

转子故障特征数据分类的KPCA-BFDA方法*

马再超^{1,2}, 赵荣珍^{1,2}, 杨文瑛^{1,2}

(1. 兰州理工大学数字制造技术与应用省部共建教育部重点实验室 兰州, 730050)

(2. 兰州理工大学机电工程学院 兰州, 730050)

摘要 对非线性转子系统故障特征数据的分类方法进行了研究。在提出一种偏费歇判别分析法(biased fisher discriminatory analysis, 简称BFDA)的前提下, 进一步提出将核主成分分析法(kernel principal component analysis, 简称KPCA)与偏费歇判别分析法相结合的数据集降维方法, 该方法中的核主成分分析步骤用于构造剔除数据集冗余信息的降维数据集, 偏费歇判别分析步骤用于进一步降低数据集维数并提高不同类别数据子集间的分离程度。对实例数据与典型故障数据的分类结果表明, 提出的偏费歇判别分析法在具备费歇判别分析降维可分性能的基础上, 具有更低计算复杂度的特点。提出的核主成分分析结合偏费歇判别分析的算法, 其对应的降维结果能直接应用于线性分类器, 且取得了较好的分类效果。

关键词 故障特征数据集; 数据分类; 偏费歇判别分析; 核主成分分析

中图分类号 TH165; TP18

引言

旋转机械的状态监测系统是一类时刻产生大量监测信息的机械装备。随着多通道监测技术的广泛应用, 传统的信号处理方法难以满足全面描述转子运行状态的需求; 因此, 研究由多通道信号构建故障数据集对智能诊断技术的发展具有积极的促进作用。Schölkopf等^[1]提出的KPCA法是目前应用广泛的数据集降维方法之一, 但其作为非监督式学习方法, 对数据集降维的特点仅为最大化表征原始数据集的方差特性^[2-3], 未充分考虑不同类别子集间的分离程度, 因而影响了数据分类的准确性。FDA法是一种通过数据集降维, 使得不同类别数据子集间分离程度最大化, 进而实施线性分类的方法, 但其等同考虑两类数据离散度的重要性, 计算复杂度较高。若能将其改进为偏重分析一类数据离散度, 进而降低原始算法复杂度的形式, 并将该形式与KPCA法相结合, 则能为旋转机械故障特征数据集降维, 从而提高特征数据的分类能力。

本研究以转子系统典型故障振动信号构建的故障特征数据集为研究对象, 对BFDA法的构造及其与KPCA法的结合实现进行探讨, 为提高识别转子系统故障类别的能力提供参考依据。

1 基本概念

1.1 核主成分分析(KPCA)法

KPCA法是借助一种非线性映射函数 Φ , 将数据集 $X(X \in R^N)$ 投影至一个高维特征空间 $F = \{\Phi(X); X \in R^N\}$ 后, 进行主成分分析的方法。实现该方法的关键步骤是求解能够最大化表征原始数据集各特征方差特性的投影方向 V , 其计算式^[1-5]为

$$\lambda V = \bar{C}V \quad (1)$$

其中: \bar{C} 为矩阵 $\Phi(X)$ 的协方差矩阵; λ 为特征值。

可得出原始数据在 V 方向的投影^[1-5]计算式为

$$(V^k \Phi(x)) = \sum_{i=1}^M \alpha_i^k (\Phi(x_i) \Phi(x)) \quad (2)$$

其中: α_i^k 为相关系数; $\Phi(x)$ 为特征空间中的样本。

1.2 费歇判别分析(FDA)法

FDA法是通过一种借助线性映射关系将高维空间中的数据集投影至低维空间后, 进行线性分类的方法。在仅考虑两类数据分类问题的情形下, 实现该方法的关键是获取最大化两类数据差异性的投影方向, 其计算方法为求解使式(3)中的 $J(\alpha)$ 值达到极大值的向量 α ^[6]

* 国家自然科学基金资助项目(50875118, 51165019); 甘肃省教育厅硕士基金资助项目(0903-11)

收稿日期: 2011-12-29; 修改稿收到日期: 2012-03-01

$$J(\alpha) = (\alpha^T \mathbf{S}_B \alpha) / (\alpha^T \mathbf{S}_W \alpha) \quad (3)$$

