

文章编号: 1000-8055(2008)07-1346-07

基于粗糙核 Fisher 鉴别分析的特征提取及其在 发动机故障诊断中的应用

胡金海, 谢寿生, 汪 诚, 李应红, 杨 帆
(空军工程大学 工程学院, 西安 710038)

摘 要: 将粗糙集理论的属性约简与核 Fisher 鉴别分析方法结合起来, 提出一种基于粗糙核 Fisher 鉴别分析的故障特征提取方法. 首先采用粗糙集理论的属性约简删除与分类无关或关系不大的特征, 降低输入特征维数, 排除干扰特征的影响, 减小了特征提取计算量; 再采用核 Fisher 鉴别分析方法进一步提取非线性特征; 最后将该方法应用于航空发动机滑油系统故障特征提取及故障识别中. 结果表明: 该方法获取的特征在提高分类正确率的同时, 还有效地降低了输入特征维数, 提高了分类效率, 并且对分类器具有较强的适应性和鲁棒性.

关 键 词: 航空发动机; 故障诊断; 特征提取; 粗糙集; 核 Fisher 鉴别分析

中图分类号: V263. 6

文献标识码: A

Feature extraction based on rough kernel Fisher discriminant analysis and its application on aeroengine fault diagnosis

HU Jin-hai, XIE Shou-sheng, WANG Cheng, LI Ying-hong, YANG Fan
(The Engineering Institute, Air force Engineering University, Xi'an, 710038, China)

Abstract: A new approach based on rough kernel fisher discriminant analysis (RKFDA) was proposed for aeroengine fault feature extraction, which combined rough set and kernel Fisher discriminant analysis. Firstly, rough set was used to exclude the features irrelevant to the fault; reduce the dimension of features, remove the effect of disturbance characteristics and cut down the cost of computation. Secondly, kernel Fisher discriminant analysis was employed on the obtained subset of features to extract the nonlinear features. Finally, fault extraction and recognition experiments in aeroengine lubricating oil system were carried out to test the performance of this method. The results show that the extracted features based on the proposed method could improve the recognition for aeroengine fault, and reduce efficiently the dimension of features with strong adaptability and robustness for various classifiers.

Key words: aeroengine; fault diagnosis; feature extraction; rough set; kernel Fisher discriminant analysis

特征提取是模式识别中最基本的问题之一, 提取有效的特征是解决模式识别问题的关键. 而航空发动机故障诊断过程本质上也是一个模式识别的过程, 构造出优质的诊断特征也是提高其诊

断效率及其准确性的关键. 因此在进行发动机故障诊断之前, 必须通过一定的方法进行特征提取, 从不同角度获取最敏感、最有用的特征信息.

为此, 研究人员给出了多种特征提取方法, 例

收稿日期: 2007-06-18; 修订日期: 2007-10-09

基金项目: 国家自然科学基金(60672179); 军队重点科研基金(2003 KJ01705)

作者简介: 胡金海(1978-), 男, 江西上饶人, 讲师, 博士, 研究方向为航空发动机状态监控与故障诊断.

如主元分析(PCA)、Fisher 线性鉴别分析(FDA)及其有关推广.然而,PCA、FDA 都是基于线性投影(变换)的特征提取方法,提取得到的都是线性特征.这对于复杂的非线性分布结构的分类问题时,其结果通常不能令人满意^[1].因此,有必要研究非线性特征提取方法.基于核的非线性特征提取方法,例如核主元分析(KPCA)、核 Fisher 鉴别分析(KFDA),不仅特别适合于处理非线性问题,且能提供更多的特征信息,提取的特征的识别效果更优^[1-2].但是由于 KPCA 提取特征时没有充分考虑到类别信息,故其提取的特征分类效果要差于 KFDA 所提取的特征^[3].为此,本文只研究采用 KFDA 方法进行特征提取.

