

DOI: 10.19650/j.cnki.cjsi.J2311647

基于小波核扩散与双阶段 SVM 的轴承复合故障分类方法^{*}

陈赛赛¹, 杨晨曦¹, 陈超¹, 贺长波², 樊薇^{1,3}

(1. 江苏大学机械工程学院 镇江 212013; 2. 安徽大学电气工程与自动化学院 合肥 230601;
3. 上海交通大学机械与动力工程学院 上海 200240)

摘要: 轴承复合故障分类中存在故障特征强线性不可分及故障数据标签不足问题,严重影响分类精度。为此,提出基于双阶段支持向量机(SVM)与小波核扩散的轴承复合故障分类方法。针对故障特征强线性不可分,使用小波核函数对其进行高维空间映射,并利用极大重叠离散小波包变换获取信号在不同频带上的能量分布作为故障特征;针对故障数据标签不足,提出增量式核空间标签扩散的双阶段 SVM 分类模型,在小波核空间核差异距离基础上,利用增量式核空间标签扩散对训练样本的近邻样本、粗分阶段边界样本进行扩充,并在细分阶段依据扩充后的样本完成模型训练。3组轴承复合故障数据验证了所提方法的有效性,实验研究表明,在单类训练样本为5的条件下,所提方法比 SVM 分类准确率平均提升7.5%,并优于其他流行算法。

关键词: 轴承复合故障分类; TWD-SVM; 增量式核空间标签扩散; 核差异距离; 半监督学习

中图分类号: TH133.3 **文献标识码:** A **国家标准学科分类代码:** 460.40

Bearing compound fault classification method based on wavelet kernel diffusion and two-stage SVM

Chen Saisai¹, Yang Chenxi¹, Chen Chao¹, He Changbo², Fan Wei^{1,3}

(1. School of Mechanical Engineering, Jiangsu University, Zhenjiang 212013, China; 2. School of Electric Engineering and Automation, Anhui University, Hefei 230601, China; 3. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: The problems of strong linear indistinguishability of different fault features and insufficient labeling of fault data exist in bearing compound fault classification, which seriously affect the classification accuracy. This paper proposes a semi-supervised compound fault classification method based on the two-stage SVM with wavelet kernel diffusion. To address the strong linear inseparability of fault features, the wavelet kernel function is used to transform them in high-dimensional space, and the maximal overlap discrete wavelet packet transform is applied to obtain the energy distribution of the signal in different frequency bands as the fault features. Aiming at the insufficiency of the fault data labeling, a two-stage SVM classification model with incremental kernel space label diffusion is proposed. Based on the kernel difference distance in the wavelet kernel space, we expand the neighboring samples and boundary samples in the coarse partition stage using incremental kernel space label diffusion, and the training of models is completed based on expanded samples at the segmentation phase. Three sets of bearing composite fault data validate the effectiveness of the proposed method, and the experimental study shows that under the condition of a single class of training samples of 5, the proposed method improves the classification accuracy by 7.5% on average than SVM, and outperforms other popular algorithms.

Keywords: bearing compound fault classifications; TWD-SVM; incremental kernel space label diffusion; kernel difference distance; semi-supervised learning

收稿日期: 2023-07-08 Received Date: 2023-07-08

^{*} 基金项目: 国家自然科学基金青年项目(52305109)、机械系统与振动国家重点实验室课题(MSV 202311)、中国博士后科学基金(2023M732218)、省部共建现代农业装备与技术协同创新中心(XTCX2021)、安徽省自然科学基金青年项目(2108085QE229)、江苏省自然科学基金青年项目(BK20210772)资助

0 引言

轴承作为旋转机械设备的关节,广泛应用于航空发动机、高铁列车、风力发电机、海洋工程等大型旋转设备。实际生产过程中,受复杂工况影响,轴承易产生复合故障^[1],时域上表征为不同故障信号存在因传递路径导致的能量衰减,频域上表征为频率成分混叠、区分能力降低。因而,实现滚动轴承复合故障准确分类,对旋转机械系统故障诊断具有重要意义。

近年来,以大数据为背景的深度学习方法在机械故障诊断领域取得了令人瞩目的成就,然而实际工况下故障样本数据量缺乏,使得模型预测效果受限^[2-3]。实现少样本滚动轴承复合故障分类的关键在于解决故障标签不足^[4-6],以及不同故障特征难以区分的问题。

