the fault diagnosis methods from Refs

	本文	PCA-PNN	PSO-SVM	文献[27]
正确率/%	96.75	91.25	93.75	95.5

4 结论

本文提出一种具有同源异构输入的复合结构分类器(H-NET)并引入类别权重建立了其训练策略,在此基础上对传统 Adaboost 集成学习算法进行了改进,建立了基于 H-NET 模型的强分类器故障诊断模型,最后



采用试验数据对上述方法进行了验证, 所得结论如下:

(1) 构建了基于多域(时域、频域和时频域)异构输入的 H-NET 模型, 克服了单网络结构模型输入单一、故障信息利用不全面的缺点, 提升了故障诊断的准确性和均衡性。验证结果表明: 三个不同等级下, 采用 H-NET 模型相对单网络结构模型平均正确率分别提升 18.23%、11.99% 和 11.43%, 同时类别间均衡性分别增加了 73.27%、49.76% 和 82.11%;

(2) 针对传统 AdaBoost 集成学习算法无法考虑类别间均衡性的问题, 建立了基于 H-NET 弱分类器的集成强分类器构造方法。验证结果表明: 强分类器预测类别差异较改进前降低了 81.3%, 而预测正确率较改进前仅降低 1.3% (改进前后强分类器故障诊断总体正确率分别 98.05% 和 96.75%, 但均高于组成强分类器的各弱分类器), 证明本文改进的有效性;

(3) 弱分类器类别间诊断差异的降低有利于提升所得强分类器的稳健性, 验证表明, 改进前后强分类器总体诊断正确率随弱分类器数量的最大变化分别为 3.60% 和 0.71%, 即提升了强分类模型的稳健性;

(4) 将本文方法与文献中方法进行对比, 结果表明强分类器故障诊断效果要优于其包含的单个弱分类器, 同时基于相同数量的弱分类器, 本文构造的强分类器总体正确率优于文献中方法所得结果。

