

改进 LPCDA 算法及其在旋转机械故障诊断中的应用*

薛 勇, 赵荣珍

(兰州理工大学机电工程学院 兰州, 730050)

摘要 针对高维故障数据集中有效信息利用率低导致故障分类难度偏大的问题,提出一种线性主成分判别分析(linear principal component discriminant analysis, 简称 LPCDA)的故障数据集降维算法。该算法将类间可分性判别与主成分计算的思想融入线性判别分析(linear discriminant analysis, 简称 LDA)算法中,使算法拥有剔除相关信息和冗余特征的能力,从而可以更好地保留能够反映机械运行状态有价值的故障状态信息以及特征的主要成分。实验结果表明,本算法能够剔除高维故障数据集中的相关信息、冗余特征并保留特征主要成分,具有降低故障分类难度与提高自动辨识准确率的功能。该研究可为有效降低高维故障数据集的规模和故障的分类难度、提高有效信息的挖掘能力,提供了理论参考依据。

关键词 线性主成分判别分析;线性判别分析;可分性;降维

中图分类号 TH133.33;TH165

引 言

发展新一代智能型旋转机械设备已成为我国流程工业装备制造面临的新挑战^[1-2]。如何将机械设备在生产过程中产生的价值密度较低的海量监测数据向数据型资源转化、并开发和利用数据型资源实现智能决策技术,已成为目前机械行业主要的发展趋势之一。这种发展趋势促使基于数据驱动的旋转机械智能故障诊断技术必须迈入“工业大数据”时代^[3-5]。如何从海量的大数据中挖掘出有价值的故障状态信息和决策知识、降低海量高维数据型资源的规模,这对于智能型旋转机械设备的落地应用具有极其重要的推动作用。

故障特征中通常包含大量的相关信息和冗余特征,影响人工智能自动辨识结果的准确性^[6-7]。为了尽可能全面描述典型故障的状态,需要从时域、频域以及时频域等角度提取出能够全方位描述故障状态的量化故障特征。因此,研究消除相关信息和冗余特征、降低高维故障数据集维数的有效算法,对于降低旋转机械故障的分类难度、提高故障的辨识准确率尤为重要。

传统的降维算法,例如:局部保持投影(locality preserving projection, 简称 LPP)^[8]、主成分分析(principal component analysis, 简称 PCA)^[6]等均属

于无监督算法。LPP 通过近邻关系保持数据的局部特性,从而获得相似度矩阵以逼近数据的真实分布^[8]。PCA 通过选择贡献率最大的几个主成分来获得最佳投影矩阵,其少数的几个主成分便可涵盖大部分的重要特征信息^[7-9],缺点是降维效果不理想。线性判别分析^[10-11]通过最大化类间散度矩阵和类内散度矩阵比值的方式,求得最佳的投影矩阵,确保低维特征子集具有较高的可分性。

在 LDA 算法的降维过程中,因高维故障数据集中包含大量的相关信息和冗余特征,导致在构建投影矩阵时存在误差,影响算法的降维效果;又因降维过程具有一定的盲目性,从而影响算法的降维效果与辨识准确率。类间可分性判别^[12]通过计算单个特征的可分性,从高维故障数据集中剔除影响故障分类的相关信息 and 冗余特征,从而提高故障辨识效果。主成分计算能够剔除特征向量中影响降维效果的非主要成分,达到提高故障辨识准确率的效果。

基于上述分析,本研究对类间可分性判别、主成分计算与 LDA 算法相融合的故障数据集降维算法进行研究,为剔除高维故障数据集中不利于实施分类运算的相关信息 and 冗余特征、减小降维过程的盲目性以及优化目标维数的参数选择问题提供理论参考。

* 国家自然科学基金资助项目(51675253);兰州理工大学红柳一流学科建设资助项目
收稿日期:2020-12-25;修回日期:2021-04-01

1 相关原理简介

1.1 类间可分性判别的概念

该算法是根据离差测度来测量特征类间可分性大小的一种算法,类内离差越小,类间离差越大,则说明特征的可分性越好。其目的是根据可分性的大小,剔除高维故障数据集中影响故障分类的相关信息和冗余特征^[12]。