针对故障标签不足,常采用无标签数据对原有小样本数据集进行扩充^[7],其中以样本间距离作为度量扩充训练样本为常见方式之一。张振良等^[8]提出基于迁移学习的半监督集成学习器,以欧氏距离为基础扩展源样本空间,构成半监督学习机完成故障识别。Yu等^[9]通过扩大有限标记样本数据的特征分布裕度,并利用K-means获取有限标记样本的聚类中心,通过聚类中心与未标记样本的特征分布之间的差异实现故障模式识别。陶新民等^[10]采用密度峰值聚类生成聚类伪标签的样本扩充方法,通过增加规范化项以及局部Fisher判别分析算法获得最佳投影向量,实现单一故障分类准确率95.75%,但上述样本扩充方式依赖于样本特征间的聚类效果。为此,部分学者从特征增强角度出发解决此类问题,邢晓松等^[11]提出增强特征匹配算法结合半监督学习提升分类器学习能力,实现单一故障分类准确率92%。Feng等^[12]基于相似度元学习计算各类质心与特征空间中查询点间的相似度来完成分类。然而,轴承复合故障振动特征相似程度大,在特征增强的基础上,直接以欧氏距离,皮尔逊相关系数或基于其他距离度量的聚类方法^[13],仍不足以分析样本特征间的聚类关系。因此,基于低维空间的距离表达易造成聚类效果不佳,需探究高维空间下的距离表达。

针对特征相似度大难以区分,支持向量机(support vector machine, SVM)^[14]将输入数据映射到高维可分空间并分类识别,提供了一种有效分类方式。然而,SVM分类效果依赖核函数,可通过构造具有系数可变的核函数^[15]提高其逼近精度和范化能力。Dong等^[16]证明了墨西哥草帽小波函数具备平移不变性,并将其作为SVM核函数,验证了其在分类准确率上明显高于高斯核函数。王宏超等^[17]验证了小波核主元分析的聚类效果明显优

于高斯核函数。因此,使用小波核函数是有效解决特征强线性不可分的途径之一。

因此,针对轴承复合故障分类中存在的上述问题,本文提出一种基于双阶段小波核扩散支持向量机(two-stage wavelet kernel diffusion-SVM, TWD-SVM)的半监督轴承复合故障分类方法。首先,利用极大重叠离散小波包变换(maximal overlap discrete wavelet packet transform, MODWPT)分解并获得振动信号对应小波包系数的能量特征作为故障特征;其次,针对故障特征强线性不可分,提出小波核空间的核差异距离扩充训练集样本数;最后,使用粗-细双阶段SVM提高模型的分类准确率,粗分阶段在扩充样本的基础上利用惩罚参数的不同获取边界样本,并依据核差异距离最小的原则获得边界样本伪标签。细分阶段利用扩充样本以及边界样本使用一对一编码SVM完成模型训练。滚动轴承复合故障数据实验及对比分析验证了所提方法的有效性及优越性。

1 SVM分类原理介绍

1.1 SVM

SVM通过寻找线性可分条件下的最优超平面实现分类。给定样本集 $S = \{(\mathbf{x}_i, y_i)_{i=1}^N \mid \mathbf{x}_i \in R^p, y_i \in \{+1, -1\}\}$,其中, N 为样本点个数, p 为 $\mathbf{x}_i$ 的维数, y_i 表示样本 $\mathbf{x}_i$ 所属的类别。若超平面方程 $\mathbf{w} \cdot \mathbf{x}_i + b = 0$ 可准确区分两类样本,且间隔最大,则该方程参数求解问题可表示为:

$$\begin{aligned} \min & \frac{1}{2} \mathbf{w}^2 + C \sum_{i=1}^N \xi_i \quad i = 1, 2, \dots, N \\ \text{s. t.} & \begin{cases} y_i(\mathbf{w} \cdot \mathbf{x}_i + b) > 1 - \xi_i \\ C \geq 0, \quad \xi_i \geq 0 \end{cases} \end{aligned} \quad (1)$$

式中: $\mathbf{w}$ 为权重向量; b 为偏置量; ξ_i 为松弛因子; C 为惩罚因子。使用拉格朗日函数构造求解^[15]并根据Kuhn-Tucker-Tucker定理,式(1)可转化成:

$$\begin{aligned} \max_{\alpha} & \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j \alpha_i \alpha_j < \mathbf{x}_i, \mathbf{x}_j > \\ \text{s. t.} & \sum_{i=1}^N \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C \end{aligned} \quad (2)$$

式中: α_j 是拉格朗日乘子, $< \mathbf{x}_i, \mathbf{x}_j >$ 为 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 的内积。其中,少数 $\alpha_i > 0$ 对应的样本即为支持向量 $\mathbf{x}_i$,并使用 $\mathbf{w}$ 即可计算偏置量 b ,对于给定的未知样本 $\mathbf{x}$ 只需计算:

$$f(x) = \text{sign}[(\mathbf{w} \cdot \mathbf{x}) + b] \quad (3)$$

式中: $\text{sign}[\cdot]$ 为符号函数。

1.2 核函数与小波核函数

对于非线性分类,通过核函数 $K(\mathbf{x}_i \cdot \mathbf{x}_j)$ 可实现数据从低维线性不可分到高维线性可分的映射,然后在高维

空间中求解最优分类面。因此,式(2)和(3)可改写为:

$$\begin{cases} \max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^j \sum_{j=1}^N y_i y_j \alpha_i \alpha_j K(\mathbf{x}_i \cdot \mathbf{x}_j) \\ \text{s. t.} \sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \end{cases} \quad (4)$$

$$f(\mathbf{x}) = \text{sign} \left[\sum_{i,j=1}^N y_i \alpha_j K(\mathbf{x}_i \cdot \mathbf{x}_j) + b \right] \quad (5)$$

