

DOI: 10.7652/xjtuxb201906008

采用规范化局部保持投影的轴承故障诊断方法

刘锐, 邹俊荣, 任超, 陶新民

(东北林业大学工程技术学院, 150040, 哈尔滨)

摘要: 针对轴承故障检测中特征融合导致的维度高、相关性强等问题,提出一种采用规范化局部保持投影算法(LPP)的轴承故障诊断(En-LPP)方法。首先,采用熵规范化的方法将相似度矩阵结合到传统 LPP 算法的优化函数中,与投影向量一并求解,得到一种规范化 LPP 降维算法;然后对原始轴承振动信号进行小波变换和经验模式分解得到 10 条信号分量,每个分量通过计算平均值、均方根等,提取 12 维统计特征,经归一化后生成特征向量;然后将特征向量输入到规范化 LPP 降维算法中进行迭代共同求解,得到满足终止条件的相似度矩阵和投影向量;最后利用降维后的特征集训练极限学习机模型确定轴承最终工作状态以实现故障检测。实验结果表明:与传统 LPP 方法以及其他降维方法相比,所提出的 En-LPP 方法对于轴承故障诊断的性能更好;在小波变换 72 维特征集合以及经验模式分解 48 维特征集合下的分类精度平均提升了 7% 以上;在 4 种不同分类器组合下的分类精度平均提升了 17% 以上;较好的降维特征区分能力使得 En-LPP 方法的故障诊断性能在不同条件组合下均具有很好的鲁棒性。

关键词: 故障诊断;局部保持投影算法;降维;熵规范化

中图分类号: TH133.33 **文献标志码:** A **文章编号:** 0253-987X(2019)06-0054-08

A Novel Diagnostic Approach for Bearing Faults Using Regularized Locally Maintaining Projections

LIU Rui, ZOU Junrong, REN Chao, TAO Xinmin

(College of Engineering & Technology, Northeast Forestry University, Harbin 150040, China)

Abstract: A novel diagnostic approach for bearing faults using regularized locally maintaining projections (En-LPP) is proposed to solve the problems of high dimension and strong relevance caused by feature fusion in bearing fault detection domains. Firstly, the entropy normalization method is used to combine a similarity matrix into the optimization function of the traditional locality preserving projections (LPP) algorithm, and to solve it along with the projection vector to obtain a regularized LPP algorithm with reduced dimension. Then, the original bearing vibration signal is decomposed into ten signal components through wavelet transform and empirical mode decomposition, and 12-dimensional statistical features for each component are extracted. Final high-dimensional feature vectors are generated by combining and normalizing these statistical features of all components. These feature vectors are then inputted into the proposed algorithm, and iteration is performed to obtain the similarity matrix and the projection

收稿日期: 2018-10-20。 作者简介: 刘锐(1998—),男,本科生;陶新民(通信作者),男,教授。 基金项目: 国家自然科学基金资助项目(61571070);哈尔滨市科技局创新人才基金资助项目(2017RAXXJ018);中央高校基本科研业务费专项资金资助项目(2572017EB02)。

网络出版时间: 2019-05-05

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190505.1638.010.html>

vector that satisfy termination conditions. Finally, the reduced dimension feature set is used to train an extreme learning machine model for determining the final working state of a bearing to achieve fault detection. Experimental results and comparisons with the traditional LPP algorithm and other dimension reduction algorithms show that the proposed En-LPP algorithm has better performance for bearing fault diagnosis. The classification accuracy is improved by more than 7% on average under the 72-dimensional feature set of the wavelet transform and 48-dimensional feature set of empirical mode decomposition, and the averaged classification accuracy of the regularized LPP algorithm with combinations of 4 classifiers is about 17% higher than those of other dimension reduction algorithms. The proposed approach has better ability to distinguish dimension-reduced features, which makes its fault diagnosis performance robust under different combinations of conditions.

Keywords: fault diagnosis; locality preserving projections algorithm; dimension reduction; entropy regularization

机械故障诊断是一种掌握机器运行状态、早期发现故障及其原因并能预报故障发展趋势的技术^[1-2]。轴承作为机械设备的重要组成部分,其工作状态直接影响设备的性能及效率^[3]。因此,为了增加设备性能的可靠性,降低由于轴承故障原因导致产量下降的可能,轴承故障诊断越来越受到人们的重视^[4]。