1.2 线性判别分析 LDA 算法

该算法属于经典的有监督降维算法,其核心思想是通过最大化目标函数 $J_{\text{LDA}}(\mathbf{W})$,从而最大化类间距离、最小化类内距离的方式构建最佳投影矩阵,通过投影矩阵使低维特征子集其类间距离最大、类内距离最小^[13]。LDA 在降维过程中存在两方面缺点:①高维数据集中大量的相关信息和冗余特征导致求得的最佳投影矩阵存在一定的偏差,使投影后低维特征子集的可分性较低;②该算法在降维过程中的目标维数通常设为 $C-1$ 维(C 为类别数),但因无法确定前 $C-1$ 个特征值所对应的特征向量中是否包含大部分重要特征信息,使得算法在处理高维数据集时可能会丢失一些重要特征信息,从而影响算法的降维效果与故障辨识精度。

1.3 主成分计算

主成分计算是 PCA 算法中确定主成分占有所有成分比例的一种算法,根据累积特征贡献率的大小选择特征向量的主要成分。贡献率越大,表明所选主要成分的个数越多,保留的故障特征信息量也就越多。

累积特征贡献率 $\rho^{[6]}$ 定义为

$$\rho = \frac{\sum_{i=1}^s \lambda_i}{\sum_{i=1}^r \lambda_i} \quad (s=1, 2, \dots, r) \quad (1)$$

由于在 PCA 算法中随着所选主成分个数的增多,主要成分中影响故障分类的相关信息、冗余特征以及噪声等不利因素也就越多,因此需要根据待处理数据集的实际情况设定其累积特征贡献率的大小。

2 建立降维算法与应用流程

2.1 建立 LPCDA 算法

鉴于 LDA 算法是通过最大化类间距离与类内距离比值的方式实现降维,故结合上述算法的优点,本研究设计一种新的故障数据集降维算法,即将

类间可分性判别和主成分计算的思想融入 LDA 算法中,提出一种 LPCDA 算法,并将其用于滚动轴承故障数据集降维处理中。LPCDA 算法描述如下。

首先,假设高维输入样本 $\mathbf{X} = \{x_1, x_2, \dots, x_k\} \in R^{m \times k}$ 中共有 C 类样本,包含 k 维特征的第 i 类样本记为 $X_i = \{x_i^l(k)\}$, $l=1, 2, \dots, m_k$,则总的类内离差矩阵第 k 个元素可表示为 $S_w(k)$,总的类间离差矩阵可表示为 $S_b(k)$ 。

$$S_w(k) = \frac{1}{C} \frac{1}{n_i} \sum_{i=1}^C \sum_{l=1}^{n_i} \|x_i^l(k) - \mu_i(k)\|^2 \quad (2)$$

$$S_b(k) = \frac{1}{C} \sum_{i=1}^C \|\mu_i(k) - \mu(k)\|^2 \quad (3)$$

其中: n_i 为第 C 类样本中包含的样本个数; $\mu_i(k)$ 为 X_i 中第 k 个特征的均值; $\mu(k)$ 为整体数据中第 k 维特征的样本均值; $S_w(k)$ 为各类样本子集围绕其均值的分布情况; $S_b(k)$ 为不同类之间的距离分布情况。

其次,根据每个特征 $J(k)$ 的大小筛选出可分性较大的特征,组成高维敏感故障数据集 $x = \{x_1, x_2, \dots, x_n\} \in R^d$,其中,大小为 n_c 的第 C 类样本记为 x_c ,则类内散度矩阵 Z_w 和类间散度矩阵 Z_b 分别为

$$Z_w = \sum_{c=1}^C \sum_{i=1}^{n_c} (x_i - m_c)(x_i - m_c)^T \quad (4)$$

$$Z_b = S_b - S_w = \sum_{c=1}^C n_c (m_c - m)(m_c - m)^T \quad (5)$$

其中: $m = \frac{1}{n} \sum_{i=1}^n x_i$ 为总体的样本均值; $m_c = \frac{1}{n_c} \sum_{x \in X_c} x_c$ 为每类样本的均值($c=1, 2, \dots, C$)。

类间可分性判别系数定义为 $J(k)$,特征的 $J(k)$ 值越大,表明其可分性越好。

$$J(k) = \frac{Z_b(k)}{Z_w(k)} \quad (6)$$

该算法的目标函数定义为 $J_{\text{LPCDA}}(\mathbf{W})$

$$\begin{cases} \arg \max J_{\text{LPCDA}}(\mathbf{W}) = \frac{\mathbf{W}^T \mathbf{Z}_b \mathbf{W}}{\mathbf{W}^T \mathbf{Z}_w \mathbf{W}} \\ \mathbf{W}^T \mathbf{W} = \mathbf{I} \end{cases} \quad (7)$$

