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

赵孝礼1 赵荣珍1

摘 要 针对传统的数据降维方法无法兼顾保持全局特征信息与局部判别信息的问题,提出一种核主元分析 (Kernel principal component analysis, KPCA) 和正交化局部敏感判别分析 (Orthogonal locality sensitive discriminant analysis, OLSDA) 相结合的转子故障数据集降维方法.该方法首先利用 KPCA 算法有效降低数据集的相关性、消除冗余属性,由此实现了最大 程度地保留原始数据全局非线性信息的作用;然后利用 OLSDA 算法充分挖掘出数据的局部流形结构信息,达到了提取出具 有高判别力低维本质特征的目的.上述方法的特点是通过同时进行的正交化处理可避免局部子空间结构发生失真,采用三维 图直观显示出低维结果,以低维特征子集输入最近邻分类器 (K-nearest neighbor, KNN)的识别率和聚类分析之类间距 Sb、 类内距 Sw 作为衡量降维效果的指标.实验表明该方法能够全面地提取出全局与局部判别信息,使故障分类更清晰,相应地识 别准确率得到了明显提升.该研究可为解决高维和非线性机械故障数据集的可视化与分类问题,提供理论参考依据. 关键词 故障诊断,数据可视化,数据降维,核主元分析,正交化局部敏感判别分析

引用格式 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. 自动化学报, 2017, **43**(4): 560-567 **DOI** 10.16383/j.aas.2017.c160317

A Method of Dimension Reduction of Rotor Faults Data Set Based on Fusion of Global and Local Discriminant Information

ZHAO Xiao-Li¹ ZHAO Rong-Zhen¹

Abstract Aimed at the problem that traditional dimension reduction methods cannot juggle global feature information and local discriminant information, a method of dimension reduction of the rotor fault dataset based on kernel principal component analysis (KPCA) and orthogonal locality sensitive discriminant analysis (OLSDA) is proposed. Firstly, the KPCA algorithm can reduce the correlation and redundant attributes of datasets and retain maximized original data information of global nonlinearity. Then, the OLSDA algorithm is used to fully excavate local manifold structure information of the data so as to extract the low-dimension essential feature with high discrimination. The method avoids distortion of local subspace structure by using a simultaneous orthogonalization process, and shows low dimensional results intuitively with 3-dimensional figure. Finally, the indexes to measure the dimension reduction effect are the recognition rate at which low-dimensional feature subset is input into KNN (K-nearest neighbor), the between-class scatter Sb and within-class scatter Sw of clustering analysis. Rotor experiment shows that this method can comprehensively extract global and local discriminant information, which makes classification of faults more clear and corresponding recognition accuracy rate significantly improved. This study provides a theoretical base for solving the visualization and classification problem of high-dimensional and nonlinear mechanical fault dataset.

Key words Fault diagnosis, data visualization, data dimension reduction, kernel principal component analysis (KPCA), orthogonal locality sensitive discriminant analysis (OLSDA)

Citation Zhao Xiao-Li, Zhao Rong-Zhen. A method of dimension reduction of rotor faults data set based on fusion of global and local discriminant information. Acta Automatica Sinica, 2017, 43(4): 560–567

旋转机械故障以转子系统故障最为常见且危害 性巨大^[1].因此,设法提高转子系统故障识别准确率 至关重要^[2].对于转子系统的故障辨识,一般均需利 用多个传感器采集信息,然后从时域、频域、时频域 等多个侧面提取出能够全面反映故障状态的量化指 标体系^[3].这导致了多元冗余特征参数渗入其中,使 得故障数据集存在着特征相关性增大、冗余信息应 该如何消除的问题^[4].此问题已成为旋转机械故障 诊断研究领域面临的挑战性新问题.因此,探讨消除 冗余信息、降低故障数据集维数的有效方法,对于全 面挖掘出敏感且本质的故障特征信息矢量、降低故 障分类的复杂度、提高故障识别的精度尤为关键^[5].

如按照结构保持方式进行划分,数据降维方法

收稿日期 2016-04-07 录用日期 2016-07-18

Manuscript received April 7, 2016; accepted July 18, 2016 国家自然科学基金 (51675253), 教育部高等学校博士学科点专项科研

基金 (20136201110004) 资助

Supported by National Natural Science Foundation of China (51675253) and the Doctor Science Research Foundation of the Education Ministry of China (20136201110004)

本文责任编委 胡昌华

Recommended by Associate Editor HU Chang-Hua

^{1.} 兰州理工大学机电工程学院 兰州 730050

^{1.} School of Mechanical and Electronical Engineering, Lanzhou University of Technology, Lanzhou 730050

可分为全局信息保持和局部信息保持两大类^[6].其 中,核主元分析 (Kernel principal component analysis, KPCA)^[7] 是主元分析 (Principal component analysis, PCA) 被扩展至处理非线性数据集的结果, 它能够在最大程度保持全局分布信息方差不变的情 况下,提取出故障信息的非线性特征,获得对故障状 态的最佳描述;但此时只能够发现数据信息的全局 欧氏结构,而对数据中低维局部流形结构特征信息 的保持无能为力^[8].这对于训练样本较少、局部结构 信息比全局结构信息更为重要的情况很不利^[9].