轴承故障诊断涉及两方面技术:一是利用模式识别技术进行故障检测;二是利用信号处理技术进行特征提取^[5]。在模式识别领域,常见的方法有神经网络^[6-7]、支持向量机^[8-9]等。在特征提取方面,主要包括:信号的时域特征如信号的均值、均方值、峰值、峭度和歪度等;信号的频域特征如能量谱、AR功率谱等^[10];信号的时频特征如小波分析、Hilbert变换和短时傅里叶变换等^[11-12]。为了充分表征不同类别的故障进而提高识别率,就需要多种不同特征进行融合,这也使得目前获取的特征向量呈现维度高、相关性强、冗余信息多等特点,严重影响分类器的分类精度及计算复杂度^[13],因此如何有效地实现特征降维成为近年来的研究热点。主成分分析(PCA)作为数据降维的经典算法,因能有效去除特征间线性相关同时保持原始特征的主要信息而被广泛应用在图像分割、数据检测、故障检测等领域^[14-15]。然而,传统的主成分分析对于去除非线性关系存在局限性且其只考虑到全局分布特征,没有充分考虑局部信息的保持,导致不同类别间区分能力的丧失进而降低故障识别率^[16]。局部保持投影(LPP)是非线性方法 Laplacian Eigenmap 的线性近似,作为一种新的子空间分析方法,既解决了主成分分析方法难以保持原始数据非线性流形局部结构的问题,又解决了其无法去除指标间非线性相关性的问

题^[17]。目前,LPP算法在人脸识别、图像检索、故障检测等领域得到广泛应用^[18]。然而,LPP算法需事先指定近邻个数以及热核函数的参数来确定相似度矩阵,而在现实应用中由于事先对原始数据的空间分布未知,导致参数设置变得十分困难,受不当参数设置的影响,传统LPP算法的性能严重下降。为了解决该问题,文献[19]采用Parzen窗函数自适应确定近邻值进而提出了邻域自适应局部保持投影算法(SALPP),但由于Parzen窗函数本身初始核参数以及用于相似度计算的热核函数参数仍需事先指定,因而导致该算法的性能提升并不明显。

为此,本文提出一种采用规范化LPP算法的轴承故障诊断方法。该方法采用熵规范化将相似度矩阵结合到优化函数中,与投影向量一并求解,弥补了传统LPP算法需事先指定参数的不足,提升了算法的局部空间保持能力。通过与不同降维方法在不同降维维度、不同特征集合以及不同分类算法相结合情况下进行轴承故障检测实验,结果表明本文提出的改进算法在保持不同类别间区分能力的同时有效实现了数据降维,大大提高了故障检测的精度和检测效率。

1 传统 LPP 算法

LPP算法作为一种新的子空间分析方法,可以较好地反映样本的流形结构,其思想是在特征降维的同时,保持数据局部结构特征不变^[20-22]。

通过对传统LPP算法流程分析可发现,传统LPP算法其核心是线性近似,需事先指定近邻个数以及热核参数来求解样本空间的相近程度,从而确定相似度矩阵。然而,在现实应用中由于事先对原

始数据的空间分布未知,导致参数设置变得十分困难,从而增加相似度矩阵的计算难度。受不当参数设置的影响,传统 LPP 算法的降维性能严重下降。

2 规范化 LPP 算法

为了弥补传统 LPP 算法受参数设置影响性能下降的不足,本文对传统 LPP 算法加以改进,提出一种规范化 LPP 算法。该算法通过采用熵规范化,将相似度矩阵 U 结合到优化函数中,与投影向量一并求解,无需事先设定近邻个数 K 以及热核参数 σ ,因此有效避免了传统 LPP 算法参数设置的问题,使得降维后的投影空间具有更高的局部空间保持能力。

2.1 规范化 LPP 算法求解

(1)已知数据集 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$, 其中 $\mathbf{x}_i \in \mathbf{R}^d, i = 1, 2, \dots, n, n$ 为样本总数, d 为特征总数。设 $\mathbf{y}_i, \mathbf{y}_j$ 是新基向量下的降维投影坐标,在总体样本中考虑,原来相近的样本 $\mathbf{x}_i, \mathbf{x}_j$ 在新的基坐标空间中也同样相近。

(2)利用最大熵规范化方法构造求解 U 和投影向量 $\mathbf{W}_{\text{EnLPP}}$ 的目标函数为

$$\begin{aligned} \min_{\alpha} & \|\mathbf{y}_i - \mathbf{y}_j\|^2 u_{ij} + \sum_{i=1}^n \sum_{j=1}^n u_{ij} \ln u_{ij} \\ \text{s. t.} & \sum_{j=1}^n u_{ij} = 1, \quad i = 1, 2, \dots, n; \\ & \sum_{i=1}^n \|\mathbf{V}^T \mathbf{x}_i\|^2 d_{ii} = 1 \end{aligned} \quad (1)$$