本文选用满足平移不变性的墨西哥草帽小波核函数^[16,18]:

$$K(\mathbf{x}_i \cdot \mathbf{x}_j) = \prod_{i,j=1}^d \left[1 - \frac{(\mathbf{x}_i - \mathbf{x}_j)^2}{a_i^2} \right] \exp \left[-\frac{(\mathbf{x}_i - \mathbf{x}_j)^2}{2a_i^2} \right] \quad (6)$$

式中: a_i 为小波尺度参数, $a_i > 0$ 。

2 双阶段小波核扩散 SVM 轴承复合故障分类

针对轴承复合故障中故障标签数据不足以及特征强线性不可分问题,提出一种 TWD-SVN 的半监督轴承复合故障分类方法,其整体流程如图 1 所示,包含特征提取、标签扩散、类别粗分和细分 4 部分。




图 1 TWD-SVM 流程

Fig. 1 TWD-SVM process

2.1 时频特征提取

针对滚动轴承复合故障振动信号的时频特征易混叠、区分能力弱的问题,采用 MODWPT 获取时间序列 $\mathbf{S}_t$ 在不同频带上的能量分布作为故障特征。设置初始

$\mathbf{W}_{0,0} = \mathbf{S}_t$, 第 j 层小波包系数为:

$$\mathbf{W}_{j,n,t} = \sum_{l=0}^{L_j-1} \mathbf{r}_{j,n,l} \mathbf{W}_{j-1,n/2,(t-2^{j-1}l) \bmod N} \quad (7)$$

$$\mathbf{r}_{j,n,l} = \begin{cases} \tilde{\mathbf{g}}_{j,l}, & n \bmod 4 = 0 \text{ or } 3; \\ \tilde{\mathbf{h}}_{j,l}, & n \bmod 4 = 1 \text{ or } 2; \end{cases} \quad (8)$$

式中: $\{\tilde{\mathbf{g}}_{j,l}\}_{l=0}^{L_j-1}$ 和 $\{\tilde{\mathbf{h}}_{j,l}\}_{l=0}^{L_j-1}$ 分别是第 j 层的尺度滤波器和 小波滤波器,滤波器的宽度为 $L_j = (2^j - 1)(L_1 - 1) + 1$, L_1 为初始小波长度, $n = 0, \dots, 2^j - 1$ 。

由式(7)可得每一层的 2^j 个小波包系数,因此各分解层的故障信号特征为:

$$\mathbf{E}(n) = \frac{\sum_{i=1}^N \mathbf{W}_{j,n,i}^2}{N} \quad (9)$$

式中: N 表示样本点个数; j 表示小波分解层数; $n = 1, \dots, 2^j$ 表示特征长度。

2.2 增量式核空间标签扩散

针对故障特征线性不可分,本文结合小波核并提出增量式核空间标签扩散,步骤如下:

1) 对已知标签样本 $\mathbf{x}_r \in R^p$ 依据式(6) $\mathbf{X}_{r,r} = K(\mathbf{x}_r, \mathbf{x}_r)$ 进行高维映射获得已知样本的高维核矩阵,由式(6)可知, $\mathbf{X}_{r,r}$ 为对称阵,且对角线上的值为 1, r 表示训练集大小, p 表示样本维度。

2) 对测试集数据 $\mathbf{x}_N^*$ 与训练集 $\mathbf{x}_{r+m}$ 进行核空间映射,获得 N 个核向量 $\mathbf{X}_{(r+m),i}^*, i = 1, 2, \dots, N$ 并计算与训练集核矩阵 $\mathbf{X}_{(r+m),(r+m)}$ 每一行的欧氏距离,取距离最小值为核差异距离 Kd_i ,取 Kd_i 中最小值对应的 $\mathbf{X}_{(r+m),o}^*$ 作为扩充核向量, $\mathbf{X}_{(r+m),1}^*$ 与 $\mathbf{X}_{(r+m),(r+m)}$ 的核差异距离为:

$$Kd = \min \{ \|\mathbf{X}_{(r+m),1}^* - \mathbf{X}_{(r+m),z}\|_2 \} \quad (10)$$

式中: $z = 1, 2, \dots, r+m$, r 为初始训练集样本大小, m 表示迭代次数。

3) 对核向量 $\mathbf{X}_{(r+m),o}^*$ 进行核矩阵扩充,若取原核矩阵为 $\mathbf{X}_{(r+m),(r+m)}$ 则新核矩阵为:

$$\mathbf{X}_{(r+m+1),(r+m+1)} = \begin{bmatrix} \mathbf{X}_{(r+m),(r+m)} & (\mathbf{X}_{(r+m),o}^*)^T \\ \mathbf{X}_{(r+m),o}^* & 1 \end{bmatrix} \quad (11)$$