流形学习以能够有效揭示出高维数据中的低维 本质特征及对特征信息的局部保持性更强而著称, 但又存在着获取全局分布特征信息性能较差的缺 陷. 正交化局部敏感判别分析 (Orthogonal locality sensitive discriminant analysis, OLSDA)^[10] 是一 种基于局部保持的流形学习算法. 此算法作为局 部敏感判别分析 (Locality sensitive discriminant analysis, LSDA)^[9]的正交化版本, 能够克服局部判 别分析 (Locality discriminant analysis, LDA) 无法 发现数据的局部几何结构的缺点,使得同类距离被 压缩、异类距离被拉远;其中,正交化形式的输出使 得数据重构不易失真,可在有监督模式下提取出最 佳分类的特征子集. 但本质上 OLSDA 是一种基于 局部保持的降维方法, 它并不能有效提取出数据的 全局特征信息. Jin 等^[10] 已将 OLSDA 成功应用到 人脸识别领域,取得了较好的应用效果,但 OLSDA 在故障诊断中的应用尚未见到.

基于上述分析,本研究拟对 KPCA 与 OLSDA 相结合的转子故障数据集降维方法进行探讨. 欲为 转子故障数据集的全局最大化方差信息保持与局部 近邻结构信息和判别信息的有效提取,提供一种理 论参考依据.

1 相关的降维算法原理简介

1.1 **KPCA** 算法的原理

KPCA 的主要思想为^[10]: 首先借助非线性函数 H 将输入空间的数据样本 $X = \{x_i | i = 1, 2, \dots, n; x_i \in \mathbf{R}^d\}$ 映射至高维特征空间 G 中, 即 $x_i \rightarrow H(x_i)$; 然后在特征空间中进行主元分析, 提取非 线性结构信息. 若映射数据满足零均值条件, 则映射 数据的协方差矩阵为

$$C = \frac{1}{n} \sum_{i=1} H^{\mathrm{T}}(x_i) \times H(x_i)$$
(1)

对 C 做特征矢量分析, 定义 λ 为其特征值、v 为其 特征向量, 则有

$$\lambda v = Cv \tag{2}$$

用样本
$$H(x_k)$$
 对式 (2) 两端做内积, 可得:

$$\lambda[H(x_k) \times v] = H(x_k) \times Cv, \quad k = 1, 2, \cdots, n$$
(3)

其中, C 的特征量 v 可以由 $H(x_i)$ 线性表示, 即

$$v = \sum_{j=1}^{n} a_j H(x_j) \tag{4}$$

其中, a_i ($j = 1, 2, \dots, n$) 应为常数^[7].

引入核函数 $K(x_i, x_j) = H(x_i) \times H(x_j)$ 和核 矩阵 $K = (K_{ij}), K_{ij} = K(x_i, x_j),$ 则式 (3) 可简化 为

$$\bar{\lambda}a = Ka \tag{5}$$

其中, $\bar{\lambda} = n\lambda$, 问题被转化为求 K 的特征量和特征 值. 计算 v 在特征空间 G 中的投影, 可得其第 t 个 核主元, 即

$$T_{t} = [v_{t} \times H(x)] = \sum_{i=1}^{n} a_{t,i} K(x_{i}, x) \qquad (6)$$

 T_t 即为利用 KPCA 对 X 进行处理得到的非线性主元.

1.2 正交化局部敏感判别分析 OLSDA 算法

OLSDA 的基本思想为^[10]:在有监督模式下,找 到最优分类的投影方向,使同类样本点对聚得更近, 异类样本点对间隔更大;在正交约束的基础上使得 输出基向量相互正交.

设存在流形 M 中的 n 个样本的训练样本集 $x_i \in X$ ($X = (x_i, c_i) | i = 1, 2, \cdots, n; x_i \in \mathbf{R}^d$),其类 别标签是 $C_i \in (1, 2, \cdots, r)$. OLSDA 首先定义类 内近邻图 G_w 和类间近邻图 G_b 用来描述数据流形 的局部结构信息和判别结构信息.在一定约束条件 下,优化类内及类间距离目标函数,即

$$\min \sum_{ij} (y_i - y_j)^2 S_{ij}^w = \frac{1}{2} \sum_{ij} (a^{\mathrm{T}} x_i - a^{\mathrm{T}} x_j)^2 S_{ij}^w = a^{\mathrm{T}} X D^w X^{\mathrm{T}} a - a^{\mathrm{T}} X S^w X^{\mathrm{T}} a$$
(7)

$$\max \sum_{ij} (y_i - y_j)^2 S_{ij}^b = \frac{1}{2} \sum_{ij} (a^{\mathrm{T}} x_i - a^{\mathrm{T}} x_j)^2 S_{ij}^b = a^{\mathrm{T}} X D^b X^{\mathrm{T}} a - a^{\mathrm{T}} X S^b X^{\mathrm{T}} a$$
(8)

其中,两个加权系数矩阵 S^w 和 S^b

$$S_{ij}^{b} = \begin{cases} 1, & x_{i} \in P^{b}(x_{j}) \ \vec{u} \ x_{j} \in P^{b}(x_{i}) \\ 0, & \not\equiv \& \end{cases}$$
(10)

其中, $P^{w}(x_{j})$, $P^{w}(x_{i})$ 表示类内与 x_{j} , x_{i} 同标记的 k 近邻, $P^{b}(x_{j})$, $P^{b}(x_{i})$ 表示类间与 x_{j} , x_{i} 不同标记 的 k 近邻. 在附加条件下合并目标函数并转化为求 解如下方程

$$a = \arg\max_{a} a^{\mathrm{T}} X B X^{\mathrm{T}} a$$

s.t. $a^{\mathrm{T}} X D^{w} X^{\mathrm{T}} a = 1$ (11)

其中, $B = \beta L^b + (1 - \beta)S^w$, 调节参数为 β , L^b 为 类间拉普拉斯矩阵, D^w 为类内对角矩阵.