式中: u_{ij} 为原有样本空间的相近程度参数; α 表示调节损失项和最大熵正则项的控制权重,通常令 $\alpha=1$ 。

(3)利用拉格朗日数乘法构造拉格朗日函数,即

$$\begin{aligned} G(\mathbf{V}, \mathbf{U}, \beta, \lambda) = & \sum_{i=1}^n \sum_{j=1}^d u_{ij} \ln u_{ij} + \alpha \|\mathbf{y}_i - \mathbf{y}_j\|^2 u_{ij} + \\ & \beta \left(\sum_{j=1}^d u_{ij} - 1 \right) + \lambda \left(\sum_{i=1}^d \|\mathbf{V}^T \mathbf{x}_i\|^2 d_{ii} - 1 \right) \end{aligned} \quad (2)$$

分别对 β, u_{ij} 求导,求得 u_{ij} 的表达式如下

$$u_{ij} = \exp(-\alpha \|\mathbf{V}^T \mathbf{x}_i - \mathbf{V}^T \mathbf{x}_j\|^2) \exp(-\beta - 1) \quad (3)$$

将求得的 u_{ij} 的表达式代入到 $\sum_{i=1}^n u_{ij} = 1$ 中,有

$$\exp(-\beta - 1) = \frac{1}{\sum_{j=1}^n \exp(-\alpha \|\mathbf{V}^T \mathbf{x}_i - \mathbf{V}^T \mathbf{x}_j\|^2)} \quad (4)$$

将式(4)代入式(3)中,得到 u_{ij} 的迭代表达式

$$u_{ij} = \frac{\exp(-\alpha \|\mathbf{V}^T \mathbf{x}_i - \mathbf{V}^T \mathbf{x}_j\|^2)}{\sum_{k=1}^n \exp(-\alpha \|\mathbf{V}^T \mathbf{x}_i - \mathbf{V}^T \mathbf{x}_k\|^2)} \quad (5)$$

为求解标准基向量 $\mathbf{V}$, 目标函数中的损失函数可作如下变换

$$\|\mathbf{y}_i - \mathbf{y}_j\|^2 u_{ij} = 2 \sum_{i,j} [(\mathbf{V} \mathbf{x}_i d_{ii} \mathbf{x}_i^T \mathbf{V} - \mathbf{V}^T \mathbf{x}_i u_{ij} \mathbf{x}_i^T \mathbf{V})] \quad (6)$$

将式(6)转换成矩阵形式表达如下

$$\mathbf{V}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{T} - \mathbf{V}^T \mathbf{X} \mathbf{U} \mathbf{X}^T \mathbf{T} = \mathbf{V}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{V} \quad (7)$$

式中: $\mathbf{L} = \mathbf{D} - \mathbf{U}$ 。为了防止 0 值解,加上约束条件

$$\sum_i \|\mathbf{V}^T \mathbf{x}_i\|^2 d_{ii} = 1, \text{ 写成矩阵形式如下}$$

$$\mathbf{V}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{V} = 1 \quad (8)$$

(4)通过拉格朗日函数求解标准基向量 $\mathbf{V}$, 得到的投影向量迭代表达式

$$\frac{\partial G(\mathbf{V}, \mathbf{U}, \beta, \lambda)}{\partial \mathbf{V}} = \frac{\mathbf{V}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{V} - \lambda (\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V} - 1)}{\partial \mathbf{V}} = 0 \quad (9)$$

$$\mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{V} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{V} \quad (10)$$

2.2 规范化 LPP 算法迭代流程

输入: $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}, \mathbf{x}_i \in \mathbf{R}^d$, 最大迭代次数 $r_{\max}$, 降维维度 P ;

输出: 投影矩阵 $\mathbf{W}_{\text{EnLPP}}$ 。

(1)初始化带权重的邻接矩阵 $\mathbf{U}_{(0)} \in \mathbf{R}^{n \times n}$;

(2)构造度量矩 $\mathbf{D}_0, d_{ii} \in \mathbf{D}_0, d_{ij} = 0, i \neq j, d_{ij} =$

$$\sum_{j=1}^n u_{ij}, i, j = 1, 2, \dots, n;$$

(3)令 $r=0$;

(4)构造拉普拉斯矩阵 $\mathbf{L}_r = \mathbf{D}_r - \mathbf{U}_r$ 求解 $\mathbf{X} \mathbf{L}_r \mathbf{X}^T \mathbf{V}_r = \lambda \mathbf{X} \mathbf{X}^T \mathbf{V}_r$ 特征值和特征向量集合 $\mathbf{V}_r$;

(5)当 $r > r_{\max}$ 时退出循环, 否则

$$u_{ij(r+1)} = \frac{\exp(-\alpha \|\mathbf{V}_r^T \mathbf{x}_i - \mathbf{V}_r^T \mathbf{x}_j\|^2)}{\sum_{k=1}^n \exp(-\alpha \|\mathbf{V}_r^T \mathbf{x}_i - \mathbf{V}_r^T \mathbf{x}_k\|^2)} \quad (11)$$