其中: \mathbf{S}_B 为类间离散度矩阵; \mathbf{S}_W 为类内离散度矩阵。

原空间数据在 α 方向投影的计算式^[6]为

$$\alpha(\mathbf{x}) = \alpha \mathbf{x} \quad (4)$$

其中: \mathbf{x} 为原空间数据。

1.3 两类数据的线性分类法

设 m_i 为第 i 类数据 $\mathbf{X}_i = \{x_{i1}^1, x_{i1}^2, \dots, x_{i1}^{l_i}, i=1,2\}$ 的均值向量,其计算式为

$$m_i = \frac{1}{l_i} \sum_{j=1}^{l_i} x_j^i \quad (5)$$

得到第 i 类数据在 u 方向的投影 u_i 为

$$u_i = u m_i \quad (6)$$

其中: u 为已确定的数据投影方向。

因此,将判别两类数据的条件定义为两类数据在 u 方向投影的算数平均值 \bar{u}

$$\bar{u} = (u_1 + u_2) / 2 \quad (7)$$

因此,未知样本 y 的判别规则^[6]如下:设 $u_1 \leq u_2$,若 $u y \leq \bar{u}$,则 y 属于第1类;否则 y 属于第2类。

2 KPCA-BFDA 数据降维与分类算法设计

2.1 偏费歇判别分析(BFDA)法

参考BDA法^[7],BFDA法是在不改变类间离散度矩阵的基础上,用样本较多类数据的离散度矩阵代替类内离散度矩阵的方法。相对于FDA法,该方法计算投影方向的过程更简洁,且得到的投影方向具有以最大化样本较多类数据集中程度的方式,达到最大化两类数据差异性效果的特点。

数据集的类间离散度矩阵 \mathbf{S}_B 的计算方法为

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \quad (8)$$

其中: $\mathbf{m}_1, \mathbf{m}_2$ 分别为两类数据样本的算术平均值。

数据集的类内离散度矩阵 \mathbf{S}_W 的计算方法为

$$\mathbf{S}_W = \sum_{i=1}^2 \sum_{j=1}^{n_i} (\mathbf{x}_j^i - \mathbf{m}_i)(\mathbf{x}_j^i - \mathbf{m}_i)^T \quad (9)$$

其中: n_i 为第 i 类数据的样本数量; \mathbf{x} 为原空间数据。

令

$$\mathbf{S}_{W1} = \sum_{i=1}^{n_1} (\mathbf{x}_i^1 - \mathbf{m}_1)(\mathbf{x}_i^1 - \mathbf{m}_1)^T \quad (10)$$

其中: n_1 代表较多的样本数量。

求解使式(12)中的 $J(\beta)$ 值达到极大值的向量

β ,即为最大化两类数据差异性的投影方向

$$J(\beta) = (\beta^T \mathbf{S}_B \beta) / (\beta^T \mathbf{S}_{W1} \beta) \quad (11)$$

得到原空间数据在 β 方向投影的计算方法为

$$\beta(\mathbf{x}) = \beta \mathbf{x} \quad (12)$$

2.2 KPCA和BFDA法的降维组合设计

1) 按照式(2)对数据集在 V 方向进行投影变换,选取可用特征,组成一次降维数据集;

2) 按照式(12)对一次降维数据集在 β 方向投影变换,选取可用特征,组成二次降维数据集,即为KPCA-BFDA法的降维结果。

定义KPCA-BFDA法的特征值贡献率和累计率计算方法如下:设步骤1中,选取特征的总累计贡献率以 Λ 表示,步骤2中,所有特征值以 $\tau_1, \tau_2, \dots, \tau_n$ 表示,则任意特征值 τ_k 的贡献率 ω_k 的计算式为

$$\omega_k = (\tau_k / \sum_{i=1}^n \tau_i) \Lambda \quad (13)$$

式(13)描述了特征 k 所含信息占总信息的份额。

选取的前 m 个特征贡献率之和称为累计率,记为 Ω_m ,其计算式为

$$\Omega_m = (\sum_{i=1}^m \tau_i / \sum_{i=1}^n \tau_i) \Lambda \quad (14)$$

式(14)表明了前 m 个特征能够提供原始数据集中所含信息的能力。

应用KPCA-BFDA法实施数据集降维时,选取的前 $m(m < n)$ 个特征,其累计率达到80%以上即可。

2.3 核的确定

2.3.1 核函数的选择

按照目前应用最为成熟的核函数^[8-11]并结合本研究的实际应用情况,选择高斯核函数为

$$K(x_i, y_j) = \exp(-\|x_i - y_j\|^2 / 2\sigma^2) \quad (15)$$

2.3.2 核参数的求解

参考基于费歇准则的粒子群优化方案^[8-9],本研究提出以偏费歇准则建立粒子群优化算法的目标函数,实施高斯核函数中参数 σ 的自动寻优方法。

样本数较多的数据子集在高维特征空间中的类内离散度的平方为

$$S_{\omega 1}^{\Phi} = \sum_{i=1}^{n_1} k(x_{1i}, x_{1i}) - \frac{1}{n_1} \sum_{i=1}^{n_1} \sum_{j=1}^{n_1} k(x_{1i}, x_{1j}) \quad (16)$$