然后,通过拉格朗日乘子法求解目标函数,可求得特征值与特征矩阵

$$\mathbf{Z}_b \mathbf{W} = \lambda \mathbf{Z}_w \mathbf{W} \Rightarrow \mathbf{Z}_w^{-1} \mathbf{Z}_b \mathbf{W} = \lambda \mathbf{W} \quad (8)$$

其中: λ 为矩阵 $\mathbf{Z}_w^{-1} \mathbf{Z}_b$ 的特征值; \mathbf{W} 为特征值对应的特征向量; $\mathbf{Z}_w^{-1} \mathbf{Z}_b$ 的前 d 个特征值对应的特征向量组成的矩阵为最佳投影矩阵。

最后,根据特征贡献率 ρ 计算出最佳投影矩阵 \mathbf{P} 。

LPCDA 算法在滚动轴承故障诊断中的主要思路如下:①通过双跨转子实验台采集滚动轴承的故障振动信号,构建能够全面描述轴承故障状态的多

域高维故障数据集;②通过类间可分性判别的算法剔除高维故障数据集中影响故障分类的相关信息和冗余特征,保留有利于实施故障分类的敏感故障数据集;③通过类内散度矩阵与类间散度矩阵构建目标函数 $J_{LPCDA}(W)$,求解得到特征值与特征向量;④通过主成分计算的方式保留特征向量中含有大部分重要特征信息的主要成分构成最佳投影矩阵,投影后得到低维特征子集 Y 。

2.2 算法优点

本研究提出的LPCDA算法具备以下优势:①能够通过类间可分性判别剔除高维故障数据集中的相关信息和冗余特征,保留可分性较高的有利于实施故障分类的特征信息;②通过计算累积特征贡献率的方式,选择满足贡献率的前 s 个特征值所对应的主成分取代按经验选取主成分的方式,避免了主成分中缺失重要的特征信息;③利用累积特征贡献率阈值对降维过程中目标维数的选择进行优化,通过设定贡献率阈值自适应选择目标维数,避免了在降维过程中人为选择目标维数的盲目性。

2.3 参数对算法的影响

LPCDA算法在降维过程中涉及2个参数:类间可分性判别阈值 J 和累积特征贡献率阈值 ρ 。设定 J 的目的是为了剔除高维故障数据集中的相关信息和冗余特征,因此需要根据待处理数据集各个特征的可分性大小,选择适当的阈值,从而剔除不利于实施故障分类的可分性较小的特征。设定 ρ 的目的是为了保证所选的主成分中含有大部分有利于实施故障分类的重要特征信息。因为LPCDA算法在降维过程中,已剔除高维故障数据集中影响故障分类的相关信息、冗余特征以及噪声等不利影响因素,故可以通过选择较大的累积特征贡献率阈值保留大部分重要特征信息。因此,根据滚动轴承故障数据集的可分性大小,本研究设置可分性判别阈值 $J=0.6$,累积特征贡献率 $\rho=99\%$ 。

2.4 降维效果衡量指标

为衡量各算法的降维效果,本研究通过引入可分性指标来评价低维特征子集的聚类与分类效果^[14]。其类间距离 L_b 用来描述不同类样本之间的分离程度,类内距离 L_w 用来描述同类样本之间数据点的聚集程度。假设数据集共有 C 类,每类样本中拥有 n 个样本点的数据记为 $y_{ki}(k=1, 2, \dots, C; i=1, 2, \dots, n)$,则每类样本的聚类中心记为 $\bar{y}_k =$

$\frac{1}{n} \sum_{i=1}^n y_{ki}, (k=1, 2, \dots, C)$,类间距离 L_b 、类内距离

L_w 与可分性指标 β 分别定义为

$$L_b = \frac{2}{C(C-1)} \sum_{k=1}^{C-1} \sum_{l=r+1}^C \|\bar{y}_k - \bar{y}_l\| \quad (9)$$

$$L_w = \frac{1}{C} \frac{1}{n} \sum_{k=1}^C \sum_{i=1}^n \|y_{ki} - \bar{y}_k\| \quad (10)$$

$$\beta = L_b / L_w \quad (11)$$

由式(11)可知,可分性指标测量的是类间分离程度与类内聚集程度的比值。 L_b 越大、 L_w 越小,则 β 的值越大,说明数据的可分性越好。

故障诊断的目标是实现故障的自动辨识,选择 k 最近邻(K-nearest neighbor,简称KNN)^[15]、支持向量机(support vector machine,简称SVM)^[16]和前馈神经网络(back propagation,简称BP)^[17]3种分类器来验证笔者提出的LPCDA算法的降维效果。若分类器的识别准确率越高,则表明算法的降维效果越好。