(6) $r = r + 1$;

(7)根据 $\mathbf{U}_r$ 构造度量矩阵 $\mathbf{D}_r$;

(8)go to 步骤(4);

(9)根据 $\mathbf{V}_{r_{\max}}$ 取前 P 个最小的特征值 $\lambda_i, i = 1, 2, \dots, P$, 所对应的特征向量 $\mathbf{V}_i, i = 1, 2, \dots, P$, 即为 $\mathbf{W}_{\text{EnLPP}} = [\mathbf{V}_i, i = 1, 2, \dots, P]$; 所对应的特征向量 $\mathbf{V}$ 即为 $\mathbf{W}_{\text{EnLPP}} = [\mathbf{V}_{i_{r_{\max}}}, i = 1, 2, \dots, P]$ 。

通过上述的迭代过程可知,经过最大熵规范化将 $\mathbf{U}$ 同投影向量一并求解后,通过上述的迭代算法(步骤 4 和 5)反复迭代后即可求出 u_{ij} 的值和最终的投影向量 $\mathbf{W}_{\text{EnLPP}}$,进而避免了传统 LPP 算法参数设置的问题。

3 采用规范化 LPP 算法的轴承故障诊断方法

采用规范化 LPP 算法的轴承故障诊断过程主要分为特征提取、特征降维和故障诊断 3 部分。特征提取首先将原始信号经过小波变换和经验模式两种信号预处理,得到 10 条信号分量,每个分量通过计算平均值、均方根等 12 种特征建立初始特征集,并进行归一化处理;然后将其输入规范化 LPP 算法中进行迭代,当满足终止条件时得到相似度矩阵及标准基向量,从而求得投影矩阵及降维后的特征集;最后使用极限学习机分类器进行故障类型的判别。具体训练过程如下。

(1)确定参数:分段长度 L ,小波变换层数 N_1 ,经验模式分解层数 N_2 ,降维维度 P ,最大迭代次数 $r_{\max}$ 。

(2)利用安装在轴承上的振动传感器收集该轴承在不同工况下的振动信号。设共有 4 种工况:正常状态、内圈故障状态、外圈故障状态和滚动体故障状态,然后分别对各种工况下的信号进行长度为 L 的分段处理,得到原信号样本集合 $\mathbf{S} = \{\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_n\}$, $\mathbf{S} \in \mathbf{R}^{n \times L}$ 。

(3)通过离散小波变换对原信号样本集 $\mathbf{S}$ 进行 N_1 层小波分解,得到 1 到 N_1 层的细节分量和第 N_1 层近似分量,共 $N_1 + 1$ 个频带分量。对原信号进行 N_2 层经验模式分解,得到 1 到 N_2 层的基本模式分量和第 N_2 层余项,共 $N_2 + 1$ 个频带分量。

(4)分别对小波变换得到的 $N_1 + 1$ 个频带分量和经验模式分解得到的 $N_2 + 1$ 个频带分量进行特征提取,其中包括平均值、均方根、方差、标准差、整流平均值、峰-峰值、峭度值、峰值、波形、峭度、脉冲、裕度因子共 12 种故障特征。

(5)归一化。对选取的 $12(N_1 + N_2 + 2)$ 个故障特征量按照线性函数归一化的方式进行归一化处理,进而得到训练特征样本集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$, $\mathbf{X} \in \mathbf{R}^{n \times 12(N_1 + N_2 + 2)}$ 。

(6)特征降维。根据本文提出的规范化 LPP 算法的迭代流程 2.2 对 $\mathbf{X}$ 进行迭代运算,其中 $\mathbf{X}$ 对应着不同工况下的轴承振动信号经特征提取后的全体训练样本集合, $d = 12(N_1 + N_2 + 2)$ 为轴承振动信号经特征提取后的特征维度,得到相似度矩阵 $\mathbf{U}_{r_{\max}}$ 及标准基向量 $\mathbf{V}_{r_{\max}}$,求得投影向量 $\mathbf{W}_{\text{EnLPP}}$,从而最终求得降维后的特征集 $\mathbf{Y} = \mathbf{W}_{\text{EnLPP}}^T \mathbf{X}$ ($\mathbf{Y} \in \mathbf{R}^{n \times P}$),并利用其训练极限学习机模型 $\mathbf{M}_{\text{elm}}$ 。 $\mathbf{Y}$ 对应着不同工况