两类数据在特征空间中的类间离散度平方为

$$S_b^{\Phi} = \frac{1}{n_1^2} \sum_{i=1}^{n_1} \sum_{j=1}^{n_1} k(x_{1i}, x_{1j}) - \frac{2}{n_1 n_2} \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} k(x_{1i}, x_{2j}) + \frac{1}{n_2^2} \sum_{i=1}^{n_2} \sum_{j=1}^{n_2} k(x_{2i}, x_{2j}) \quad (17)$$

所建立的目标函数为

$$J(\theta) = S_{a1}^{\phi} / S_b^{\phi} \quad (18)$$

其中： θ 为目标函数 $J(\theta)$ 的极小值点。

2.4 线性分类器结构设计

针对本研究中多类数据的分类问题,可采用一对多分类方法^[12-13],并将其拓展为适用于识别转子系统各类典型故障的分类器结构,如图1所示。




图1 线性多分类器

建立对应 n 种类型的 n 个两类分类器,将这些分类器按图1所示的二叉树形式组合,从而得到1个可以分离 n 种数据类型的多分类器。当测试样本输入到此多分类器时,若经过第1个分类器的判别结果为类型1,则此次判别过程结束,否则送入第2个分类器继续判别。依此类推,直到第 n 个分类器,若仍未得出类型 n 的判别结果,则测试样本属于其他数据类型,从而可解决多类数据的分类问题。

2.5 故障诊断流程设计

本研究规划的转子系统故障诊断流程如图2所示。整个过程的实施步骤如下:

- 1) 采集转子系统典型故障的振动信号;
- 2) 提取振动信号特征,建立故障特征数据集;
- 3) 将故障特征数据集划分成训练集和测试集;
- 4) 针对各二分类问题,确定对应的核函数;
- 5) 运用KPCA-BFDA法对故障特征数据集进行降维分析;
- 6) 将训练集降维结果按照两类数据的线性分

类法设计图1所示的线性多分类器;

- 7) 将测试集降维结果输入多分类器,得出结论。

3 应用情况分析

首先,采用实例数据集验证BFDA法;然后,采用转子实验台振动信号验证KPCA-BFDA。

3.1 BFDA法的实例降维


采用的实例数据集参见文献[6]。分别应用BFDA法和FDA法对实例数据集进行降维分析,降维后不同类别数据子集的分离效果如图3所示。表1列出了实例数据集中样本回报的判别准确程度。

整体比较图3可见,指定类数据(图中标记为“x”)在图3(a)中表现出的结构比在图3(b)中的结构更为紧致,且图中不同类别数据的分离程度都非常显著,说明BFDA法更趋向于以提高指定类别数据集中程度的方式,实现不同类别数据的分离。


由表1可见,BFDA法对应的回归结果中,I类错判数为2,II类错判数为1,这与FDA法对应的回归结果差别不大,且两种算法对应的总判错数均为3,由此验证了图3显示的数据可分性效果。

表1 两种方法判别准确程度对比

类别	BFDA		FDA	
	I	II	I	II
I	10	2	11	1
II	1	22	2	21
总判错数	3		3	



(a) BFDA分离效果



(b) FDA分离效果

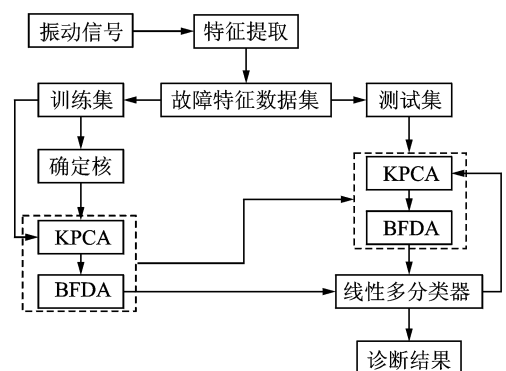


图2 转子系统故障诊断流程图

图3 实例数据集降维效果图

3.2 KPCA-BFDA 法的故障特征数据集降维与分类

首先,在文献[12]所示转子实验台进行升降速实验,采集转子动静碰摩、质量不平衡、支座松动、轴系不对中及正常这5种转子运行状态的振动信号;然后,按图2所示流程的步骤2,计算1~12通道每次采样的振动峰峰值、振动最大值和振动均方根值,共36个特征。取5种转子运行状态的样本数各80,样本总数为400,建立故障特征数据集,如表2所示。