为在降维过程中尽量保持数据的局部线性重 构关系,需实现基向量相互正交,即 $AA^{T} = I$,则 能够避免局部子空间的结构失真. 设 $W = [w_1, w_2, \dots, w_k]$ 为新的输出正交向量且满足条件: $w^{T}_{K}w_1 = w^{T}_{K}w_2 = \dots = w^{T}_{K}w_{k-1} = 0.$ 令 $S_d = XD^wX, S_u = XBX, W^{(k-1)} = [w_1, w_2, \dots, w_{k-1}], C^{(k-1)} = [W^{(k-1)}], 增加约束条件 w^{T}S_dw =$ 1. 已知 w_1 对应的特征值,若假设前k-1个正交向量基已知,那么第k个特征值对应的特征向量可由式(11)求得.采用拉格朗日乘数法,将式(11)所求的约束优化问题可转化为

$$H^{k} = w_{k}^{\mathrm{T}} S_{u} w_{k} - \lambda (w_{k}^{\mathrm{T}} S_{d} w_{k} - 1) - \eta_{1} w_{k}^{\mathrm{T}} w_{1} - \dots - \eta_{k-1} w_{k}^{\mathrm{T}} w_{k-1}$$
(12)

通过求解式 (12), 得 w_k 为式 (13) 最大特征值 对应的特征向量

$$\{I - (S_d)^{-1} W^{(k-1)} [C^{(k-1)}]^{-1} [W^{(k-1)}]^{\mathrm{T}}\} \times (S_d)^{-1} S_u w_k = \lambda w_k$$
(13)

最后通过迭代基向量可得到变换矩阵 $A_o = [w_1, w_2, \dots, w_k]^{[4,10]}$.

2 设计的 KPCA 与 OLSDA 相融合的流形 学习算法

鉴于数据降维的实质是对数据信息有效保持的 过程,原始数据信息损失越少则数据降维的效果越 好,后续用于分类的信息精确度越高.从对 KPCA 和 OLSDA 的介绍可知,传统降维方法无法兼顾全 局与局部判别信息的提取.前者作为一种统计和 描述性的全局降维算法,只能保持数据的全局方差 最大化信息, 在局部结构信息与判别信息的尺度上效果不佳; 而后者能充分挖掘出潜藏在低维流形中的局部结构信息与判别信息, 但易忽略数据的全局与非线性特征信息, 导致全局信息的丢失. 综合两类算法的优缺点, 本研究拟设计一种新的融合全局与局部判别信息的流形学习降维算法, 即 KPCA-OLSDA 融合算法用于转子故障数据集的降维处理, 其理论依据如下.

2.1 融合算法的主要思路

KPCA-OLSDA 融合算法的主要思路为: 先将 原始特征数据通过非线性核函数 *H*(*X*) 映射到高维 特征空间进行主元分析, 计算累计特征贡献率达到 95% 时, 提取出全局非线性方差信息; 然后将提取 的全局特征向量组成新的观测数据, 进行 OLSDA 双空间降维, 通过局部欧氏距离计算 *K* 个近邻点, 进而构建近邻结构与权值矩阵, 在类别标记信息的 指导下, 通过最大化类内散度矩阵的同时最小化类 间散度矩阵, 描述出数据的局部近邻结构与判别信 息, 并通过正交迭代基向量来消除投影向量间的冗 余信息, 得出低维嵌入.

2.2 融合算法信息的提取

全局信息反映整体共有特性,局部信息对应的 是区域细节;全局与局部信息的作用不同,但同等重 要.融合算法的数据信息提取包括全局特征信息的 提取、局部与判别信息的提取和全局与局部判别信 息的提取.

2.2.1 全局信息的保持

在全局范围内,由 KPCA 的原理式 (1) 所示数 据的全局信息体现在协方差矩阵里,目标是经过 *K* - *L* 变换将高维空间数据投影到低维空间,使得压 缩后的低维数据均方差最小,信息丢失最小.求解式 (5) 所示的目标函数,进行特征分析,提取出数据的 全局非线性信息.同时,为避免大范围特征对小范围 特征产生影响,有必要对数据进行归一化处理.为尽 可能的保留大部分数据信息,根据累计特征贡献度 进行降维,提取出蕴含主要信息的前 *t* 个主元.

$$\frac{\sum_{i=1}^{k} \lambda_{i}}{\sum_{i=1}^{d} \lambda_{i}}$$
(14)

用式 (14) 可计算出前 *t* 个特征所包含原始数据的信息量, 该比值越大说明全局信息保持的越好. 当累计贡献率达到 95% 时, 通过选取前 *t* 个特征作为特征主元, 即可达到提取出全局特征信息的目的^[11].