4) 依据设定扩散样本个数 U ,重复 1) ~ 3),获得扩散样本序列以及扩散后的核矩阵。在设定已知标签样本 $\mathbf{x}_r \in R^p$,未知样本 $\mathbf{x}_N^* \in R^p$,样本维度 $p = 3$,迭代次数为 U 时,增量式核空间标签扩散法如图 2 所示。

2.3 双阶段 SVM 决策模型

增量式核空间标签扩散难以扩展各类边界样本,影响分类准确率。为此,提出 TWD-SVM 复合故障分类方法,包含粗分-细分两阶段,流程如图 3 所示。

1) 粗分阶段

在一对多编码方式下,对单类已知样本进行增量式核空间标签扩散,在低惩罚参数 SVM 下获得测试集初始




图2 增量式核空间标签扩散法

Fig. 2 Incremental kernel space label diffusion method




图3 TWD-SVM 算法流程

Fig. 3 TWD-SVM algorithm flow

预测标签,并将获得的预测结果在高惩罚参数下进行再分类,通过比较两次预测得分获得其边界样本。以 G 类故障类别为例对其中一类进行标签扩散并作为类别1,其余作为类别2。用扩散后的样本数据在低惩罚参数 C_1 下完成测试集标签预测,获得预测标签 $\hat{Y}$,得分 $Y1.s$ 为:

$$Y1.s = \sum_{i,j=1}^N y_i \alpha_i K(x_i^* \cdot x_j^*) + b \quad (12)$$

式中: α_i 是拉格朗日乘子; b 为偏置量。将预测标签 $\hat{Y}$ 与测试集作为 SVM 的训练集,在高惩罚参数 C_2 下对自身进行预测并获得 $Y2.s$,取预测结果差值最大的前 b 个样本作为第1个分类器的边界样本,最终获得 $b \times G$ 个边界样本。最后以边界样本与各类扩散样本之间核差异距离最小的原则赋予边界样本伪标签。

2) 细分阶段

在一对一编码方式下,使用扩散样本以及粗分阶段边界样本,在中惩罚参数 C_3 下预测测试集标签,在 G 类故障下获得 $G(G-1)/2$ 组预测结果,通过多类投票获得最终预测结果。

3 实验验证

3.1 实验数据描述

采用两组实验台验证所提方法的有效性,实验对象1为深沟球轴承 SKF 6205,设置外圈故障、内圈故障、滚

动体故障、内圈外圈故障、内圈滚子故障、外圈滚子故障以及正常状态的轴承7类运行状态。实验台1如图4所示,实验参数如表1所示。




图4 实验台1:轴承故障实验台

Fig. 4 Test rig 1: Faulty bearing test rig

表1 实验台1:深沟球轴承 SKF 6205 工作参数

Table 1 Test rig 1: Deep groove ball bearings SKF 6205 operating parameters

实验轴承参数	数值	实验轴承参数	数值
外圈直径/mm	52	内圈直径/mm	25
接触角/(°)	0	滚子直径/mm	7.938
滚子个数	9	转速/(r·min ⁻¹)	500
外部负载/kN	4.5	采样频率/kHz	51.2

A 组故障特征向量计算过程为使用5层 MODWPT 分解并获得对应小波包系数的峭度值。

实验对象2为圆锥滚子轴承 FGA 30206,设置外圈故障、内圈故障、滚动体故障、内圈外圈故障、内圈滚子故障、外圈滚子故障以及正常状态7类运行状态。实验台2如图5所示^[3],实验参数如表2所示。

实验台2的B组,其故障特征向量采用传统14个时域特征。实验台2的C组,其故障特征向量计算过程为使用5层 MODWPT 分解并获得对应小波包系数的能量。

3 组数据如表 3 所示,3 组均获得 1 400 个特征向量,700 为待选取训练集,700 为测试集。




图 5 实验台 2:轴承齿轮故障试验台

Fig. 5 Test rig 2: Bearing gear fault test rig

表 2 实验台 2:圆锥滚子轴承 FGA 30206 工作参数

Table 2 Test rig 2: Tapered roller bearings FGA 30206 operating parameters

实验轴承参数	数值	实验轴承参数	数值
外圈直径/mm	62	内圈直径	30
接触角/(°)	14.036	滚子直径/mm	7.92
滚子个数	17	转速/(r·min ⁻¹)	1 477.2
外部负载/kN	0	采样频率/kHz	51.2

表 3 三组实验数据说明

Table 3 Three sets of experimental data illustrate

组别	特征类型	数据来源	轴承状态
A	MODWPT+峭度	图 4 实验台	7 类故障
B	14 时域指标	图 5 实验台	7 类故障
C	MODWPT+均方根	图 5 实验台	7 类故障

3.2 故障特征提取及其性能分析

使用时频分析方法 MODWPT 与时域特征能量相结合的方法实现轴承信号的特征提取。C 组单一故障特征如图 6 所示,其中 N1、O1、I1、R1 分别表示各样本 1 在正常运行状态、外圈故障状态、内圈故障和滚动体故障状态下的均方根时频特征值。