2.5 基于LPCDA算法的故障诊断应用流程

图1为LPCDA算法应用流程图。其具体步骤如下:

1) 采集滚动轴承的故障振动信号进行消噪,计算其时域、频域以及时频域特征,构建高维故障数据集 X ;

2) 对 X 进行归一化处理,通过类间可分性判别计算 X 中所有特征的可分性大小,选择出可分性 $J(k) \geq 0.6$ 的特征,记为 X_i ;

3) 计算 X_i 的类内散度矩阵 Z_w 、类间散度矩阵 Z_b 和目标函数 $J_{LPCDA}(W)$,从而求得特征值与特征向量;

4) 设定累积特征贡献率阈值 $\rho=99\%$,选择满足设定贡献率的前 s 个特征值对应的特征向量构成最佳投影矩阵;

5) 通过最佳投影矩阵对训练样本和测试样本进行投影,分别得到训练样本和测试样本的低维特征子集,再将低维特征子集分别输入不同的分类器中进行故障模式辨识,得到故障诊断结果。

3 实验验证

3.1 Wine数据集的仿真实验

Wine数据集的特征来源于意大利同一地区3种不同葡萄酒的化学成分。数据集的3类样本中分别包含59,71和48组样本,每个样本都拥有13种共

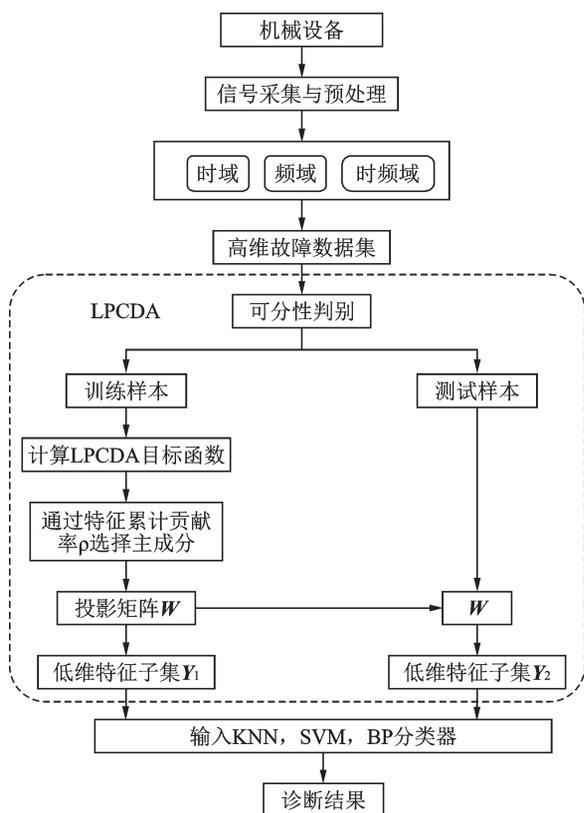


图 1 LPCDA 算法应用流程图

Fig.1 The process of LPCDA algorithm application

同属性。将 3 类样本分别按照 30:29, 36:35, 23:25 的比例设置训练集和测试集, 用来验证 LPCDA 算法的降维效果, 并与 LDA 和 PCA 算法进行对比。各算法降维后特征子集的可视化效果如图 2 所示。其中: 设置 LPCDA 的可分性判别阈值 $J=0.3$, 累积特征贡献率 $\rho=99\%$, 其目标维数自适应至 2 维; 设 LDA 和 PCA 的目标维数均为 2 维。

由图 2 可知, 3 种算法降维后得到的低维特征子集的可分离可视化效果均有所改善, 但 PCA 和 LDA 的改善程度较小。经 LPCDA 降维后其低维特征子集的内类较为聚集、类间较为分离, 可视化效果最好。通过 KNN, SVM 和 BP 分类器测试样本的分类准确率如表 1 所示。其中: 设置 KNN 分类器的 $k=$