#### 参考文献

- [1] ATTOUI I, FERGANI N, BOUTASSETA N, et al. A new time-frequency method for identification and classification of ball bearing faults [J]. *Journal of Sound and Vibration*, 2017, 397:241-265.
- [2] 李军宁, 罗文广, 陈武阁. 面向振动信号的滚动轴承故障诊断算法综述[J]. *西安工业大学学报*, 2022, 42(2):105-122.  
LI Junning, LUO Wenguang, CHEN Wuge. Overview of algorithms for rolling bearing fault diagnosis based on vibration signal[J]. *Journal of Xi'an Technological University*, 2022, 42(2):105-122.
- [3] 陈鹏. 基于振动信号的滚动轴承故障诊断方法综述[J]. *轴承*, 2022, 50(6):21-27.  
CHEN Peng. Review on fault diagnosis methods for rolling bearings based on vibration signals[J]. *Bearing*, 2022, 50(6):21-27.
- [4] 郭艳平, 解武波, 龙涛元, 等. 拟合振动信号模型实现滚动轴承故障诊断[J]. *兰州交通大学学报*, 2017, 36(3):205-208.  
GUO Yanping, XIE Wubo, LONG Taoyuan. Fault diagnosis of rolling bearing by vibration signal model fitting[J]. *Journal of Lanzhou Jiaotong University*, 2017, 36(3):205-208.
- [5] DOLENC B, BOSKOSKI P, JURICIC D. Distributed bearing fault diagnosis based on vibration analysis[J]. *Mechanical Systems and Signal Processing*, 2016, 66/67:521-532.
- [6] PRIETO M D, CIRRINCIONE G, ESPINOSA A G, et al. Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks [J]. *IEEE Transactions on Industrial Electronics*, 2013, 60(8):3398-3407.
- [7] 戴邵武, 陈强强, 丁宇. 基于时域特征的滚动轴承寿命预测[J]. *计算机测量与控制*, 2019, 27(10):60-63.  
DAI Shaowu, CHEN Qiangqiang, DING Yu. Prediction for rolling bearing remaining life based on time domain feature [J]. *Computer Measurement & Control*, 2019, 27(10):60-63.
- [8] 王平, 廖明夫. 滚动轴承故障特征信息的自动提取方法研究[J]. *机械强度*, 2003, 25(6):604-608.  
WANG Ping, LIAO Mingfu. Auto extraction of fault features in rolling element bearing fault diagnosis [J]. *Journal of Mechanical Strength*, 2003, 25(6):604-608.
- [9] 韩业锋, 仲涛, 石磊. 基于包络谱分析的滚动轴承故障诊断分析[J]. *机械研究与应用*, 2010, 23(4):118-119.  
HAN Yefeng, ZHONG Tao, SHI Lei. Rolling element bearing fault diagnosis based on envelope analysis [J]. *Mechanical Research & Application*, 2003, 25(6):604-608.
- [10] YANG B S, WIDODO A. Introduction of intelligent machine fault diagnosis and prognosis [M]. Hauppauge, NY: Nova Science Publishers, 2009.
- [11] LERCH A. An introduction to audio content analysis: application in signal processing and music informatics [M]. New Jersey: Wiley-IEEE Press, 2012.
- [12] ZHONG D W, GUO W, HE D. An intelligent fault diagnosis method based on STFT and convolutional neural network for bearings under variable working conditions [C] // 2019 Prognostics and System Health Management Conference. Qingdao: PHM, 2019.
- [13] ZHOU S, XIAO M H, BARTONS P, et al. Remaining useful life prediction and fault diagnosis of rolling bearings based on short-time fourier transform and convolutional neural network [J]. *Shock and Vibration*, 2020, 2020(8857307):1-14.
- [14] 朱军. 滚动轴承非平稳信号故障诊断若干方法研究[D]. 合肥: 中国科学技术大学, 2016.
- [15] 陈刚, 廖明夫. 基于小波分析的滚动轴承故障诊断研究[J]. *科学技术与工程*, 2007, 7(12):2810-2814.  
CHEN Gang, LIAO Mingfu. Fault diagnosis for a rolling element bearing based on wavelet analysis [J]. *Science Technology and Engineering*, 2007, 7(12):2810-2814.
- [16] ZHANG J, YAN R, GAO R X, et al. Performance enhancement of ensemble empirical mode decomposition [J]. *Mechanical Systems and Signal Processing*, 2010, 24(7):2104-2123.
- [17] SHEN F, CHEN C, YAN R, et al. Bearing fault diagnosis based on SVD feature extraction and transfer learning classification [C] // Prognostics and System Health Management Conference. Chengdu: PHM, 2016.
- [18] LU W, WANG X, YANG C, et al. A novel feature extraction method using deep neural network for rolling bearing fault diagnosis [C] // The 27 th Chinese Control and Decision Conference. Qingdao: CCDC, 2015.
- [19] ZHAO L, WANG X. A deep feature optimization fusion method for extracting bearing degradation features [J]. *IEEE Access*, 2018:19640-19653.

(下转第 248 页)

提方法的有效性。试验结果表明:

(1) 设计的基于 JS 相对熵的构图方法对 GNN 模型性能的提升具有普适性和鲁棒性

(2) 构造的基于 E-DGAT 的半监督学习模型具有更强的故障特征提取能力。

(3) 与其他 GNN 相比,所提方法具有更高的故障诊断精度和稳定性。

#### 参考文献

- [1] 邵海东,张笑阳,程军圣,等. 基于提升深度迁移自动编码器的轴承智能故障诊断[J]. 机械工程学报,2020,56(9): 84-90.  
SHAO Haidong, ZHANG Xiaoyang, CHENG Junsheng, et al. Intelligent fault diagnosis of bearing using enhanced deep transfer auto-encoder[J]. Journal of Mechanical Engineering, 2020,56(9): 84-90.
- [2] 文成林,吕菲亚. 基于深度学习的故障诊断方法综述[J]. 电子与信息学报,2020,42(1): 234-248  
WEN Chenglin, LÜ Feiya. Review on deep learning based fault diagnosis [J]. Journal of Electronics and Information Technology, 2020, 42(1): 234-248.
- [3] ZHAO R, YAN R Q, CHEN Z H, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.
- [4] RAZAVI-FAR R, HALLAJI E, FARAJZADEH-ZANJANI M, et al. A semi-supervised diagnostic framework based on the surface estimation of faulty distributions [J]. IEEE Transactions on Industrial Informatics, 2019, 15 (3): 1277-1286.
- [5] 邢晓松,郭伟. 基于改进半监督生成对抗网络的少量标签轴承智能诊断方法[J]. 振动与冲击,2022,41(22): 184-192.  
XING Xiaosong, GUO Wei. Intelligent diagnosis method for bearings with few labelled samples based on an improved semi-supervised learning-based generative adversarial network [J]. Journal of Vibration and Shock, 2022, 41 (22): 184-192.
- [6] ZHANG Y C, YU K, LEI Z H, et al. Integrated intelligent fault diagnosis approach of offshore wind turbine bearing based on information stream fusion and semi-supervised learning [J]. Expert Systems with Applications, 2023, 232: 1-15.
- [7] LIAO W L, BAK-JENSEN B, PILLA J R, et al. A review of graph neural networks and their applications in power systems [J]. Journal of Modern Power Systems and Clean Energy, 2022,10(2): 345-360.
- [8] 王博. 基于半监督图卷积的行星齿轮箱故障诊断方法研究[D]. 哈尔滨:哈尔滨理工大学,2022.
- [9] KAVIANPOUR M, RAMEZANI A, BEHESHTI M T H. A class alignment method based on graph convolution neural network for bearing fault diagnosis in presence of missing data and changing working conditions [J]. Measurement, 2022, 199: 111536.
- [10] XIE Z L, CHEN J L, FENG Y, et al. Semi-supervised multi-scale attention-aware graph convolution network for intelligent fault diagnosis of machine under extremely-limited labeled samples [J]. Journal of Manufacturing Systems, 2022, 64: 561-577.
- [11] YAN S, SHAO H D, XIAO Y M, et al. Semi-supervised fault diagnosis of machinery using LPS-DGAT under speed fluctuation and extremely low labeled rates [J]. Advanced Engineering Informatics, 2022, 53: 1-12.
- [12] 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: 1-37.
- [13] YANG L C, BI S F, FAES M G R, et al. Bayesian inversion for imprecise probabilistic models using a novel entropy-based uncertainty quantification metric [J]. Mechanical Systems and Signal Processing, 2022, 162: 1-21.
- [14] HUANG H, BADDOUR N, LIANG M. Bearing vibration data collected under time-varying rotational speed conditions [J]. Data in Brief, 2018,21: 1745-1749.
- [15] ZHANG H Q, LU G Q, ZHAN M M, et al. Semi-supervised classification of graph convolutional networks with Laplacian rank constraints [J]. Neural Processing Letters, 2021, 54 (4): 2645-2656.
- [16] HAMILTON W, YING Z, LESKOVEC. Inductive representation learning on large graphs [J]. Advances in neural information processing systems, 2017,30: 1025-1035.
- [17] 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.
- [18] XU G, LIU M, JIANG Z, et al. Bearing fault diagnosis method based on deep convolutional neural network and random forest ensemble learning[J]. Sensors, 2019, 19(5): 1088.
- [19] 陈法法,杨晶晶,肖文荣,等. Adaboost-SVM 集成模型的滚动轴承早期故障诊断[J]. 机械科学与技术, 2018, 37 (2): 237-243.  
CHEN Fafa, YANG Jingjing, XIAO Wenrong. Adaboost-SVM integrated model for early fault diagnosis of rolling bearings [J]. Mechanical Science and Technology, 2018, 37 (2): 237-243.
- [20] LI H, ZHENG H. Bearing fault detection using envelope spectrum based on EMD and TKEO [C] // International Conference on Fuzzy Systems and Knowledge Discovery. Shandong: IEEE, 2008:142-146.
- [21] WANG X, LI Y, RUI T, et al. Bearing fault diagnosis method based on Hilbert envelope spectrum and deep belief network[J]. Journal of Vibro Engineering, 2015, 17(3): 1295-1308.
- [22] GONG X Y, HAN J, CHEN H, et al. A bearing fault diagnosis using wavelet envelope spectrum based on full vector spectrum technology [J]. Applied Mechanics and Materials, 2012, 190/191:873-879.
- [23] WADE A S, ROBERT B R. Rolling element bearing diagnostics using the Case Western Reserve University data: a benchmark study [J]. Mechanical Systems and Signal Processing. 2015, 64/65:100-131.
- [24] DOU D Y, JIANG J, WANG Y L, et al. A rule-based classifier ensemble for fault diagnosis of rotating machinery [J]. Journal of Mechanical Science and Technology, 2018, 32(6):2509-2515.
- [25] GANGAVVA, MANGAI J A, MOHIT B. An investigation of ensemble learning algorithms for fault diagnosis of roller bearing [J]. Computer Science, 2022(2022): 117-125.

(上接第 182 页)