下的轴承振动信号全体训练样本特征集合经规范化 LPP 算法降维后的降维特征集合。

测试过程如下:将收集到的轴承振动信号片段 $\mathbf{S}_{\text{new}} \in \mathbf{R}^{1 \times L}$ 经过小波变换及经验模式分解求得频带分量,对其进行特征提取得到故障特征,经归一化处理求得训练特征样本集 $\mathbf{X}_{\text{new}}$,降维后得到特征集 $\mathbf{Y}_{\text{new}} = \mathbf{W}_{\text{EnLPP}}^T \mathbf{X}_{\text{new}}$ ($\mathbf{Y}_{\text{new}} \in \mathbf{R}^{1 \times P}$),将其输入到训练好的 $\mathbf{M}_{\text{elm}}$ 中,确定当前轴承最终的工作状态。

4 实验分析及对比

为了验证采用规范化 LPP 的轴承故障诊断方法的检测性能,本文进行了下列实验。实验数据均来源于美国凯斯西储大学(Case Western Reserve University)的电气工程实验室^[23],利用安装在感应电动机输出轴的支撑轴承上端机壳上的振动加速传感器来收集振动信号,采样频率为 12 kHz。实验模拟了滚动轴承的 4 种运行状态:1 正常状态;2 内圈故障;3 外圈故障;4 滚动体故障。每个振动信号片段的样本点数 $L = 1\,024$,每个工况下的振动信号片段如图 1 所示。




图 1 4 种工况时域振动信号片段

采用 DB1 小波对振动信号片段进行分解层数为 $N_1 = 5$ 的小波变换并提取 12 维故障特征,共计 $6 \times 12 = 72$ 维特征,以及 $N_2 = 3$ 层经验模式分解,提

取12维故障特征,共计 $4 \times 12 = 48$ 维特征,经特征融合后总计120维故障特征。实验环境为Windows7操作系统,CPU为Intel i7,3.4 GHz处理器,仿真软件为Matlab2010b。

4.1 规范化LPP算法降维性能分析

为了验证本文提出的规范化局部保持投影算法的降维性能,实验中取正常样本、内圈故障样本、外圈故障样本和滚动体故障样本各50个样本构成整体数据集进行降维,并与传统LPP算法进行比较。其中,规范化局部保持投影算法的最大迭代次数 $r_{\max} = 300$,降维维度 $P = 2$,传统LPP算法的最近邻个数为3,热核参数 σ 为1。为了便于比较,本文算法利用相同参数计算的邻接矩阵作为初始值,经两种算法降维后得到的数据分布情况如图2、图3所示。




图2 120维数据特征集经传统LPP算法投影到二维空间后的特征分布图




图3 120维数据特征集经本文规范化LPP算法迭代300次后投影到二维空间后的特征分布图

由图2、图3不难看出:传统LPP得到的投影特征虽然保持的局部邻域信息,相同类别的样本大部分能聚集在一起,但却没能实现内圈故障和外圈故障样本的有效区分;本文提出的规范化局部保持投影算法得到的降维数据具有明显的区分性,不仅同一类样本聚集在一起,而且不同类别的样本间实现

了有效分离。

为了能量化地比较传统LPP算法和本文提出的规范化LPP算法所得到的降维特征的区分性能,本文采取基于类间分离指标(SC)的区分指标^[24], D_j 表示第 j 类样本的分离度, D_C 表示同一类样本的分离度, D_B 表示类与类之间的分离度,计算公式如下

$$D_j = \sum_{x_i \in c_j} \frac{1}{n_j} (x_i - m_j)(x_i - m_j)^T \quad (12)$$

$$D_C = \sum_{j=1}^C D_j \quad (13)$$

$$D_B = \sum_{j=1}^C (m_j - m)(m_j - m)^T \quad (14)$$

式中: m 是全体样本的均值; m_j, n_j 是属于第 j 类 c_j 所有样本的均值和个数; C 是类别个数。设 z_{SC} 是类间分离指标,则有

$$z_{SC} = \text{tr}(D_C^{-1} D_B) \quad (15)$$

式中: tr 为求解矩阵迹的函数,为了防止 D_C 矩阵是奇异的,这里通常采用 $z_{SC} = \text{tr}(D_B) / \text{tr}(D_C)$, z_{SC} 值越大,特征区分能力就越强。

为了比较在不同降维维度的情况下传统LPP算法和本文的规范化局部保持投影算法得到的降维特征的区分能力,本文采用正常样本、内圈故障样本、外圈故障样本和滚动体故障样本各500个样本,构成整体数据集进行降维,除降维维度 P 外,其他参数设置同上, z_{SC} 值随不同降维维度 P 的变化对比结果如图4所示。




图4 传统LPP算法和本文规范化LPP算法在不同降维维度下的降维特征区分能力比较

从图4可以看出,本文的规范化局部保持投影算法在不同降维维度情况下降维性能都优于传统LPP算法,这也表明本文算法的局部近邻保持效果明显优于传统LPP算法,且投影后的系数向量在不同降维维度下均具有很好的区分能力。