2.2.2 局部与判别信息的提取

经一次降维后, 在全局非线性特征空间里, 数据 噪声与冗余信息得到减少, 但 KPCA 忽略了对局部 信息与判别信息的提取. 在局部小范围内, OLSDA 利用局部欧氏距离构建类内近邻图 G_w 和类间近邻 图 G_b, 建立式 (9) 和式 (10) 的权重矩阵, 刻画数据 的局部近邻结构, 进而通过建立类内散度与类间散 度描述数据的局部判别信息.

2.2.3 全局与局部判别信息的提取

经上述两步信息提取后,新的特征空间在对全局与局部信息保持程度上都较好.然而没有任何约束的降维过程,容易导致数据特征提取混叠,数据重构困难^[4].针对此问题可通过式 (12) 和式 (13) 正交化过程,消除投影向量的冗余信息,增强全局与局部信息的融合.

2.3 KPCA-OLSDA 算法的具体实现步骤

结合 KPCA 与 OLSDA 各自优缺点,设计融合 全局与局部判别信息的降维方法.融合方法实现步 骤如下:

输入. 高维空间数据集 X.

输出.低维特征向量 Y,映射矩阵 Ao.

步骤 1. 将原始数据集进行归一化处理, 新的数据集仍然记为 X.

步骤 2. 数据集 $X \in \mathbf{R}^d$ 通过核函数映射到高 维特征空间 $H(X) \in \mathbf{R}^h$ $(h \ge d)$.

步骤 3. 在高维特征空间中进行主元分析, 特 征分析得到特征根及对应的特征向量 (降序排列). 当由式 (14) 计算特征根的累积贡献率达到阈值 95 % 时, 保留前 t 个非线性主元, 高维空间的低维 投影向量为 $\ell_1 = (v_1, v_2, \dots, v_t), t < d$, 可得到经 KPCA 方法处理后的一次降维数据表示 $X_{\text{KPCA}} = \ell_1^{\text{T}} H(X)$.

步骤 4. 将 X_{KPCA} 再经过 OLSDA 进行二 次降维, 训练得到映射矩阵 A_o , 低维嵌入为 $Y = A_o^{\text{T}} X_{\text{KPCA}}, Y \in \mathbf{R}^q, q < t$.

2.4 算法的优势分析

融合全局与局部判别信息的 KPCA-OLSDA 算 法作为一种新的降维算法,相比其他降维算法它具 有以下优势:

1) KPCA-OLSDA 算法既保留了 KPCA 的全局特性,又具有 OLSDA 在类别信息指导下挖掘出数据的局部判别信息的特性. KPCA 无监督与局部信息的不足,由 OLSDA 算法优点补充; OLSDA 的全局信息与非线性不足,由 KPCA 的核化与全局特性补充. KPCA-OLSDA 实现了对传统统计与流形学习降维算法的取优去劣与信息的高度融合.

2) KPCA 不仅保持数据的全局方差信息,而 且增强了后续判别信息的提取. OLSDA 从局部结 构近似描述全局特征信息,同时,正交化消除冗余 信息,使得全局与局部信息提取更加精确. KPCA-OLSDA 在不消弱全局与局部判别信息的前提下, 通过从整体到局部,再从局部反映整体的角度,增强 全局与局部判别信息.

3) KPCA 能解决 OLSDA 容易出现类内散度 矩阵奇异值的问题,即小样本问题;全局与局部信息 保持的 KPCA-OLSDA 能适应各类训练样本,泛化 能力强.

3 KPCA-OLSDA 相结合的故障数据降维 方法实现

为解决高维和非线性故障数据集降维过程中难 以全方位地提取故障信息的问题,本研究设计一种 全新的融合全局与局部判别信息的降维方法.其基 本思路为:首先以双跨度转子试验台为研究对象,建 立能够从不同侧面反映故障信息的高维故障特征集; 再将数据集输入融合 KPCA-OLSDA 的算法中进 行降维处理;最后将低维特征子集输入最近邻分类 器 (K-nearest neighbor, KNN),计算 KNN 的识别 率及聚类分析中的 Sb/Sw 作为衡量降维效果指标.

3.1 确定的降维效果评价指标

为实现故障数据的可视化,量化降维效果.本文 用模式识别中的特征评价准则反映出样本的分类与 聚类程度^[12].类内距 Sw 描述每类样本分布的紧凑 程度,类间距 Sb 用来定义类与类的分离程度.设特 征向量为 v₁,v₂,…,v_d, d 为特征向量的目标维数. 定义 Sw 和 Sb 分别为

$$Sw = \sum_{r=1}^{l} \sum_{v_{k \in L_r}} (v_k - m_v^r) (v_k - m_v^r)^{\mathrm{T}},$$

$$k = 1, 2, \cdots, d \qquad (15)$$

$$Sb = \sum_{r=1}^{l} (m_v^r - \bar{m}_v)(m_v^r - \bar{m}_v)^{\mathrm{T}}$$
(16)

其中, m_v^r 表示第 $r, r \in (L = 1, 2, \dots, l)$ 类的样本 特征向量的均值, $\bar{m}_v = (1/r) \sum_r^l m_v^r$ 是所有各类特 征向量的平均值. 显然, Sb/Sw 越大说明分类与聚 类效果越好, 故该项指标可作为降维效果的综合衡 量指标之一.