8; SVM 选用高斯径向基核函数, 通过网格搜索法对核参数和惩罚因子寻优; BP 分类器的隐含层神经元个数设为 10。结合图 2 和表 1 可知, 相比于其他算法, LPCDA 算法具有更好的降维效果与更高的故障辨识精度。

表 1 各算法降维后测试样本的分类准确率

Tab.1 The classification accuracy of test samples after dimension reduction of each algorithm

分类器	未降维	PCA	LDA	LPCDA
KNN	62.92	95.51	96.63	98.88
SVM	96.63	94.38	95.51	98.88
BP	88.76	93.26	95.51	98.88

3.2 轴承故障模拟实验

3.2.1 实验数据说明

实验台和故障轴承如图 3 所示。本研究选择图 3(a) 所示的无锡厚德自动化仪表有限公司生产的 HZXT-001 型实验台为平台, 模拟滚动轴承 6308 的内圈裂纹、外圈裂纹、滚动体破裂、保持架破裂和正常 5 种状态下的振动信号。为了能够全面分析滚动轴承的振动信号, 前 3 个通道使用加速度传感器采集振动信号, 后 2 个通道使用电涡流传感器采集振动信号, 设置采样频率为 8 kHz。在转速为 3 kr/min 时, 采集每种故障状态的振动信号各 80 组, 前后各 40 组分别用作训练样本和测试样本。表 2 为故障特征量化指标。为了能够尽可能全面描述滚动轴承的故障状态, 确定通过时域、频域以及时频域共 38 个特征量构建单个通道的信号特征, 5 个通道构建的高维故障数据集共包含 $38 \times 5 = 190$ 个量化特征。

3.2.2 降维效果可视化

为了验证 LPCDA 算法的有效性, 将其与 PCA 和 LDA 两种算法的降维效果进行对比。设置 LPCDA 的类间可分性判别阈值 $J=0.6$ 、累积特征贡献率

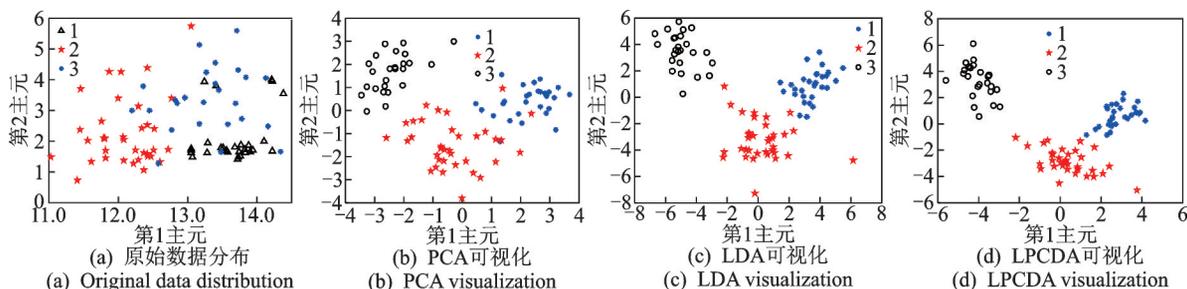


图 2 降维后特征子集的可视化效果

Fig.2 The visualization effect of dimension reduction

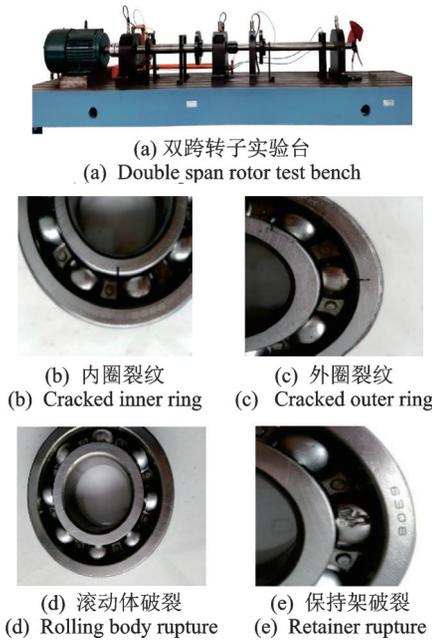


图 3 实验台和故障轴承

Fig.3 Test bench and faulty bearings

表 2 故障特征量化指标

Tab.2 The quantitative index of fault characteristics

序号	特征名称	序号	特征名称
1	均值	13	峰值指标
2	均方值	14	脉冲指标
3	方根幅值	15	裕度指标
4	均方根值	16	峭度指标
5	绝对均值	17	均值频率
6	歪度	18	均方根频率
7	峭度	19	频率标准差
8	方差	20	频率中心
9	最大值	21	频谱峭度
10	最小值	22	频谱二阶距
11	峰峰值	23~38	4层小波包分
12	波形指标		解能量特征