另外在原始特征集中,也并不是所有的特征都能有效地表征故障信息,反映系统的工作状态,并且这些无关特征有时还可能成为干扰特征,影响对系统工作状态的判断^[4].

然而,不论是线性的 PCA、FDA 还是基于核的 KPCA、KFDA 都存在一个不足:那就是不能在特征提取之前,事先删除与分类无关的输入特征,从而排除干扰特征的影响,使最终提取的特征效果更佳.

粗糙集理论(RS)的属性约简是其核心内容之一.它不需要事先预知额外信息,能在保持知识库分类能力不变的条件下,剔除其中不相关或不重要的属性(特征),以使知识简化^[5].

综上所述,将粗糙集的属性约简与基于核理论的 KFDA 特征提取方法结合起来,是一个可以考虑的研究思路.首先对所有输入特征进行约简,提前删除次要的或与分类无关的特征,然后对保留的特征再运用 KFDA 进行特征提取,最终有望使提取的特征具有最强的分类能力,提高分类性能和速度,有助于提高故障诊断的实时性.

本文把粗糙集理论和核 Fisher 鉴别分析相结合进行特征提取的方法称为粗糙核 Fisher 鉴别分析(Rough kernel Fisher discriminant analysis, RKFDA).

1 粗糙核 Fisher 鉴别分析(RKFDA)

1.1 粗糙集理论的属性(特征)约简

人类在对某个事物作出判断和决策时,所依据的往往不是被判断事物的全部属性,而是最主要的一个或几个重要属性.属性约简就是根据这一原理,在保持知识库分类能力不变的条件下,剔除其中不相关或不重要的信息,以使知识简化.

本文不对 RS 理论进行详细介绍,只介绍有关粗糙集的属性约简方面的知识.

1.1.1 约简和核

在工程应用中,经常要在保持知识库中初等范畴的情况下,消去冗余基本范畴,进行属性的约简,完成属性约简的基本工作是利用约简和核来进行的.

令 R 为一等价关系族,且 $r \in R$,当 $IND(R) = IND(R - \{r\})$ 称 r 为 R 中可省略的,否则 r 为 R 中不可省略的.当对于任一 $r \in R$,若 R 不可省略,则族 R 为独立的.当 R 独立的,且属性子集 $P \subseteq R$,则 P 也是独立的.当 Q 独立,且 $IND(Q) = IND(P)$, $Q \subseteq P$ 为 P 的约简,记为 $RED(P)$.显然 P 可以有许许多多约简. P 中所有不可省略关系的集合,称为 P 的核,记为 $CORE(P)$.

$$CORE(P) = \bigcap RED(P) \quad (1)$$

从式(1)可以看到,核是属性约简时不能消去的知识特征部分的集合,值得注意的是核可能为空.根据核的定义,核保留了在进行属性约简时不能消去的知识特征,所以核可以作为所有简化的计算基础.

对于实际的属性约简问题,属性集往往是比较庞大的,且其核可能为空集,如何求出属性集的最小子集是模式识别问题研究的难点,因为该问题实际上是一个 NP 难题,即求解问题所需的时间与问题的规模成指数关系^[6].

人工智能的理论知识与实践经验给人们以启示,解决 NP 问题的最有效途径是采用某一种形式的启发式搜索策略.为此,本文采用基于启发式知识的属性约简算法^[7].

1.1.2 基于启发式知识的属性约简

首先,需要定义适合解决分类问题的启发式函数.

设讨论的对象可分为 N 类,共包含 L 个样本.每个样本可用一 M 维向量来描述,即 $(X_1, y_1), (X_2, y_2), \dots, (X_L, y_L)$. 对各样本 $X_i \in R^M, y_i \in \{1, 2, \dots, N\}, i = 1, 2, \dots, L$. 用 $Y_i, i = 1, 2, \dots, N$ 表示第 i 类样本的集合,样本个数为 $L_i, L = \sum_{i=1}^N L_i$. 用 m_{ij} 表示第 i 类样本第 j 分量的均值,有

$$m_{ij} = \frac{1}{L_i} \sum_{X_k \in Y_i, k=1}^{L_i} X_{kj} \quad (2)$$

式(2)中, $i = 1, 2, \dots, N; j = 1, 2, \dots, M$.