表2 故障特征数据集 μm

状态	编号	通道1			通道2		
		峰峰值	最大值	均方根	峰峰值	最大值	均方根
碰摩	1	109.86	51.13	30.90	100.10	53.36	28.38
	2	117.19	56.01	32.48	104.98	58.24	31.52
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	80	139.57	60.33	39.17	122.07	48.19	30.02
不平衡	1	117.19	58.42	37.21	122.07	58.01	36.30
	2	112.30	55.98	37.17	114.75	55.57	35.29
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	80	110.87	58.04	35.90	102.32	55.98	33.99
松动	1	114.75	59.85	36.67	109.86	56.09	33.78
	2	107.42	52.52	32.53	107.42	56.09	33.32
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	80	103.93	56.91	34.03	102.92	53.35	32.41
不对中	1	103.08	60.73	33.05	136.72	70.65	41.45
	2	107.95	61.75	34.70	117.19	60.89	36.04
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	80	125.08	60.92	40.45	122.08	67.59	39.66
正常	1	107.42	53.86	33.99	102.54	55.31	32.65
	2	114.75	61.19	34.08	102.54	52.87	33.65
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	80	114.75	55.93	33.16	114.23	66.54	37.34

由表2可看出,不同运行状态对应的同一特征表现出数值区间严重重叠的现象。如通道1峰峰值中的碰摩故障区间(109.86~139.57 μm)包含了不平衡故障区间(110.87~117.19 μm),故仅简单地将测试信号的特征提取结果和表2进行对比来决策故障,则可能造成错判,甚至无法判别。

3.3 故障特征数据集的降维

按照图2所示流程的步骤3~5,首先,将故障特征数据集中各子类的1~40号样本组成训练集,41~80号样本组成测试集;然后,参照文献[12]建立4种二分类问题,并确定各分类问题的核函数;最后,得出KPCA-BFDA法对故障特征数据集的降维分析结果。得出的最优核参数 σ 及按照从大到小顺序排列的测试子集降维结果如表3所示。

表3 KPCA-BFDA 法的最优核参数及无量纲降维结果

	分类问题1	分类问题2	分类问题3	分类问题4
σ	5.985 8	6.293 5	6.237 3	6.030 8
碰摩	0.031 732			
	0.030 295			
	⋮			
	-0.049 634			
不平衡	0.057 845	-0.024 749		
	0.057 662	-0.024 926		
	⋮	⋮		
	0.030 913	-0.045 107		
松动	0.060 373	-0.000 210	-0.001 095	
	0.059 727	-0.001 175	-0.006 149	
	⋮	⋮	⋮	
	0.034 302	-0.013 291	-0.028 179	
不对中	0.060 596	-0.006 051	0.037 448	0.058 618
	0.059 797	-0.006 604	0.036 882	0.015 178
	⋮	⋮	⋮	⋮
	0.006 374	-0.024 090	0.009 493	-0.018 829
正常	0.062 672	0.003 826	0.036 953	-0.026 606
	0.062 531	0.002 462	0.031 015	-0.027 435
	⋮	⋮	⋮	⋮
	0.031 253	-0.017 028	0.008 913	-0.048 364

由表3可看出,不同分类问题对应的最优核参数 σ 不同,因而产生了不同的投影方向。各投影方向对应的测试子集,其降维结果均为可分性较强的一维特征向量。以分类问题2为例,不平衡故障的特征值区间是-0.045 107~-0.024 749,而非不平衡状态的特征值区间是-0.024 090~0.000 210,两种区间未发生重叠,且分类问题3和分类问题4也表现出相同的差异性。分类问题1中,仅不平衡、不对中和正常状态的最小值,即0.030 913,0.006 374和0.031 253同属于碰摩故障的区间(-0.049 634~0.031 732)内。故可以说明,采用KPCA-BFDA法对故障特征数据集降维的结果中,不同故障类别间的差异性可由无量纲数据的数值大小关系直接表现。对比表2中的数据可知,这种数值大小的差异性已经具备了分离不同类别故障数据的能力。