最近邻分类器 (KNN) 作为一种非参数的统计 分类方法,无需经过复杂的训练过程,直接根据训练 样本的局部和类别信息对测试样本即可进行分类决 策,以其简单直观、高效稳定、时效性强等被广泛应 用到故障诊断领域^[5,13].数据降维的最终目的是实现故障类别的准确分类,故 KNN 识别率越高,其相应的降维效果越好,本文中 KNN 的邻域值参数采用交叉验证选取为 7^[3,5].

3.2 融合全局与局部判别信息的转子故障数据集降 维方法

融合全局与局部判别信息的故障数据集降维方 法流程图见图 1. 具体实施步骤如下:

步骤 1. 信号采集与处理, 特征提取与选择并构 建高维混合故障数据集 X.

步骤 2. 进行归一化处理, 得到 *X*, 分为训练样 本集与测试样本集.

步骤 3. 确定核函数, 训练样本输入 KPCA, 当 累计方差贡献度达到 95 % 时, 得到一次降维特征向 量.

步骤 4. 将新观测数据输入 OLSDA 进行训练, 得到映射矩阵 *A*_o.

步骤 5. 通过映射矩阵对训练及测试样本进行 维数约简,再将得到的低维特征子集输入到 KNN, 并计算低维特征子集的 Sb, Sw 及 Sb/Sw 指标.

步骤 6. 数据可视化降维结果及故障分类诊断 结果.



图 1 融合全局与局部判别信息的故障数据集降维方法 Fig. 1 The method of dimension reduction of fault data set of the integrated global and local discriminant information

4 实验结果与分析

本研究对象为文献 [14] 中的一套双跨度转子实 验台. 实验模拟如下四种典型故障: 轴承松动、动静 碰摩、质量不平衡和轴系不对中.实验台在6个关键 截面处相互垂直方位上分别布置了12个电涡流传 感器,通过采集转子系统的振动信号,另在电机端安 置第13个通道的电涡流传感器用来拾取转速信号. 本研究实验数据选取驱动电机转速为2800r/min, 在采样频率为5000Hz采集振动信号.每种故障共 采集80组样本,其中前50作为训练样本,后30组 作为测试样本. 为从多个角度全面分析转子运行状 况,从振动信号时域、频域、时频域中提取不同的故 障特征量,如表1所示为1个通道的特征参数情况. 拓展至多通道,建立12个通道的混合特征集,即得 $12 \times 23 = 276$ 维高维故障数据集, 根据最大相关性 原则从 276 个特征集中筛出 110 个敏感特征, 作为 输入特征集.

表1 各通道故障特征参数

 Table 1
 Fault characteristic parameters of each channel

序号	特征名称	序号	特征名称
1	均方幅值	10	裕度指标
2	方根幅值	11	频率均值
3	平均幅值	12	频率中心
4	最大值	13	标准差频率
5	峰峰值	14	峭度频率
6	峭度	15	均方根频率
7	波形指标		前 4 层 IMF 分量
8	峰值指标	$16\sim 23$	的能量特征及对应
9	脉冲指标		的4层复杂度特征

将故障数据集经 KPCA-OLSDA 降维方法进行 处理,选取 PCA、KPCA、PCA-KOLSDA、KPCA-OLPP、KPCA-LSDA 6 种算法进行对比,并将 6 种 算法记为 A1, A2, A3, A4, A5, A6.为充分涵盖原 始数据集的本质信息,根据文献 [15],在本研究中选 取的目标维数为 3 维 (即 d = 3).研究中采用了五折 交叉验证方法选取最优高斯核参数,得到 KPCA、 KOLSDA 的最优高斯核参数分别为 $\theta = 137.5, 65.$ 实验从以下四个方面验证本文方法的有效性.

4.1 降维可视化与故障辨识结果对比

为验证本文降维方法的有效性, 将故障数据集 经 KPCA-OLSDA 等 6 种降维方法进行处理后,得 到降维后的测试样本三维特征量分布见图 2. 从图 2 可以看出,在三维视图描述情况下, PCA 的降维效果

赵孝礼等: 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



Fig. 2 The results of test sample based on different methods of dimension reduction

最差; KPCA-OLSDA 降维效果最好, 其降维后的各 故障类内距离小、类间间距明显. 二次降维方法的 聚合与分离程度明显好于 PCA、KPCA. 除 KPCA-OLSDA、KPCA-LSDA 外, 其他四种降维方法的各 故障间都存在着一定程度的交叉混叠, 其中不平衡 与碰磨降维效果最不理想.

4.2 计算降维效果衡量指标 Sb/Sw

为直观有效地可视化各类降维效果,将 Sw, Sb 及 Sb/Sw 作为评价指标,计算降维后测试样本的聚 类与分类指标,得到的评价结果见图 3.