用 S_{ij} 表示第 i 类样本第 j 分量的类内散度,

有

$$S_{ij} = \frac{1}{L_i X_k} \sum_{j=1}^{L_i} (X_{kj} - m_{ij})^2 \quad (3)$$

式(3)中, $i=1, 2, \dots, N; j=1, 2, \dots, M$.

为了使各类别能有效地分开,应使类间距离大,类内分布散度小.可设启发式函数为

$$J(k) = \sum_{i=1}^N \sum_{j=1}^N \left(\frac{(m_{ik} - m_{jk})^2}{S_{ik} + S_{jk}} \right) \quad (4)$$

式(4)中, $k=1, 2, \dots, M$.

基于启发式知识的属性约简算法的总体指导思想是:对于所讨论对象中可能被约简的条件属性(下面算法中将其称为核以外的属性),计算该启发式函数的值,用于衡量各条件属性的重要性,以此作为启发性知识,决定条件属性的约简次序,实现对条件属性的快速、有效约简.

整个算法可描述如下:

1) 对数据进行预处理(包括两步:数据的离散化;消除不相容样本),使其符合以下各步的处理要求;

2) 计算讨论对象的核,即不可约简条件属性的集合;

3) 计算核以外各条件属性的 $J(k)$ 值,并由大到小进行排列;

4) 按照 $J(k)$ 值的大小,由小到大对核以外各条件属性进行约简操作.

其中第4)步可详述为

for $i=1:n$ (n 为核以外属性的个数)

① 将样本数据备份;

② 约简第 i 个属性;

③ 判断约简操作是否成立,若成立,删除因条件属性约简而引入的冗余样本和不相容样本, $i=i+1$,转①;否则恢复约简该属性前的样本数据, $i=i+1$,转①

第③步中的判断约简操作是否成立的条件为

$$\begin{cases} N_1/N_2 \leq \alpha \\ N_3/N_4 \leq \beta \end{cases} \quad (5)$$

式(5)中, N_1 为由于执行本次约简操作而引入的不相容样本数; N_2 为执行本次约简操作前知识表中样本的数量; N_3 为若执行本次约简操作,整个约简过程引入的不相容样本数; N_4 为执行任何操作前知识表中的总样本数量; α, β 为两个阈值, $\alpha < \beta$.

设立 α, β 两个参数的目的:一定程度上克服测量过程中可能引入的误差,实现在可接受的分类型损失下,换取理想的属性约简效果,即折中考虑

分类精度和约简比例.如令 $\alpha = \beta = 0$,则意味着要确保分类的完全正确.

1.2 核 Fisher 鉴别分析(KFDA)

核 Fisher 鉴别分析方法是 Mika 等^[8]利用核方法将线性 FDA 进行非线性推广时提出的,其基本思想为:首先通过适当的非线性映射 Φ 把非线性可分的原始样本输入空间变换到一个线性可分的高维(可能为无限维)特征空间 H ,然后在此高维特征空间 H 中完成经典的 Fisher 线性鉴别分析.在高维特征空间 H 中得到的线性最佳鉴别特征,实质为原始输入空间中非线性最佳鉴别特征.

由于特征空间 H 的维数非常高甚至是无穷维,为了避免直接显式地处理变换后的样本,引入支持向量机中的核方法,即用满足 Mercer 条件的一些核函数来替代高维特征空间 H 中样本的内积运算.

定义核函数 $k(x, y) = \langle \Phi(x), \Phi(y) \rangle$,这样特征空间中两向量的内积可以用输入空间中的两变量的核函数来表示.至于核函数的选择,常见的主要有3类:高斯径向基函数、多项式核函数和神经网络核函数.