1~16为时域指标;17~22为频域指标;23~38为时频域小波包能量特征。

阈值 $\rho=99\%$,其目标维数自适应至 4 维;PCA 和

LDA 的目标维数均设置为 4 维。3 种降维算法的可视化效果如图 4 所示。

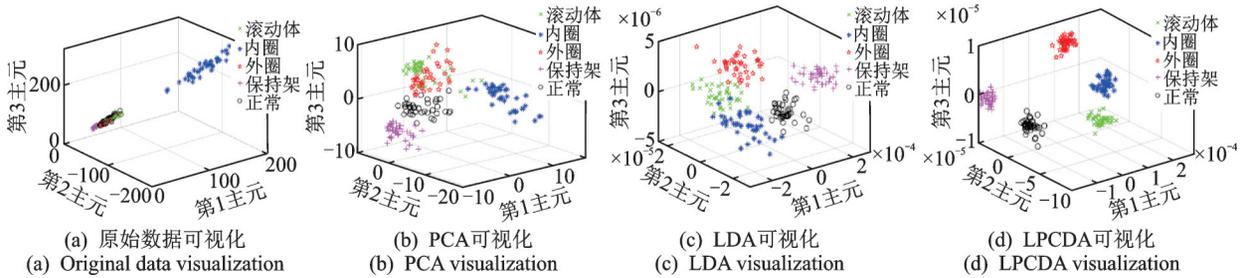


图 4 3 种降维算法的可视化效果

Fig.4 The visualization effect of three dimensionality reduction algorithms

由图 4 可知,经 LPCDA 算法降维后得到特征子集的可视化效果明显优于其他两种算法,当前结果呈现的特点是类内距离较小、类间距离较大,各类之间均无混叠现象,轴承的 5 种状态可以有效地被分离开。经 PCA 与 LDA 算法降维后得到的特征子集的可视化效果均较差,这两种降维算法呈现的特点均为类内较为分散、类间较为聚集,各故障之间无法完全有效地进行分离。上述分析表明,LPCDA 算法的降维效果明显优于其他 2 种算法。

3.2.3 降维效果衡量指标

为直观有效地衡量各算法的降维效果,在本研究中使用 L_b, L_w 和可分性指标 β 作为降维效果的衡量指标,对 3 种算法的降维结果进行评价。各算法降维后测试样本的可分性指标如图 5 所示。各算法的上述 3 项指标分别按照从左到右的顺序进行排列。

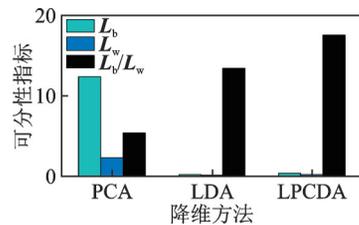


图 5 各算法降维后测试样本的可分性指标

Fig.5 The separability index of test samples after dimensionality reduction by each algorithm

故障诊断的目标是实现模式的自动辨识,为了进一步量化各算法的降维效果,选择 KNN, SVM 和 BP 3 种不同的分类器分别验证经各算法降维后得到的测试样本的分类准确率,各降维算法的分类准确率如表 3 所示。其中:设置 KNN 的 $k=7$;SVM 采用高斯径向基核函数,通过网格搜索法确定其核函数和惩罚因子;设置 BP 分类器的隐含层神经元个

表 3 各降维算法的分类准确率

Tab.3 The classification accuracy of each dimension reduction algorithm %

分类器	未降维	PCA	LDA	LPCDA
KNN	50.50	89.50	76.50	100.00
SVM	20.00	93.50	76.50	100.00
BP	67.00	94.50	62.00	100.00