为进一步说明KPCA-BFDA法的优越性,列出测试集降维过程中的特征值、贡献率和累计率,与测试集实施KPCA-FDA,KPCA降维法得到的以上3种指标进行对比,结果如表4所示。

由表4可以发现,碰摩故障分类问题对应的测试子集经KPCA-BFDA法降维后,第1特征的贡献率为86.07%,与KPCA-FDA法所对应第1特征的贡献率相同,且基本达到了KPCA法对应的总累计率(86.08%),而第2、第3和第4特征的贡献率分别

表4 KPCA-BFDA, KPCA-FDA 和 KPCA 法的测试集降维特征贡献分布

状态	KPCA-BFDA			KPCA-FDA			KPCA		
	特征值	贡献率/%	累计率/%	特征值	贡献率/%	累计率/%	特征值	贡献率/%	累计率/%
碰撞	16.001 1	86.07	86.07	1.110 8	86.07	86.07	0.161 7	30.93	30.93
	1.80×10^{-16}	1.17×10^{-15}	86.07	2.22×10^{-16}	2.00×10^{-16}	86.07	0.150 4	28.77	59.70
	1.80×10^{-16}	1.17×10^{-15}	86.08	1.39×10^{-17}	1.25×10^{-17}	86.07	0.091 2	17.45	77.15
	0	0	86.08	6.07×10^{-18}	5.47×10^{-18}	86.08	0.046 7	8.93	86.08
不平衡	2.910 6	88.74	88.74	$0.917 6 \times 10^{-18}$	88.74	88.74	0.089 2	61.32	61.32
	4.65×10^{-17}	1.60×10^{-15}	88.74	4.79×10^{-17}	5.22×10^{-17}	88.74	0.015 7	10.79	72.12
	1.63×10^{-19}	5.59×10^{-17}	88.75	4.55×10^{-20}	4.96×10^{-20}	88.75	0.013 7	9.42	81.54
	0	0	88.75	0	0	88.75	0.010 5	7.22	88.75
松动	6.988 5	93.20	93.20	1.910 2	93.20	93.20	0.091 5	58.94	58.94
	-1.03×10^{-16}	1.48×10^{-15}	93.21	8.30×10^{-17}	4.35×10^{-17}	93.20	0.041 4	26.67	85.60
	-3.89×10^{-16}	9.28×10^{-18}	93.21	1.28×10^{-19}	6.71×10^{-20}	93.21	0.007 5	4.83	90.43
	-6.49×10^{-19}	5.56×10^{-15}	93.21	0	0	93.21	0.004 3	2.77	93.21
不对中	8.297 5	82.39	82.39	1.310 8	82.39	82.39	0.035 7	37.62	37.62
	2.08×10^{-17}	2.51×10^{-16}	82.39	8.98×10^{-18}	6.85×10^{-18}	82.39	0.026 5	27.92	65.54
	9.54×10^{-19}	1.15×10^{-17}	82.40	-5.61×10^{-19}	4.28×10^{-19}	82.40	0.008 7	9.17	74.71
	0	0	82.40	0	0	82.40	0.007 3	7.69	82.40

为 $1.17 \times 10^{-15} \%$, $1.17 \times 10^{-15} \%$ 和 0% , 与 KPCA-FDA 法对应特征贡献率的数量级差别不大, 表明此类特征包含的信息量极少。不平衡、松动和不对中故障的分类问题, 也都表现出上述特性。另外, KPCA 法对应的所有特征中, 虽然不平衡故障的第 1 特征具有最大贡献率, 但仅为 61.32% , 表明该特征仍需结合其他特征, 形成二维以上的数据集后, 才能描述原始数据集的大部分信息。由此说明, KPCA-BFDA 法和 KPCA-FDA 法对数据集的降维结果差异不大, 均具备了表征原始数据集大部分分类信息的能力, 且其维数低于 KPCA 法对应的降维结果。

3.4 故障特征数据的分类

按照图 2 所示流程的步骤 6 和 7, 采用 KPCA-BFDA 法所对应训练集降维结果的第 1 特征训练线性多分类器, 并应用于测试集降维结果的分类。另将 KPCA-FDA 法对应的第 1 特征和 KPCA 法对应的前 4 个特征实施相同的训练与测试过程, 得出分类结果的对比情况如表 5 所示。