图 3 各类降维方法的测试样本类问距、类内距及其比值 Fig. 3 The test samples' between-class scatter, within-class scatter and their ratio of all kinds of dimension reduction methods

故障诊断的实质是模式识别,为量化降维结果 将低维样本输入 KNN 分类器给出了测试样本的故 障诊断结果,见表 2. 结合图 3 和表 2 可知:

1) PCA 的降维效果及识别正确率最差,因为 PCA 不能有效处理非线性问题,容易丢失大量有用 信息; KPCA 降维效果及识别率一般,因为 KPCA 具有较强的全局非线性提取能力,但其局部保持信 息的能力较低.

2) 经 PCA 处理后的 KOLSDA 识别率及聚类 分类指标较差,因为经 PCA 处理后易丢失大量的利 于分类的信息,导致其降维效果不佳.

表 2 各降维方法的识别准确率 (%) Table 2 Methods of dimension reduction of recognition accuracy (%)

故障	各降维方法的故障诊断准确率					
类型	A1	A2	A3	A4	A5	A6
松动	1	0.667	1	1	1	1
碰磨	1	0.8	0.833	1	0.967	1
不对中	0.72	0.933	1	1	1	1
不平衡	0.62	1	0.867	0.8	1	1
识别准确率	0.835	0.85	0.925	0.95	0.992	1

3) 相对于 PCA 和 KPCA, 二次降维将原始特 征映射到全局非线性空间, 并在其子空间采用局部 结构保持的方法 OLPP、LSDA 和 OLSDA 进行二 次降维, 识别正确率都有所提升. 原因是 KPCA 能 够有效去除空间中的噪声与冗余信息, 并提取出能 够有效描述特征空间的最佳全局结构信息; 局部结 构保持的方法能提取出故障数据集中局部流形信息, 挖掘到具有高辨识力的低维特征.

4) KPCA-OLSDA 的降维效果及识别率要高 于 KPCA-OLPP 和 KPCA-LSDA, 因为 OLPP 无 监督模式导致其降维过程的盲目性, 而 OLSDA 能 够避免子空间重构更利于故障类别的划分, 降低了 后续故障识别压力. KPCA-OLSDA 具有较强的全 局与局部判别信息的挖掘能力, 比传统的降维方法 更能获得较高的故障识别精度.

4.3 兼顾提取信息与抗噪能力的验证

当训练样本不足时,局部信息比全局信息更为 重要;训练样本较多时,全局信息比局部信息更有价 值.为进一步验证 KPCA-OLSDA 方法兼顾提取全 局与局部判别信息的能力,采用交叉训练与测试样 本组合的方法.得出不同训练样本比例的上述6种 方法降维后的低维矢量在 KNN 中的识别结果,见 图 4 不同训练样本数对应的平均识别准确率 Fig. 4 The average recognition accuracy based on the different number of training samples

从图 4 可以看出,总体上 6 种降维方法的识别 准确率都随着训练样本数的增加而增加, KPCA-OLSDA 的稳定性能最好,推广适应能力较强,识别 准确率一直较高. PCA 和 KPCA 在少训练样本情 况下准确率下降明显;而二次降维方法整体下降不 明显,其中 KPCA-OLSDA 一直很稳定,基本不受 影响,表明其全局与局部判别信息的挖掘能力最强.

为验证本文方法优异的抗噪能力,将样本集混 入干扰系数为 g = 0.1, 0.3, 0.5, 1 的 4 种随机噪 声^[16],上述 6 类降维方法的 KNN 识别率如图 5 所 示.



Fig. 5 The average recognition accuracy of six kinds of algorithms under different random noise interference

从图 5 可以看出,随着噪声干扰系数的增加, 6 类降维算法的平均识别率总体都随之下降,而 KPCA-OLSDA 的识别率在不同的干扰情况下基本 不受影响. KPCA-OLSDA 表现出较稳定的抗噪能 力,其相应的鲁棒性较好.

4.4 复杂度和特征提取时间性能分析

为分析 KPCA-OLSDA 算法的性能, 从复杂度和特征提取时间两个方面进行.

复杂度是评价一个算法质量优劣的重要指标之一. 算法的时间复杂度影响因素主要有数据样本点数 n、初始数维数 d 和目标维数 m 等^[17-18].在所提算法中计算协方差矩阵需要 O(nd),对 n × n 矩阵进行特征分析,所需要的时间复杂度需要 O(pn²) (p 为稀疏矩阵中非零元素与零元素比值),

而 OLSDA、LSDA 等算法步骤中均涉及构造 k 近 邻图,该步骤时间复杂度最高为 O(dn^2),仅与样本 数 n 与初始维数 d 有关;计算邻接权重矩阵需要 O(n^2),计算核矩阵与核矩阵的特征分解需要时间复 杂度为 O(n^3).综合上述分析,列出相应的降维算法 时间复杂度,见表 3.