为了考察不同最大迭代次数对本文规范化局部保持投影算法性能的影响,实验分析了本文算法在

不同降维维度 $P=2,5,10$ 下得到的特征区分能力 z_{sc} 随迭代次数的变化情况,参数设置同上,实验结果如图 5 所示。不难发现,本文规范化 LPP 算法在不同降维维度下得到的降维特征的区分能力在初期随着迭代次数的增大呈现上升趋势,但随着迭代次数的进一步增大,上升趋势不再明显且逐渐呈现平坦趋势。因此,为了在保持降维性能的同时降低计算复杂度,建议最大迭代次数设置在 300 左右。




图 5 本文规范化 LPP 算法在不同降维维度下的特征区分能力随迭代次数的变化

4.2 不同降维算法的分类精度对比分析

为了考察采用规范化 LPP 算法的轴承故障识别方法的故障诊断精度,本文分别选取 1 000 个正常样本、内圈故障样本、外圈故障样本和滚动体故障样本,并同传统 PCA 算法、传统 LPP 算法和自适应 LPP 算法(SALPP)进行对比分析。分类器采用极限学习机 ELM 进行故障检测。规范化 LPP 算法的最大迭代次数 $r_{max}=300$,ELM 输入单元个数为 5,输出单元个数为 4,隐层单元的个数为 30。观察不同降维维度下采用不同降维算法的轴承故障识别方法的分类精度,通过 10 次交叉验证法进行实验并计算其平均值,其他参数设置同上,实验结果如图 6 所示。由图 6 可以看出,本文提出的故障诊断方法在不同降维维度下的分类性能都明显优于采用其他降维算法的轴承故障诊断方法的分类性能。该实验结果再次证明了经本文规范化 LPP 算法降维后的特征具有很好的区分能力。

为了分析本文规范化 LPP 算法对不同特征集合的降维性能,本文采用基于小波变换的 72 维特征集合和经经验模式分解后的 48 维特征集合进行降维处理,其中降维维度为 5,参数设置同上,结果如表 1 所示。由表 1 结果可知,本文提出的采用规范化 LPP 算法在不同特征集合下都具有较好的降维性能,使得降维特征具有较强的区分能力,从而提高了故障识别性能。




图 6 采用不同降维算法的轴承故障识别方法在不同降维维度下的分类精度对比

表 1 不同特征集合的降维性能对比

特征集合	分类精度/%			
	PCA	LPP	SALPP	本文算法
小波变换 72 维特征	84.239	85.833	87.933	92.712
经验模式分解 48 维特征	83.157	84.858	86.758	92.204

4.3 同其他分类算法结合后的性能分析

最后,为了验证本文规范化 LPP 算法和其他 3 种算法与不同分类器相结合后的轴承故障识别性能,本文采用了支持向量机 SVM(one-all)、RBF 神经网络(RBFNN)、多层感知机神经网络(MLP)、极限学习机 ELM 这 4 种分类器进行对比实验,其中,SVM 参数采用高斯核,核宽度和惩罚因子由 grid-search 搜索方法确定,RBF、MLP 和 ELM 的隐层单元个数为 30,降维维度为 5,其他参数设置同上,实验结果如表 2 所示。

表 2 不同算法的分类精度对比结果

分类器	分类精度/%			
	PCA	LPP	SALPP	本文算法
SVM(one-all)	86.191	86.625	86.579	91.115
RBFNN	84.253	85.135	85.537	90.135
MLP	83.511	85.212	86.515	91.037
ELM	86.022	86.131	88.235	93.927

通过表 2 的实验结果可以发现,本文算法同各种分类器算法组合后的故障诊断性能均优于其他降维算法。该实验结果进一步表明,经本文提出的规范化 LPP 算法降维后得的特征能有效地保持局部分布邻域信息且具有较高的区分能力,使得同其组合的分类器的检测精度大大提高。

5 结 论

本文提出一种采用规范化 LPP 算法的轴承故障识别方法。该算法采用熵规范化将相似度矩阵结合到优化函数中,与投影向量一并求解,无需事先指定参数,弥补了传统 LPP 算法需事先指定参数的不足,大大提升了算法局部保持能力,且使得降维后的特征具有较高的区分能力。实验结果表明,本文所提规范化 LPP 算法的降维性能明显优于其他降维方法,较好的降维特征区分能力使得本文 En-LPP 方法的故障诊断性能在不同条件组合下均具有很好的鲁棒性。

参考文献:

- [1] 剡昌锋,朱涛. 基于马田系统的滚动轴承初始故障检测和状态监测 [J]. 振动与冲击, 2017, 36(12): 155-188.
YAN Changfeng, ZHU Tao. Incipient fault detection and condition monitoring of rolling bearings by using the Mahalanobis-Taguchi system [J]. Journal of Vibration and Shock, 2017, 36(12): 155-188.
- [2] 沈微,陶新民. 基于同步挤压小波变换的振动信号自适应降噪方法 [J]. 振动与冲击, 2018, 37(14): 239-247.
SHEN Wei, TAO Xinmin. Self-adaptive de-noising algorithm for vibration signals based on synchrosqueezed wavelet transforms [J]. Journal of Vibration and Shock, 2018, 37(14): 239-247.
- [3] 陈娜,杨绍普. 基于匹配追踪预处理的铁道车辆滚动轴承故障诊断方法 [J]. 振动与冲击, 2017, 36(21): 132-137.
CHEN Na, YANG Shaopu. Railway vehicle rolling bearing fault diagnosis method based on the matching pursuit pretreatment [J]. Journal of Vibration and Shock, 2017, 36(21): 132-137.
- [4] 王林,蔡改改. 基于改进 MP 的稀疏表示快速算法及其滚动轴承故障特征提取应用 [J]. 振动与冲击, 2017, 36(3): 176-182.
WANG Lin, CAI Gaigai. Fast sparse representation algorithm based on improved MP and its applications in fault feature extraction of rolling bearings [J]. Journal of Vibration and Shock, 2017, 36(3): 176-182.
- [5] 武英杰,辛红伟. 基于 VMD 滤波和极值点包络阶次的滚动轴承故障诊断 [J]. 振动与冲击, 2018, 37(14): 102-107.
WU Yingjie, XIN Hongwei. Rolling bearing fault diagnosis based on the variational mode decomposition

- filtering and extreme point envelope order [J]. Journal of Vibration and Shock, 2018, 37(14): 102-107.
- [6] SWAGATAM D, SHOUNAK D. Handling data irregularities in classification: foundations, trends, and future challenges [J]. Pattern Recognition, 2018, 81: 674-697.
- [7] SHAO H D, JIANG H K. Rolling bearing fault feature learning using improved convolutional deep belief network with compressed sensing [J]. Mechanical Systems and Signal Processing, 2018, 100: 743-765.
- [8] SHAO H D, JIANG H K. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders [J]. Mechanical Systems and Signal Processing, 2018, 102: 278-297.
- [9] WANG S B, IVAN S. Nonconvex sparse regularization and convex optimization for bearing fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2018, 65(9): 7332-7343.
- [10] 柯燕亮,王华庆. 基于 Teager 峰值能量的低转速轴承故障特征提取方法 [J]. 振动与冲击, 2017, 36(11): 124-133.
KE Yanliang, WANG Huaqing. Fault feature extraction of low speed roller bearings based on Teager peak energy [J]. Journal of Vibration and Shock, 2017, 36(11): 124-133.
- [11] 唐贵基,庞彬. 基于时时能量阶比谱的变转速工况滚动轴承微弱故障诊断研究 [J]. 振动工程学报, 2017, 30(5): 856-864.
TANG Guiji, PANG Bin. Research on fault diagnosis of rolling bearing's weak fault under variable speed conditions based on time-time energy order spectrum [J]. Journal of Vibration Engineering, 2017, 30(5): 856-864.
- [12] 孔佑炳,郭瑜. 基于 EEMD 的混合陶瓷球轴承故障双冲击特征提取 [J]. 振动与冲击, 2016, 35(1): 17-22.
KONG Ruobing, GUO Yu. Double-impulse feature extraction of faulty hybrid ceramic ball bearings based on EEMD [J]. Journal of Vibration and Shock, 2016, 35(1): 17-22.
- [13] 谷朝健,马增强. 多通道相关-自适应轴承故障诊断方法 [J]. 航空动力学报, 2018, 33(7): 1750-1756.
GU Chaojian, MA Zengqiang. Adaptive bearing fault diagnosis method of multi-channel correlation [J]. Journal of Aerospace Power, 2018, 33(7): 1750-1756.
- [14] 赵孝礼,赵荣珍. 全局与局部判别信息融合的转子故障数据集降维方法研究 [J]. 自动化学报, 2017, 43(4): 560-567.