由表 5 可以看出, KPCA-BFDA 法对应的各第 1 特征, 应用于线性分类的准确率均超过 95% , 且松动和不对中问题的分类准确率略高于 KPCA-FDA 法对应的准确率。在 KPCA 法对应的所有特征中, 不平衡故障的第 3 特征具有最高的分类准确率, 为 83.75% , 但该特征对应表 4 中的贡献率仅为 9.42% , 表明其在原始信息中占有的份额低, 因此不能说明该特征能够应用于分类。另外, KPCA 法对应的各分类问题中, 碰撞的第 1 特征虽然具有最高的分类准确率, 但仅为 22% , 甚至还出现松动问题分

表5 KPCA-FDA 和 KPCA 法的降维特征线性分类结果

状态	KPCA-BFDA		KPCA-FDA		KPCA	
	特征号	准确率/%	特征号	准确率/%	特征号	准确率/%
碰撞	1	95.00	1	95.00	1	22.000
					2	51.000
					3	67.500
					4	41.000
不平衡	1	96.88	1	96.88	1	54.375
					2	14.375
					3	83.750
					4	44.375
松动	1	100.00	1	99.17	1	0
					2	58.330
					3	62.500
					4	60.000
不对中	1	100.00	1	97.50	1	2.500
					2	46.250
					3	66.250
					4	50.000

类准确率为 0% 的情况。上述结果表明, KPCA-BFDA 法是在达到 KPCA-FDA 法的降维可分性效果的前提下, 具备了更低的算法复杂度。KPCA-BFDA 法较 KPCA 法, 获取的降维数据集不仅具有更低的维数, 还使不同数据子集间具备更高的分离程度; 而 KPCA 法对应的降维结果, 虽然能够最大化表征原始数据集的方差特性, 但可分性较差, 不能直接应用于线性分类。为加强特征的可分性对比, 根据表 4 所示的降维特征贡献分布, 采用 KPCA-BFDA 法和 KPCA-FDA 法对应的第 1 特征作为一维空间的 x 坐标, 建立两种一维判别模型; 采用 KPCA 法对应的前 3 个特征, 分别作为三维空间的 x, y 和 z 坐标, 建立三维判别模型。3 种模型的可分性如图 4 所示