数为 10。

结合图 5 和表 3 对比发现, LDA 算法的降维效果与识别准确率最差, 其缺点在于无法剔除高维故障数据集中的相关信息和冗余特征, 导致目标函数以及投影矩阵存在一定误差, 且选取目标维数时盲目性可能会导致部分主要成分丢失。PCA 算法的降维效果与识别准确率较差, 其缺点在于 PCA 属于无监督算法, 无法有效利用故障的类别信息。LPCDA 算法的降维效果与识别准确率最高, 该算法可通过类间可分性判别有效地剔除不利于实施故障分类与辨识的相关信息 and 冗余特征, 且通过累积特征贡献率可以精确地选取出包含大部分重要特征信息的主要成分, 由此可以极大程度地减小构建目标函数以及投影矩阵时存在的误差, 从而实现优化降维效果、提高故障分类准确性的功能。以上分析充分表明, LPCDA 算法相比于对比的其他算法, 其降维效果更好、故障辨识精度更高。

3.2.4 变工况环境下算法性能

机械设备工作时其速度具有一定的波动性, 本研究通过变工况实验来验证所提出算法对速度波动的适应性。实验选用 2.6, 2.8 和 3 kr/min 3 种不同转速下的混合数据来模拟变工况环境下的速度波动情况。实验在每种转速的不同故障中选取 20 组数据混合后做为训练样本, 另取各转速下不同故障中不重复的 20 组混合后作为测试样本。通过 KNN, SVM 和 BP 3 种不同的分类器, 分别验证 LPCDA 算法的分类准确率, 并与 LDA 和 PCA 算法进行比较。变工况下 3 种算法的分类准确率如表 4 所示。分析表 4 可知, 在变工况工作环境影响下, 各算法降维后

表 4 变工况下 3 种算法的分类准确率

Tab.4 The classification accuracy of 3 algorithm under variable working conditions %

分类器	PCA	LDA	LPCDA
KNN	86.67	62.67	99.67
SVM	86.00	61.33	97.33
BP	85.67	72.00	99.00

得到的测试样本的分类准确率均有所下降, 但 LPCDA 算法的分类准确率下降程度最小, 分类效果明显优于其他 2 种算法, 表明该算法抗速度波动的能力更强, 具有更好的适应性和鲁棒性。

4 结束语

针对实现智能决策过程中遇到的高维故障数据集有效信息利用率低的问题, 本研究以 LDA 算法为基础, 通过引入类间可分性判别与主成分计算的思想, 建立了一种新的故障数据集降维算法 LPCDA。该算法通过类间可分性判别有效地剔除了不利于实施故障分类的相关信息 and 冗余特征; 同时, 通过主成分计算避免了所选主成分中缺失重要的故障特征信息, 实现了提高算法的降维效果与故障辨识精度的功能。通过计算累积特征贡献率, 避免了目标维数的选择问题, 使降维过程不再具有盲目性。Wine 数据集的仿真实验和在实验台上采集到的滚动轴承故障数据集的各项实验结果表明: 相比于其他算法, 本研究所建立的 LPCDA 算法具有更好的降维效果与更高的故障辨识精度。该算法可为挖掘高维数据集中能够反映机械运行状态的有价值的故障状态信息提供理论参考。

参 考 文 献

- [1] 李杰, 李响, 许元铭, 等. 工业人工智能及应用研究现状及展望[J]. 自动化学报, 2020, 46(10): 2031-2044. LEE Jay, LI Xiang, XU Yuanming, et al. Recent advances and prospects in industrial and applications[J]. Acta Automatica Sinica, 2020, 46(10): 2031-2044. (in Chinese)
- [2] 柴天佑. 工业人工智能发展方向[J]. 自动化学报, 2020, 46(10): 2005-2012. CHAI Tianyou. Development directions of industrial artificial intelligence[J]. Acta Automatica Sinica, 2020, 46(10): 2005-2012. (in Chinese)
- [3] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104. LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104. (in Chinese)
- [4] 金晓航, 王宇, ZHANG Bin. 工业大数据驱动故障预测与健康诊断[J]. 计算机集成制造系统, 2022,