- ZHAO Xiaoli, ZHAO Rongzhen. A method of dimension reduction of rotor faults data set based on fusion of global and local discriminant information [J]. *Acta Automatica Sinica*, 2017, 43(4): 560-567.
- [15] 吴广宁, 袁海满, 高波, 等. 基于特征评估与核主元分析的电力变压器故障诊断 [J]. *高电压技术*, 2017, 43(8): 2533-2540.
- WU Guangning, YUAN Haiman, GAO Bo, et al. Fault diagnosis of power transformer based on feature evaluation and kernel principal [J]. *High Voltage Engineering*, 2017, 43(8): 2533-2540.
- [16] 张绍辉, 李巍华. 基于特征空间降噪的局部保持投影算法及其在轴承故障分类中的应用 [J]. *机械工程学报*, 2014, 50(3): 92-99.
- ZHANG Shaohui, LI Weihua. Locality preserving projections based on feature space denoising and its application in bearing fault classification [J]. *Journal of Mechanical Engineering*, 2014, 50(3): 92-99.
- [17] 王广斌, 杜谋军. 基于多尺度子带样本熵和 LPP 的轴承故障诊断方法 [J]. *振动与冲击*, 2016, 35(20): 71-76.
- WANG Guangbin, DU Moujun. A bearing fault diagnosis method based on multi-scale sub-band sample entropy and LPP [J]. *Journal of Vibration and Shock*, 2016, 35(20): 71-76.
- [18] 丁晓喜, 何清波. 基于 WPD 和 LPP 的设备故障诊断方法研究 [J]. *振动与冲击*, 2014, 33(3): 89-93.
- DING Xiaoxi, HE Qingbo. Machine fault diagnosis based on WPD and LPP [J]. *Journal of Vibration and Shock*, 2014, 33(3): 89-93.
- [19] 杨望灿, 张培林. 基于邻域自适应局部保持投影的轴承故障诊断模型 [J]. *振动与冲击*, 2014, 33(1): 39-44.
- YANG Wangchan, ZHANG Peilin. Bearing fault diagnosis based on neighborhood adaptive locality preserving projections [J]. *Journal of Journal of Vibration and Shock*, 2014, 33(1): 39-44.
- [20] HE Xiaofei, YAN Shuicheng, HU Yuxiao, et al. Face recognition using Laplacian faces [J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2005, 27(3): 328-340.
- [21] FADI D, AMMAR A. Enhanced and parameterless locality preserving projections for face recognition [J]. *Neurocomputing*, 2013, 99(1): 448-457.
- [22] ZHENG Heng. A new construction method of neighbor graph for locality preserving projections [J]. *Journal of Information and Computational Science*, 2013, 10(5): 1357-1365.
- [23] Case Western Reserve University. Bearing data center website: bearing data center seeded fault test data [DB/OL]. (2016-04-06) [2018-07-15]. <http://cse-groups.case.edu/bearingdatacenter/pages/download-data-file>.
- [24] GYEONGYONG H, PAUL G. Robust kernel discriminant analysis using fuzzy memberships [J]. *Pattern Recognition*, 2011, 44: 716-723.

[本刊相关文献链接]

- 张西宁, 向宙, 唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用. 2018, 52(7): 1-8. [doi: 10.7652/xjtuxb201807001]
- 成玮, 张周锁, 何正嘉. 采用信息理论准则的信号源数估计方法及性能对比. 2015, 49(8): 38-44. [doi: 10.7652/xjtuxb201508007]
- 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用. 2015, 49(5): 73-81. [doi: 10.7652/xjtuxb201505012]
- 徐田华, 杨连报, 胡红利, 等. 高速铁路信号系统异构数据融合和智能维护决策. 2015, 49(1): 72-78. [doi: 10.7652/xjtuxb201501012]
- 田福庆, 罗荣, 李万, 等. 改进的卷积型小波包分解及在故障诊断中的应用. 2014, 48(3): 89-95. [doi: 10.7652/xjtuxb201403017]
- 杨清宇, 孙凤伟. 一种迭代改进的球向量机故障诊断算法. 2013, 47(10): 1-6. [doi: 10.7652/xjtuxb201310001]
- 高瑞鹏, 尚春阳, 江航. 遗传算法结合小波神经网络的列车车轮扁疤故障检测方法. 2013, 47(9): 88-91. [doi: 10.7652/xjtuxb201309015]
- 高进, 袁奇, 李浦, 等. 燃气轮机拉杆式转子的刚度模化和模型修正方法. 2013, 47(5): 18-23. [doi: 10.7652/xjtuxb201305004]
- 夏虎, 庄健, 于德弘. 面向高维特征故障数据的进化软子空间聚类算法. 2013, 47(5): 115-120. [doi: 10.7652/xjtuxb201305021]
- 王跃飞, 张振涛, 张波, 等. 利用声发射的往复空压机环状阀泄漏故障诊断试验. 2012, 46(9): 26-30. [doi: 10.7652/xjtuxb201209006]
- 陈景龙, 訾艳阳, 何正嘉, 等. 自适应冗余多小波及其在故障诊断中的应用. 2012, 46(7): 44-49. [doi: 10.7652/xjtuxb201207009]
- 徐宇亮, 孙际哲, 陈西宏, 等. 采用多目标粒子群算法的模拟电路故障诊断研究. 2012, 46(6): 92-97. [doi: 10.7652/xjtuxb201206016]

(编辑 刘杨)