进一步对所提特征进行类内、类间间距定量描述,对实验台 2 采集数据进行特征提取,包含传统 14 个时域特征、以及经过 5 层 MODWPT 分解并获得对应小波包系数的峭度、波形因子、能量特征的各 700 数据进行比较分析。样本特征为 $\mathbf{x}_i \in R^p, i = 1, 2, \dots, N, N$ 为每类样本个数,每类样本的特征均值为 $\mathbf{M}_{r,p}, r = 1, 2, \dots, G, G$ 为故障类别个数,则类内距离 d_{in} 为:

$$d_{in}(r) = \frac{1}{N} \sum_{i=1}^N \sqrt{\sum_{e=1}^p (\mathbf{x}_{i,e} - \mathbf{M}_{r,e})^2}$$

(13)




图 6 C 组实验数据能量特征分布结果

Fig. 6 Distribution of energy characteristics in experimental data of Group C

类间距离 d_o 为:

$$d_o(r) = \frac{1}{G-1} \sum_{r=1, r \neq r}^G \sqrt{\sum_{e=1}^p (\mathbf{M}_{r,e} - \mathbf{M}_{r',e})^2}$$

(14)

实验台 2 采集轴承信号在 4 类特征下的类内、类间间距。从图 7 可以看出 5 层 MODWPT 分解并获得对应小波包系数的能量特征具有最高的类内间距以及较小的类内间距,因此其可以作为轴承信号特征用于故障分类算法,实验结果表明所提特征向量优于其他特征。




图 7 4 类特征类内、类间间距

Fig. 7 Intra-class and inter-class spacing of the four types of features

3.3 核差异距离分类及增量式核空间扩散

欧氏距离、曼哈顿距离等方法用于描述两个向量之间的相似程度,并广泛应用于机器学习领域,针对故障数

据标签不足的轴承复合故障数据进行扩充时,使用欧氏距离等会存在如下问题。

1) 距离为一对一样本相似度衡量,难以有效评价单一样本与一类样本相似度。

2) 低维空间样本特征出现线性不可分时,扩充准确率无法保证。

设单一样本向量为 $\mathbf{x} \in R^p$, 一类样本向量为 $\mathbf{Y}_i \in R^p$, 其中 $i = 1, 2, \dots, N$, N 为样本个数, 那么核差异距离计算公式为:

$$Kd = \min \{ \| K(\mathbf{x}, \mathbf{Y}) - K(\mathbf{Y}, \mathbf{Y})_i \|_2 \} \quad i = 1, 2, \dots, N$$

(15)

式中: $K(\mathbf{x}, \mathbf{Y})$ 表示小波核函数, 计算过程如式(6)所示; $K(\mathbf{Y}, \mathbf{Y})_i$ 表示核矩阵第 i 列。

为进一步验证核差异距离的有效性, 基于 B 组数据不同训练集样本分别构建以核差异距离 K , 欧氏距离 E , 皮尔逊系数 P , 曼哈顿距离 M , 余弦距离 C 为基础的分类模型, 对 700 组未知样本的 10 次分类准确度的均值如图 8 所示。由图 8 可知, 所提核差异距离优于其他距离, 并且伴随训练样本个数增加, 准确率有明显提升。

为验证增量式核扩散方法的有效性, 对 C 组轴承复合故障特征经主成分分析 (principal component analysis, PCA) 降维后取二维数据进行可视化分析, 结果如图 9 所示。扩散准确率如表 4 所示。图 9 中 TD、BN、BO、BI、BR、BIO、BIR、BOR 依次表示测试集数据、轴承正常状态、外圈故障、内圈故障、滚动体故障、内圈外圈故障、内圈滚动体故障、外圈滚动体故障。C 组中单类训练集为 5, 测试集为 100 如图 9(a) 所示, 图 9(b) 为增量式




图 8 不同距离分类结果

Fig. 8 Classification results for different distances

核扩散中当 $U=20$ 时扩散后的标签, 图 9(c) 为增量式核扩散中当 $U=40$ 时扩散后的标签, 其中灰色代表未知标签。

表 4 增量式核扩散准确率

Table 4 Incremental kernel diffusion accuracy

数据维度	样本	数据	扩散个数	准确率/%
2	5	峭度 A 组	20	100
2	5	峭度 A 组	40	100
2	5	时域 B 组	20	98.57
2	5	时域 B 组	40	93.21
2	5	均方根 C 组	20	100
2	5	均方根 C 组	40	100




图 9 增量式核扩散结果

Fig. 9 Incremental kernel diffusion results

3.4 轴承复合故障分类结果及对比分析

分别使用本文所提 TWD-SVM 算法、SVM^[19]、以及增加标签扩散的 SSVM 即 TWD-SVM 中不包含粗分阶段扩充的边界样本, 以不同样本、核函数对 3 组轴承复合故障

特征数据进行验证。取惩罚参数 $C = 200$, 扩充样本大小 $U = 10$, 单类测试集样本数为 100, 共 700 组。对 A 组数据的分类结果如表 5 所示, 对 B 组数据的分类结果如表 6 所示。