对于任意一个原始样本 X ,它的非线性最优鉴别特征为^[7]

$$T = W^T \Phi(X) = (t_1, t_2, \dots, t_d)^T \quad (6)$$

式(6)中, W 为特征空间 H 最佳鉴别向量集构成的投影矩阵; $t_i = \alpha^T \xi_x$ ($i=1, 2, \dots, d$), ξ_x 为原始样本的核样本向量, $\alpha, \alpha, \dots, \alpha_d$ 为一组最佳核鉴别向量.

1.3 基于粗糙核 Fisher 鉴别分析(RKFDA)的特征提取

基于 RKFDA 的特征提取具体步骤为:

1) 从收集的原始数据中产生训练样本集,建立初始的知识表达系统.

2) 连续属性离散化并消除冗余样本,得到 RS 理论的离散信息表.

3) 运用基于启发式知识属性约简方法进行条件属性约简.

4) 采用条件属性约简后得到的最小条件属性集及相应的原始数据重新形成新的训练样本集.该样本集去除了所有不必要的条件属性,仅保留了影响分类的重要属性.

5) 运用核 Fisher 鉴别分析方法对属性约简后形成的训练样本进行特征提取.

2 应用实例与分析

滑油系统是保障发动机正常工作的一个重要系统,其主要功能是保障发动机摩擦件的润滑、散热.以滑油系统故障为例,在滑油泵实验台上模拟了 5 种发动机滑油系统的工作状态,即正常状态(D1)、管路阻塞(故障 1,D2)、滑油泵滞(故障 2,D3)、封严装置失效(故障 3,D4)以及柱塞磨损(故障 4,D5).由安装在高压管路上的压力传感器获取压力信号,采样频率为 100 Hz.实验共获得 60 组压力信号数据,每组数据有 1 024 个采样点,每种工作状态各有 12 组数据,共 60 组样本.在具体分析前进行数据预处理,包括零均值处理和异常点剔除.分别对每一组实验数据计算下列 12 个基于统计特性的指标,它们分别是压力信号的最大峰值 $X_{\max}$ (C1),最小值 $X_{\min}$ (C2),绝对均值(C3) X ,有效值 X_r (C4),均方值 X_{rms} (C5),方差 D_x (C6),斜度 α (C7),峭度 β (C8)及指标峰值因子 C_f (C9),波形因子 S_f (C10),脉冲因子 I_f (C11)和裕度因子 CL_f (C12).

下面就以上述 12 个指标作为原始特征,利用 RKFDA 进行特征提取.

2.1 基于 RKFDA 的特征提取结果

根据第 2 节介绍的特征提取步骤,首先从收集的原始数据中产生训练样本集,以每种状态的 12 组数据共 60 组作为训练数据.

1) 建立决策表

以 12 个原始特征作为条件属性,依次标记为 C1 至 C12;以滑油系统的 5 种工作状态作为决策属性,依次标记为 D1 至 D5;对条件属性离散化并消除冗余样本建立决策表.

条件属性的离散化方法较多,综合分析各种方法的特点后,本文采用 2×2 的 Kohonen 自组织网络对连续属性进行离散化处理^[9].离散化后的决策表如表 1 所示.

2) 条件属性约简

运用基于启发式知识属性约简方法进行条件属性约简.

①计算本决策表的核属性.具体过程在此不列出,可参阅文献[5].经计算,核属性为{C9,C10,C11}.

②计算核属性以外各条件属性的 $J(k)$ 值,并由大到小进行排列,结果如表 2 所示.

③按照 $J(k)$ 值的大小,由小到大对核以外各条件属性进行约简操作.在约简过程中,为了保证分类完全准确,取 $\alpha=\beta=0$.在保证分类完全准确和保留下来属性的 $J(k)$ 值都比约简属性的 $J(k)$ 大的前提下,可约简条件属性 C4,C2,C1,C5.

由此可见,原来需要用 12 个特征来对故障进行诊断,而进行属性约简后,可以只需其中 8 个特征.