表 3 算法的时间复杂度

Table 3 Time complexity of all the algorithms

降维算法	时间复杂度
PCA	$O(d^3) + O(nd)$
KPCA	$O(d^3) + O(nd) + O(d^3)$
OLSDA	$\mathcal{O}(dn\log n) + \mathcal{O}(n^2) + \mathcal{O}(pn^2)$
PCA-KOLSDA	$\mathcal{O}(d^3) + \mathcal{O}(nd) + \mathcal{O}(dn\log n) + \mathcal{O}(n^2) + \mathcal{O}(pn^2)$
KPCA-OLPP	$\mathcal{O}(d^3) + \mathcal{O}(nd) + \mathcal{O}(d^3) + \mathcal{O}(dn\log n) + \mathcal{O}(n^2)$
KPCA-LSDA	$\mathcal{O}(d^3) + \mathcal{O}(nd) + \mathcal{O}(d^3) + \mathcal{O}(dn\log n) + \mathcal{O}(n^2)$
KPCA-OLSDA	$\mathcal{O}(d^3) + \mathcal{O}(nd) + \mathcal{O}(d^3) + \mathcal{O}(dn\log n) + \mathcal{O}(n^2)$

在实际问题中,初始样本维数 d > 样本数 n (即存在小样本问题)^[18].从表 3 可以看出, PCA, KPCA 等算法最高时间复杂度为 O(d³), PCA-KOLSDA, KPCA-OLPP, KPCA-LSDA, KPCA-OLSDA 等二次降维算法相对于传统全局降维算法 复杂度并没有增加,但是二次降维算法相对于局部 流形算法时间复杂度有所增加,这是在全局特征提 取过程中添加的.总体上 KPCA-OLSDA 算法在提 升降维效果与分类精度的同时复杂度有所增加,但 是在可以接受范围内.

表4 是在一台 Intel Corei5 CPU 2.3 Hz, RAM 2 GB 的 PC 机上进行的实验,操作系统 Windows 2007,通过 Matlab 2008a 软件计算 6 种方法降维 所需时间性能实验. 由表 4 可知, A6 即 KPCA-OLSDA 降维所需时间相对于 A1、A2、A3 等有一 定的时间牺牲,但是相对于识别率的提升,时间代价 有所增加,但都是一个数量级,所以是可以接受的. KPCA-OLSDA 降维方法的时间在 3.6 s 以内,算法 运行速度满足实时要求.

表 4 算法的特征提取时间 (s)

Table 4 Feature extraction time (s) for algorithms

降维数目	A1	A2	A3	A4	A5	A6
3	0.210	1.300	0.527	5.306	3.323	3.541
10	0.848	1.132	0.366	4.715	3.350	3.441
20	0.939	1.136	0.448	4.767	3.443	3.371
40	0.947	1.168	0.380	5.667	3.801	3.407
60	0.704	1.312	0.388	5.632	3.564	3.331
80	0.654	1.236	0.381	6.013	3.708	3.430

5 结论

为实现高维和非线性的复杂故障数据集的全局 与局部信息提取,通过融合降维方法进一步提升故

图 4.

障数据集的可视化程度与故障诊断识别精度,提出 一种 KPCA-OLSDA 相结合的故障数据集维数约 简故障分类辨识方法.该方法首先通过 KPCA 从高 维特征数据中提取全局非线性主元,然后在 KPCA 构造的低维子空间中应用 OLSDA 算法,实现局部 流形结构与判别信息的提取.双跨度转子实验台故 障模拟数据集的实验验证结果表明,与其他方法相 比,本文提出的 KPCA-OLSDA 方法具有更强的降 维能力和更高的故障识别精度.该方法可为旋转机 械高维和非线性故障数据集的全面、多层次的降维 工作与故障类别的可视化提供一种全新的解决方案.

References

- Ai Yan-Ting, Fei Cheng-Wei, Wang Zhi. Technique for diagnosing fault of rotor vibration based on improved fuzzy SVM. Journal of Aerospace Power. 2011, 26(5): 1118-1123 (艾延廷,费成巍, 王志. 基于改进模糊 SVM 的转子振动故障诊断 技术. 航空动力学报, 2011, 26(5): 1118-1123)
- 2 Xu Bin-Gang, Qu Liang-Sheng, Tao Xiao-Ming. Study on Bayesian diagnostic network of rotor fault. *Chinese Journal* of Mechanical Engineering. 2004, **40**(1): 66-72 (徐宾刚, 屈梁生, 陶肖明. 转子故障贝叶斯诊断网络的研究. 机械工 程学报, 2004, **40**(1): 66-72)
- 3 Li Yue-Xian, Han Zhen-Nan, Huang Hong-Chen, Ning Shao-Hui. Fault diagnosis of rotating machineries based on Laplacian eigenmaps. Journal of Vibration and Shock. 2014, **33**(18): 21-25 (李月仙, 韩振南, 黄宏臣, 宁少慧. 基于拉普拉斯特征映射的旋转机

(1) 加, 中战带, 莫公正, 19 点: 至于12 目上所有面或有可能不能 械故障识别. 振动与冲击, 2014, **33**(18): 21-25)

4 Su Zu-Qiang, Tang Bao-Ping, Liu Zi-Ran, Qin Yi. Fault diagnosis method based on orthogonal semi-supervised local Fisher discriminant analysis. *Chinese Journal of Mechanical Engineering*. 2014, **50**(18): 7–13 (苏祖强, 汤宝平, 刘自然, 秦毅. 基于正交半监督局部 Fisher 判别

分析的故障诊断. 机械工程学报, 2014, 50(18): 7-13)