- 28(5): 1314-1336.
JIN Xiaohang, WANG Yu, ZHANG Bin. Industrial big data-driven fault prognostics and health management [J]. Computer Integrated Manufacturing Systems, 2022, 28(5): 1314-1336. (in Chinese)
- [5] 王庆锋, 卫炳坤, 刘家赫, 等. 一种数据驱动的旋转机械早期故障检测模型构建和应用研究[J]. 机械工程学报, 2020, 56(16): 22-32.
WANG Qingfeng, WEI Bingkun, LIU Jiahe, et al. Research on construction and application of a data-driven incipient fault detection model for rotating machinery [J]. Journal of Mechanical Engineering, 2020, 56(16): 22-32. (in Chinese)
- [6] KHEDIRI I B, LIMAM M, WEIHS C. Variable window adaptive kernel principal component analysis for nonlinear nonstationary process monitoring [J]. Computers & Industrial Engineering, 2011, 61(3): 437-446.
- [7] JOLLIFFE I T, CADIMA J. Principal component analysis: a review and recent developments [J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2016, 374(2065): 20150202.
- [8] LI Y Y, LU R Q. Locality preserving projection on SPD matrix Lie group: algorithm and analysis [J]. Science China (Information Sciences), 2018, 61(9): 50-66.
- [9] 朱文昌, 罗梦婷, 倪广县, 等. 随机矩阵理论和主成分分析融合的滚动轴承性能退化评估方法[J]. 西安交通大学学报, 2021, 55(2): 55-63.
ZHU Wenchang, LUO Mengting, Ni Guangxian, et al. Rolling bearing performance degradation assessment method combining random matrix theory and principal component analysis [J]. Journal of Xi'an Jiaotong University, 2021, 55(2): 55-63. (in Chinese)
- [10] LI R H, LIANG S, BACIU G, et al. Equivalence between LDA/QR and direct LDA [J]. International Journal of Cognitive Informatics and Natural Intelligence, 2011, 5(1): 94-112.
- [11] ZHANG X W, CHU D L, TAN R C E. Sparse uncorrelated linear discriminant analysis for under sampled problems [J]. IEEE Transactions on Neural Networks & Learning Systems, 2016, 27(7): 1469-1485.
- [12] 张恒, 赵荣珍. 故障特征选择与特征信息融合的加权KPCA方法研究[J]. 振动与冲击, 2014, 33(9): 89-93, 121.
ZHANG Heng, ZHAO Rongzhen. Weighted KPCA based on fault feature selection and feature information fusion [J]. Journal of Vibration and Shock, 2014, 33(9): 89-93, 121. (in Chinese)
- [13] 高云龙, 王志豪, 丁柳, 等. 动态加权非参数判别分析[J]. 控制与决策, 2020, 35(8): 1866-1872.
GAO Yunlong, WANG Zhihao, DING Liu, et al. Dynamic weighted nonparametric discriminant analysis [J]. Control and Decision, 2020, 35(8): 1866-1872. (in Chinese)
- [14] 李学军, 李平, 蒋玲莉. 类均值核主元分析法及在故障诊断中的应用[J]. 机械工程学报, 2014, 50(3): 123-129.
LI Xuejun, LI Ping, JIANG Lingli. Class mean kernel principal component analysis and its application in fault diagnosis [J]. Journal of Mechanical Engineering, 2014, 50(3): 123-129. (in Chinese)
- [15] LIU R, YANG B, ZIO E, et al. Artificial intelligence for fault diagnosis of rotating machinery: a review [J]. Mechanical Systems & Signal Processing, 2018, 108: 33-47.
- [16] 李从志, 郑近德, 潘海洋, 等. 基于精细复合多尺度散布熵与支持向量机的滚动轴承故障诊断方法[J]. 中国机械工程, 2019, 30(14): 1713-1719, 1726.
LI Congzhi, ZHENG Jinde, PAN Haiyang, et al. Fault diagnosis method of rolling bearings based on refined composite multiscale dispersion entropy and support vector machine [J]. China Mechanical Engineering, 2019, 30(14): 1713-1719, 1726. (in Chinese)
- [17] 都明宇, 王志恒, 荀一, 等. 多模式人手动作分类识别方法[J]. 中国机械工程, 2019, 30(12): 1474-1479.
DU Mingyu, WANG Zhiheng, XUN Yi, et al. Classification and identification of multi-pattern of hand actions [J]. China Mechanical Engineering, 2019, 30(12): 1474-1479. (in Chinese)



第一作者简介:薛勇,男,1995年4月生,硕士。主要研究方向为旋转机械故障诊断。

E-mail: 1099325873@qq.com

通信作者简介:赵荣珍,女,1960年12月生,博士、教授、博士生导师。主要研究方向为旋转机械故障诊断。

E-mail: zhaorongzhen@lut.cn