3) 运用粗糙核 Fisher 鉴别分析方法进行特征提取的结果

采用属性约简后得到的 8 个特征及相应的原始数据重新形成新的训练样本集,运用 KFDA 方法进行特征提取,最终可得到 4 个特征 RK_1 , RK_2 , RK_3 , RK_4 .KFDA 中的核函数采用具有较强非线性的径向基函数,参数取值采用 5 层 Cross-Validation 方法进行优选.

2.2 特征提取结果分析

这一节从样本集的可分性和分类器的分类性能两方面来考察 RKFDA 在特征提取中的有效性.

表 1 离散化后的决策表(部分)

Table 1 Attribute discretization of decision table (section)

C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	D
4	4	4	4	4	4	3	1	4	4	4	4	D1
2	4	4	3	4	4	4	4	2	2	2	2	D2
3	1	4	2	2	2	2	3	3	3	3	3	D3
2	1	2	2	2	2	2	3	3	3	3	1	D4
3	4	2	4	4	4	3	3	1	1	1	1	D5
...	...	...	...	...	...	...	...	...	...	...	...	...

表 2 核属性以外各条件属性的 $J(k)$ 值

Table 2 $J(k)$ of each condition attribute except core attributes

核属性以外的条件属性	C12	C8	C7	C3	C6	C5	C1	C2	C4
$J(k)$	509.5	465.2	437.8	280.1	50.3	27.6	17.9	11.0	3.7

另外,为了对比说明对原始特征进行属性约简的效果,采用 KFDA 对未经属性约简的 12 个原始特征进行了特征提取;为对比说明非线性特征提取的效果,采用 FDA 对经属性约简后的 8 个原始特征进行了特征提取.共定义下列 4 种不同的特征集:

特征集 I:RKFDA 进行特征提取所得到的 4 个新特征 RK_1, RK_2, RK_3, RK_4 .

特征集 II:KFDA 对未经约简的 12 个原始特征集中进行提取所得的 4 个新特征 KF_1, KF_2, KF_3, KF_4 .

特征集 III:FDA 对约简后的 8 个特征进行提取所得的 4 个新特征 FD_1, FD_2, FD_3, FD_4 .

特征集 IV:选取由属性约简后保留的 8 个特征组成原始特征集 IV.

2.2.1 特征的可分性分析

为了证明本文提出的 RKFDA 特征提取方法的有效性,对以上 4 组特征样本集的可分性进行对比分析.首先定义平均类间可分性参数^[9]

$$\rho = \frac{1}{s(s+1)} \sum_{i=1}^{s-1} \sum_{j=i+1}^s \left[1 - \exp \left(- \frac{d_{ij}}{r_i + r_j} \right) \right] \tag{7}$$

可分性参数用来度量给定特征样本集的可分性大小.式(7)中, s 为模式类别数; d_{ij} 为第 i 类模式与第 j 类模式间的类内距离; r_i, r_j 分别为第 i, j 类模式中样本距模式中心的最大距离,即为容纳本类样本的最小球体的半径.

图 1 为 4 种特征集的可分性参数对应不同特征维数的可分性变化曲线.




图 1 4 种特征集的可分性比较

Fig. 1 Comparison of separability with four type features

从图 1 中可以看出,RKFDA 提取的特征集的可分性要高于 KFDA 和 FDA 提取的特征集的可分性,而原始特征集的可分性最差.进一步观察可以发现,基于 RKFDA 的特征样本集的可分性随着

特征维数的增加而基本保持不变,KFDA 和 FDA 提取的特征样本集的可分性受特征维数的影响较大,原始特征集的可分性受特征维数的影响最大,从而证明 RKFDA 很好地提取了类别可分信息,最大程度地提高了样本的可分性.由此可以说明,对原始特征集进行特征约简和采用非线性特征提取方法均是有效的,均可提高样本的可分性.