表 5 A 组数据分类结果

Table 5 Data classification results for Group A

测试集	方法	核函数	核参数	准确率/%
35	SVM	高斯核	5 000	89.42
70	SVM	高斯核	5 000	96.10
35	SSVM	小波核	500	94.00
70	SSVM	小波核	500	97.57
35	TWD-SVM	小波核	500	98.70
70	TWD-SVM	小波核	500	98.90

表 6 B 组数据分类结果

Table 6 Data classification results for Group B

测试集	方法	核函数	核参数	准确率/%
35	SVM	高斯核	1	87.70
70	SVM	高斯核	1	91.70
35	SSVM	小波核	1	89.00
70	SSVM	小波核	1	93.20
35	TWD-SVM	小波核	1	94.10
70	TWD-SVM	小波核	1	96.30

由表 5 和 6 可知,在少样本条件时使用增量式核空间标签扩散效果明显优于同阶段 SVM,但由于扩充样本的核心是依据样本在核空间的核差异距离,扩展的是训练集近邻样本,导致其准确率不会出现跨越式提升;使用 TWD-SVM 分类效果较 SVM 有明显提升。10 训练样本 A 组、10 训练样本 B 组和 5 训练样本 C 组数据的 TWD-SVM 分类结果如图 10~12 所示,结果表明 TWD-SVM 对 C 组分类准确率达到 100%。

轴承故障分类结果




图 10 10 训练样本 A 组 TWD-SVM 分类结果

Fig. 10 TWD-SVM classification results of Group A of 10 training samples

轴承故障分类结果




图 11 10 训练样本 B 组 TWD-SVM 分类结果

Fig. 11 TWD-SVM classification results of Group B of 10 training samples

轴承故障分类结果




图 12 5 训练样本 C 组 TWD-SVM 分类结果

Fig. 12 TWD-SVM classification results of Group C of 5 training samples

采用所提出方法和传统智能诊断方法对 B 组实验数据进行处理,得到的故障分类结果如表 7 所示。其中,对图 5 实验台 2 的振动信号数据以 2 500 个采集点作为单一样本,共 1 400 组数据,取部分样本如表 6 所示,作为 1D-CNN 模型数据输入。核心参数中,RBF 表示高斯核函数、G 表示核参数、Ns 表示隐藏神经元的数量、lr 表示初始学习率,1D-CNN 迭代次数为 200,使用 Adam 优化器、ksvd_iter 为字典迭代次数,字典大小与训练集样本个数一致、WK 表示小波核函数。由表 7 可知,在 35 训练

样本以及 10 次重复实验的条件下,所提算法与原有的 SVM 分类算法相比故障识别精度平均提升 5.73%且优于其他传统智能诊断方法算法。对于 C 组数据,使用 SVM、ELM、TWD-SVM 方法在 35 训练样本下均能达到 100%准确率,表明所提特征能够解决轴承复合故障线性不可分问题,极大提高分类准确精度。

表 7 B 组数据各类算法比较
Table 7 Comparison of various algorithms in Group B data

分类算法	训练集	测试集	核心参数	BN	BO	BI	BR	BIO	BIR	BOR	平均准确率	标准差
SVM ^[19]	35	700	RBF $G = 1$	0.779	0.988	0.790	0.898	0.760	0.964	0.996	0.882 1	0.020 0
	70	700	RBF $G = 1$	0.897	0.988	0.804	0.925	0.824	0.986	1.000	0.917 7	0.016 4
	175	700	RBF $G = 1$	0.979	0.999	0.888	0.966	0.890	0.994	1.000	0.959 4	0.007 1
	350	700	RBF $G = 1$	0.999	1.000	0.936	0.993	0.940	0.992	1.000	0.980 0	0.006 9
ELM ^[20]	35	700	$N_s = 20$	0.971	0.978	0.994	0.720	0.935	0.976	0.524	0.871 1	0.028 7
	70	700	$N_s = 20$	0.979	0.999	0.999	0.824	0.939	0.990	0.797	0.932 4	0.014 2
	175	700	$N_s = 20$	0.996	0.998	0.999	0.939	0.987	0.949	0.932	0.971 3	0.010 0
	350	700	$N_s = 20$	0.998	0.999	0.999	0.955	0.978	0.960	0.946	0.976 4	0.006 0
1D-CNN	35	700	Adam $lr = 0.000\ 1$	0.892	0.995	0.883	0.311	0.764	1.000	0.496	0.763 0	0.003 9
	70	700	Adam $lr = 0.000\ 1$	0.980	0.999	0.998	0.784	0.957	0.984	0.764	0.923 7	0.021 3
	175	700	Adam $lr = 0.000\ 1$	0.988	1.000	0.998	0.857	0.966	0.990	0.841	0.948 6	0.009 3
	350	700	Adam $lr = 0.000\ 1$	0.994	1.000	0.998	0.937	0.988	0.995	0.937	0.978 4	0.008 2
KSVD ^[21]	35	700	$k_{svd_iter} = 20$	0.597	0.925	0.982	0.665	0.849	0.901	1.000	0.845 6	0.007 9
	70	700	$k_{svd_iter} = 20$	0.792	0.982	0.848	0.794	0.950	0.942	1.000	0.901 1	0.008 4
	175	700	$k_{svd_iter} = 20$	0.987	0.924	0.969	0.866	0.991	0.918	1.000	0.950 7	0.008 1
	350	700	$k_{svd_iter} = 20$	0.984	0.948	0.971	0.990	0.993	0.990	1.000	0.982 3	0.001 2
TWD-SVM	35	700	WK $G = 1$	0.958	0.983	0.839	0.935	0.906	0.955	1.000	0.939 4	0.017 3
	70	700	WK $G = 1$	0.967	0.996	0.900	0.933	0.909	0.993	0.998	0.956 6	0.014 8
	175	700	WK $G = 1$	0.997	1.000	0.941	0.979	0.952	0.993	1.000	0.980 3	0.007 4
	350	700	WK $G = 1$	1.000	1.000	0.969	0.983	0.969	0.992	1.000	0.987 6	0.006 2