- 5 Chen Fa-Fa, Tang Bao-Ping, Su Zu-Qiang. Rotating machinery fault diagnosis based on isometric mapping and weighted KNN. Chinese Journal of Scientific Instrument. 2013, **34**(1): 215-220 (陈法法,汤宝平,苏祖强. 基于等距映射与加权 KNN 的旋转机械 故障诊断. 仪器仪表学报, 2013, **34**(1): 215-220)
- 6 Zhang Mu-Guang, Song Zhi-Huan. LPMVP algorithm and its application to fault detection. Acta Automatica Sinica, 2009, **35**(6): 766-772
 (张沐光, 宋执环. LPMVP 算法及其在故障检测中的应用. 自动化

(示尔元, 末执环, LFMVF 异法及其在故厚检测中的应用, 自幼化 学报, 2009, **35**(6): 766-772)

- 7 Schölkopf B, Smola A, Müller K R. Kernel principal component analysis. Advances in Kernel Methods — Support Vector Learning, 2009, 27(4): 555–559
- 8 Guo Jin-Yu, Yuan Wei-Qi. Palmprint recognition based on kernel principal component analysis and fisher linear discriminant. Journal of Optoelectronics · Laser. 2008, 19(12): 1698-1701 (第金玉, 苑玮琦. 基干核主元分析和 Fisher 线性判别的掌纹识别.

(郭金玉, 宛玮琦, 基丁核土兀分析和 Fisher 线性判别的革纵识别, 光电子 · 激光, 2008, **19**(12): 1698—1701)

9 Cai D, He X, Zhou K, Han J, Bao H. Locality sensitive discriminant analysis. In: Proceedings of the 2007 International Joint Conference on Artificial Intelligence, Hyderabad, India: ACM, 2007. 708-713

- 10 Jin Y, Ruan Q, Wu J. Gabor-based orthogonal locality sensitive discriminant analysis for face recognition. Journal of Information Science, Engineering, 2009, 25(2): 419–433
- Wang Yun-Hong, Fan Wei, Tan Tie-Niu. Face recognition based on information fusion. *Chinese Journal of Comput*ers, 2005, **28**(10): 1657-1663 (王蕴红,范伟,谭铁牛. 融合全局与局部特征的子空间人脸识别算 法. 计算机学报, 2005, **28**(10): 1657-1663)
- Zhang Xue-Gong. Pattern Recognition. BeiJing: Tsinghua University Press, 2010. 146
 (张学工. 模式识别. 北京: 清华大学出版社, 2010. 146)
- 13 Li Juan, Wang Yu-Ping. A fast neighbor prototype selection algorithm based on local mean and class global information. Acta Automatica Sinica, 2014, 40(6): 1116-1125
 (李娟, 王宇平. 考虑局部均值和类全局信息的快速近邻原型选择算法. 自动化学报, 2014, 40(6): 1116-1125)
- 14 Huo Tian-Long, Zhao Rong-Zhen, Hu Bao-Quan. Fault diagnosis for rotor systems based on entropy Band method and support vector machine optimized by PSO. Journal of Vibration, Measurement, and Diagnosis, 2011, **31**(3): 279– 284

(霍天龙,赵荣珍,胡宝权.基于熵带法与 PSO 优化的 SVM 转子 故障诊断.振动、测试与诊断, 2011, **31**(3): 279-284)

- Wang Ze-Jie, Hu Hao-Min. On parameter selection in manifold learning algorithm. Computer Applications and Software, 2010, 27(6): 84-85, 102 (王泽杰, 胡浩民. 流形学习算法中的参数选择问题研究. 计算机应 用与软件, 2010, 27(6): 84-85, 102)
- 16 Chen F, Tang B, Chen R. A novel fault diagnosis model for gearbox based on wavelet support vector machine with immune genetic algorithm. *Measurement*, 2013, 46(1): 220– 232
- 17 Li Ya-Qian, Li Ying-Jie, Li Hai-Bin, Zhang Qiang, Zhang Wen-Ming. Fusion of global and local various feature for facial expression recognition. *Journal of Acta Optica Sinica*, 2014, **34**(5): 172–178 (李雅倩, 李颖杰, 李海滨, 张强, 张文明. 融合全局与局部多样性特 征的人脸表情识别. 光学学报, 2014, **34**(5): 172–178)
- 18 Zheng Jian-Wei, Wang Wan-Liang, Yao Xiao-Min, Shi Hai-Yan. Face recognition using tensor local Fisher discriminant analysis. Acta Automatica Sinica, 2012, **38**(9): 1485–1495 (郑建炜, 王万良, 姚晓敏, 石海燕. 张量局部 Fisher 判别分析的人 脸识别. 自动化学报, 2012, **38**(9): 1485–1495)



赵孝礼 兰州理工大学硕士研究生. 主要研究方向为旋转机械故障诊断. E-mail: m18893494840_2@163.com (**ZHAO Xiao-Li** Master student at Lanzhou University of Technology. His research interest covers rotating machinery fault diagnosis.)



赵荣珍 兰州理工大学教授. 主要研究 方向为旋转机械故障诊断, 机械系统动 力学. 本文通信作者.

E-mail: zhaorongzhen@lut.cn

(**ZHAO Rong-Zhen** Professor at Lanzhou University of Technology. Her research interest covers rotating machinery fault diagnosis and mechanical

system dynamics. Corresponding author of this paper.)