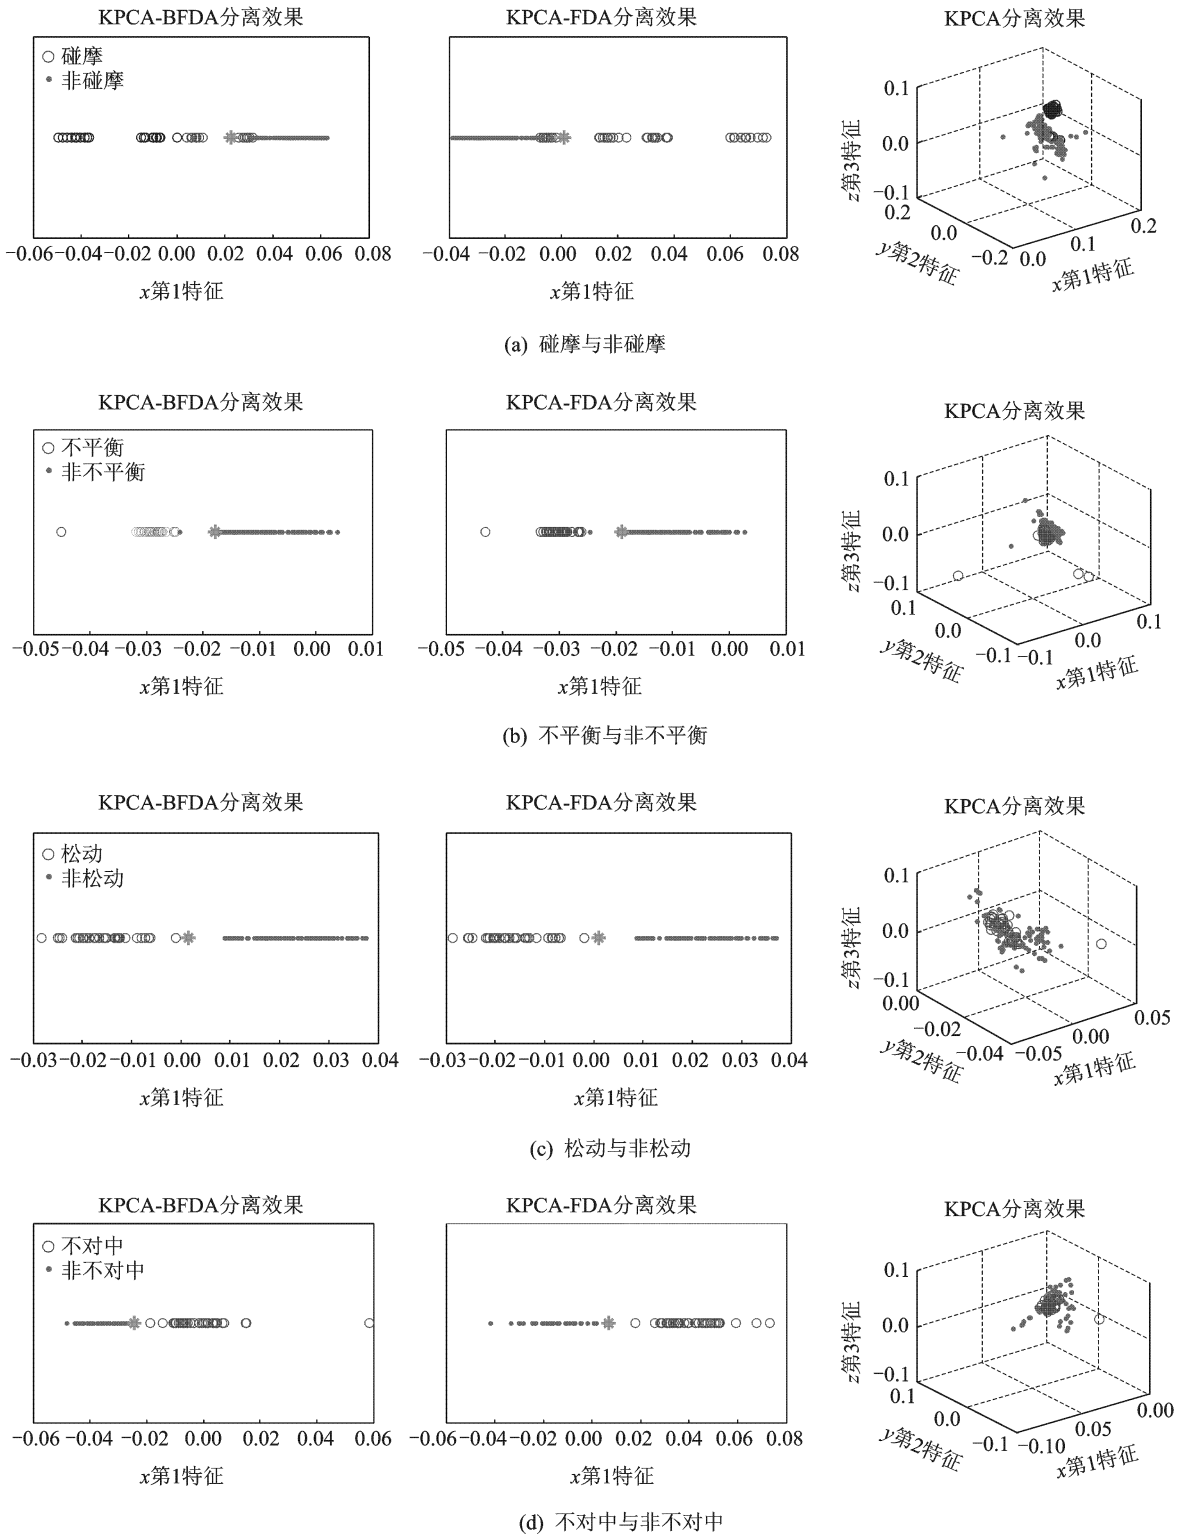


图4 测试样本分类效果图

图4给出了4类故障分类问题的测试子集分别采用KPCA-BFDA法、KPCA-FDA法和KPCA法降维后,3种降维结果的可分性效果。从图中可直观看出,KPCA-BFDA法对应的一维降维结果对4类故障的分离效果都非常显著,且该结果与KPCA-

FDA法对应的结果差别不大。在碰摩和不对中问题中,KPCA-BFDA法对应的降维结果则从整体上明显表现出指定类数据(标记为“.”)更为紧密的结构。KPCA法对应的三维降维结果中,仅碰摩故障的分离效果较明显,其余几种故障类型则表现出严重的