4 结 论

本文提出了一种 TWD-SVM 的轴承复合故障分类方法,解决了轴承复合故障分类中存在的少量标签数据及强线性不可分问题。针对传统时频域特征线性不可分的问题,利用 MODWPT 与能量的时频特征用于表示轴承故障特征。其次,针对少样本问题,提出了增量式核空间标签扩散方法扩充样本,并利用双阶段 SVM 提高模型的分类准确率。实验结果表明,MODWPT 分解小波包系数能量,能灵敏的表征故障特征、提高方法分类准确率;基于核差异距离的增量式核空间标签扩散,能有效表示单一样本与一类样本间的相似程度,具备更优的标签扩散效果;所提 TWD-SVM 在单类故障样本为 5 的条件下平均准确率达到 96.3%,在同等条件下较 SVM 分类效果提升 7.5%。在未来的研究中,需要探索新的方法减少增量式

核空间标签扩散中由于增加训练样本而产生的计算复杂度,进一步提高 TWD-SVM 方法的运算效率及可行性。

参考文献

[1] RAI A, UPADHYAY S H. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings [J]. Tribology International, 2016, 96: 289-306.

[2] XIE W, LI Z, XU Y, et al. Evaluation of different bearing fault classifiers in utilizing CNN feature extraction ability[J]. Sensors,2022, 22:3314.

[3] JIAO Z, PAN L, FAN W, et al. Partly interpretable transformer through binary arborescent filter for intelligent bearing fault diagnosis [J]. Measurement, 2022, 203: 111950.

[4] 徐卓飞, 李旭东, 张婵婵, 等. 基于孪生网络的小样

- 本滚动轴承故障诊断研究[J]. 仪器仪表学报, 2022, 43(10): 241-251.
- XU ZH F, LI X D, ZHANG CH CH, et al. Research on small sample rolling bearing fault diagnosis based on twin networks[J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 241-251.
- [5] 雷春丽, 夏奔锋, 薛林林, 等. 小样本下自校正卷积神经网络的滚动轴承故障识别方法[J]. 仪器仪表学报, 2022, 43(9): 122-130.
- LEI CH L, XIA B F, XUE L L, et al. Rolling bearing fault identification method based on self-correcting convolutional neural network under small sample[J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 122-130.
- [6] 陈保家, 陈学力, 肖文荣, 等. 小样本下滚动轴承故障的多源域迁移诊断方法[J]. 电子测量与仪器学报, 2022, 36(2): 219-228.
- CHEN B J, CHEN X L, XIAO W R, et al. Multi-source domain transfer diagnosis method for rolling bearing faults under small samples[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 219-228.
- [7] 陈良臣, 傅德印. 面向小样本数据的机器学习方法研究综述[J]. 计算机工程, 2022, 48(11): 1-13.
- CHEN L CH, FU D Y. Survey on machine learning methods for small sample data[J]. Computer Engineering, 2022, 48(11): 1-13.
- [8] 张振良, 刘君强, 黄亮, 等. 基于半监督迁移学习的轴承故障诊断方法[J]. 北京航空航天大学学报, 2019, 45(11): 2291-2300.
- ZHANG ZH L, LIU J Q, HUANG L, et al. A bearing fault diagnosis method based on semi-supervised and transfer learning[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(11): 2291-2300.
- [9] YU K, LIN T R, MA H, et al. A multi-stage semi-supervised learning approach for intelligent fault diagnosis of rolling bearing using data augmentation and metric learning[J]. Mechanical Systems and Signal Processing, 2021, 146: 107043.
- [10] 陶新民, 任超, 徐朗, 等. 基于伪标签半监督核局部 Fisher 判别分析轴承故障诊断[J]. 振动与冲击, 2020, 39(17): 1-9.
- TAO X M, REN CH, XU L, et al. Bearing fault diagnosis based on semi-supervised kernel local Fisher discriminant analysis using pseudo labels[J]. Journal of Vibration and Shock, 2020, 39(17): 1-9.
- [11] 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 X S, GUO W. 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.
- [12] FENG Y, CHEN J, ZHANG T, et al. Semi-supervised meta-learning networks with squeeze-and-excitation attention for few-shot fault diagnosis[J]. ISA Transactions, 2022, 120: 383-401.
- [13] ZHANG X, RAMÍREZ-MENDIOLA J L, LI M, et al. Electricity consumption pattern analysis beyond traditional clustering methods: A novel self-adapting semi-supervised clustering method and application case study[J]. Applied Energy, 2022, 308: 118335.
- [14] VAPNIK V N. The nature of statistical learning theory[M]. Berlin: Springer, 1995.
- [15] VAN M, HOANG D T, KANG H J. Bearing fault diagnosis using a particle swarm optimization-least squares wavelet support vector machine classifier[J]. Sensors, 2020, 20(12): 3422.
- [16] DONG L, LIAO J. Wavelet kernel function based multiscale LSSVM for elliptic boundary value problems[J]. Neurocomputing, 2019, 356: 40-51.
- [17] 王宏超, 陈进, 董广明. 基于补偿距离评估-小波核 PCA 的滚动轴承故障诊断[J]. 振动与冲击, 2013, 32(18): 87-90, 94.
- WANG H CH, CHEN J, DONG G M. Fault diagnosis of rolling bearing based on compensation distance evaluation technique-wavelet kernel principal component analysis[J]. Journal of Vibration and Shock, 2013, 32(18): 87-90, 94.
- [18] DHIMAN H S, DEB D, MUYEEN S M, et al. Wind turbine gearbox anomaly detection based on adaptive threshold and twin support vector machines[J]. IEEE Transactions on Energy Conversion, 2021, 36(4): 3462-3469.
- [19] 陈剑, 阚东, 孙太华, 等. 基于 SVD-VMD 和 SVM 滚动

轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(1): 220-226.

CHEN J, GAN D, SUN T H, et al. Rolling bearing fault diagnosis method based on SVD-VMD and SVM[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 220-226.

[20] KUMAR M, KUMAR V, BISWAS R, et al. Hybrid ELM and MARS-based prediction model for bearing capacity of shallow foundation[J]. Processes, 2022, 10(5): 1013.

[21] YUAN H, WU N, CHEN X, et al. Fault diagnosis of rolling bearing based on shift invariant sparse feature and optimized support vector machine[J]. Machines, 2021, 9(5): 98.


作者简介



陈赛赛, 2022 年于江苏大学获得测控技术与仪器学士学位, 现在江苏大学攻读仪器科学与技术硕士学位, 主要研究方向为信号处理、机械系统智能故障诊断与分类。

E-mail: csaisai2000@163.com

Chen Saisai received his B. Sc. degree in Measurement and Control Technology and Instrument from Jiangsu University in 2022. He is currently pursuing his M. Sc. degree in Instrument Science and Technology at Jiangsu University. His main research interests include signal processing and intelligent fault diagnosis.



陈超(通信作者), 2011 年和 2014 年于江苏大学分别获得学士和硕士学位, 2020 年于东南大学获博士学位, 现为江苏大学讲师、硕士生导师, 主要研究方向为信号处理、机械系统状态监测与智能故障诊断。

E-mail: chenchao@ujs.edu.cn

Chen Chao (Corresponding author) received his B. Sc. and M. Sc. degrees both from Jiangsu University in 2011 and 2014, respectively, and received his Ph. D. degree from Southeast University in 2020. He is currently a lecturer and a master advisor at Jiangsu University. His main research interests include signal processing, machine condition monitoring and intelligent fault diagnosis.



贺长波, 2012 年于沈阳东北大学获得学士学位, 分别于 2016 年和 2019 年获得大连理工大学硕士和博士学位。现为安徽大学电气工程与自动化学院讲师。主要研究方向为弱故障特征提取、状态监测等。

E-mail: changbh@ahu.edu.cn

He Changbo received his B. Sc. degree from Northeastern University in 2012, and M. Sc. degree and Ph. D. degree both from Dalian University of Technology in 2016 and 2019, respectively. He is currently a lecturer with the College of Electrical Engineering and Automation at Anhui University. His research interests include weak fault feature extraction and condition monitoring.



樊薇, 2012 年和 2015 年于苏州大学分别获学士和硕士学位, 2018 年于香港城市大学获博士学位。现为江苏大学机械工程学院教授。主要研究方向为信号处理和机械故障诊断。

E-mail: weifan@ujs.edu.cn

Fan Wei received her B. Sc. degree and M. Sc. degree both from Soochow University in 2012 and 2015, respectively, and Ph. D. degree from City University of Hong Kong in 2018. She is currently a professor with the School of Mechanical Engineering at Jiangsu University. Her research interests include signal processing and machinery fault diagnosis.