混叠现象。由此说明,相对于 KPCA-FDA 法和 KPCA法,KPCA-BFDA 法具有明显优势,即在以最低维数的数据集最大化表征故障特征数据集分类信息的前提下,具有最低的计算复杂度。

4 结束语

为提高转子故障特征数据的分类能力,本研究提出了一种偏费歇判别分析法,将核主成分分析与偏费歇判别分析相结合,用于故障特征数据集的降维。实例研究与实验研究分别表明,提出的BFDA 算法是在达到FDA 法降维性能的前提下,具有更低的计算复杂度;提出的KPCA-BFDA 算法,在以较低维数的数据集最大化表征故障特征数据集分类信息的同时,具有较低的计算复杂度,且获得的降维结果能直接应用于线性分类器,分类准确率高。

参 考 文 献

- [1] Schölkopf B, Smola A, Müller K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. *Neural Computation*, 1998(10):1299-1319.
- [2] 李巍华, 史铁林, 杨叔子. 基于非线性判别分析的故障分类方法研究[J]. *振动工程学报*, 2005, 18(2):133-138.
Li Weihua, Shi Tielin, Yang Shuzi. Mechanical fault classification using Nonlinear discriminant analysis [J]. *Journal of Vibration Engineering*, 2005, 18(2): 133-138. (in Chinese)
- [3] 李巍华. 基于核方法的机械故障特征提取与分类技术研究[D]. 武汉:华中科技大学, 2003.
- [4] Shawe T J, Cristianini N. Kernel methods for pattern analysis [M]. Cambridge: Cambridge University Press, 2004:143-151.
- [5] 胡金海, 谢寿生, 侯胜利, 等. 核函数主元分析及其在故障特征提取中的应用[J]. *振动、测试与诊断*, 2007, 27(1):48-52.
Hu Jinhai, Xie Shousheng, Hou Shengli, et al. Kernel principal component analysis and its application to fault feature extraction [J]. *Journal of Vibration, Measurement & Diagnosis*, 2007, 27(1): 48-52. (in Chinese)
- [6] 张尧庭, 方开泰. 多元统计分析引论[M]. 北京:科学出版社, 2003:178.
- [7] Zhou X, Huang T S. Small sample learning during multimedia retrieval using biasmap[C]// IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Kauai, Hawaii, USA: [s. n.], 2001.
- [8] 何学文. 基于支持向量机的故障智能诊断理论与方法研究[D]. 长沙:中南大学, 2004.
- [9] 魏秀业, 潘宏侠, 王福杰. 基于粒子群优化的核主元分析特征的提取技术[J]. *振动、测试与诊断*, 2009, 29(2):162-166.
Wei Xiuye, Pan Hongxia, Wang Fujie. Feature extraction based on kernel principal component analysis optimized by particle swarm optimization algorithm [J]. *Journal of Vibration, Measurement & Diagnosis*, 2009, 29(2):162-166. (in Chinese)
- [10] Bozdogan H, Camillo F, Liberati C. On the choice of the kernel function in kernel discriminant analysis using information complexity[J]. *Data Analysis, Classification and the Forward Search*, 2006, 34:11-21.
- [11] Xu Yong, Liu Chuancui, Zhang Chongyang. Determine the kernel parameter of KFDA using a minimum search algorithm[J]. *Lecture Notes in Computer Science*, 2007(4682):418-426.
- [12] 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[J]. *振动、测试与诊断*, 2011, 31(3):279-284.
Huo Tianlong, Zhao Rongzhen, Hu Baoquan. Fault diagnosis for rotor systems based on entropy band method and support vector machine optimized by PSO [J]. *Journal of Vibration, Measurement & Diagnosis*, 2011, 31(3):279-284. (in Chinese)
- [13] 于德介, 陈森峰, 程军圣, 等. 一种基于经验模式分解与支持向量机的转子故障诊断方法[J]. *中国电机工程学报*, 2006, 26(16):162-167.
Yu Dejie, Cheng Miaofeng, Cheng Junsheng, et al. A fault diagnosis approach for rotor systems based on empirical mode decomposition method and support vector machines [J]. *Proceeding of the CSEE*, 2006, 26(16):162-167. (in Chinese)



第一作者简介:马再超,男,1986年8月生,硕士研究生。主要研究方向为旋转机械的状态监测与故障诊断。
E-mail:mazaichao@163.com