为了更直观地看到不同特征样本集的可分性大小,把特征样本进行归一化处理,然后投影到 2 维平面显示.图 2 至图 5 依次是原始特征集 IV、FDA 提取的特征集 III、KFDA 提取的特征集 II 和 RKFDA 提取的特征集 I 的在 2 维平面的投影效果.由这几幅图比较可知,图 5 中的 5 种工作状态基本上没有重叠,可分性较好,因此相应的 RKFDA 提取的特征的可分性参数值就较高;而图 4、图 3 与图 5 相比,5 种工作状态重叠较严重,可分性变差,相应的 FDA 和 KFDA 提取的特征的可分性参数值就降低;图 2 的 5 种工作状态重叠最严重,表明原始特征的可分性最差,相应的原始特征集的可分性参数值最小.




图 2 原始特征的 2 维平面投影效果
Fig. 2 Two-dimensional projection of primitive feature samples




图 3 FDA 的 2 维平面投影效果
Fig. 3 Two-dimensional projection of feature samples by FDA




图 4 KFDA 提取特征的 2 维平面投影效果

Fig. 4 Two-dimensional projection of feature samples by KFDA

2.2.2 特征的分类性能分析

这一节根据分类器的分类性能来验证 RKFDA 特征提取方法的有效性. 为了体现出特征对分类器的鲁棒性, 采用支持向量机 (SVM) 和人工神经网络 (ANN) 两种分类器进行分类实验.




图 5 RKFDA 提取特征的 2 维平面投影效果

Fig. 5 Two-dimensional projection of feature samples by RKFDA

由于训练和测试样本数较少, 为了更准确地估计分类器的分类性能, 这里采用交叉检验的方法对分类正确率进行估计. 总共将 60 个样本分成 4 组进行交叉检验.

下面通过一系列分类实验来分析不同特征集对分类器性能的影响.

首先, 采用支持向量机对其分类. 支持向量机采用径向基核函数, 多类别分类器采用一对多方法^[11]. 为了考察采用不同方法提取的特征集对支持向量机核函数参数的敏感性, SVM 取两组参数设置: SVM₁: $\sigma=0.25$, $C=100$; SVM₂: $\sigma=1$, $C=100$. 支持向量机的分类结果如表 3 所示.

由表 3 的对比可以看出, 采用 RKFDA 提取的特征的分类效果远远优于原始特征的分类效果, 也要好于 KFDA 和 FDA 提取的特征的分类效果. 进一步分析可以发现, 使用 RKFDA 提取的 2 维特征就可以超过使用 4 个 KFDA 或 FDA 提取的特征的分类正确率, 有效地实现了特征维数的压缩.

当支持向量机核函数参数改变时, 直接使用原始特征的分类效果明显下降, 采用 FDA 和 KFDA 提取的特征的分类效果也有所下降; 而采用 RKFDA 提取的特征的分类效果无明显变化. 说明采用 RKFDA 所提取的特征对支持向量机核函数参数不敏感, 因此提高了对分类器的适应性.

其次, 为考察 4 种特征提取方法提取的特征对不同种类的分类器的鲁棒性, 分别采用支持向量机 (SVM) 和人工神经网络 (ANN) 两种分类器进行分类实验, 结果如表 4 所示. 支持向量机分类器仍采用一对多支持向量机, 核函数采用径向基核函数. 参数 $\sigma=0.25$, $C=100$. 神经网络分类器为多层感知器 (MLP) 神经网络, 包含一个隐含层和一个输出层, 隐层神经元取 9 个.

表 3 4 种方法提取的特征的分类正确率比较

Table 3 Comparison of classification accuracy of feature samples by four type methods

分类器	特征维数	分类正确率/ %			
		原始特征	FDA	KFDA	RKFDA
SVM ₁	2	83.3	90.1	91.5	97.6
	3	87.4	92.3	94.2	97.5
	4	90.2	94.0	95.3	97.7
SVM ₂	2	75.6	89.2	90.6	97.0
	3	84.3	91.7	92.5	97.2
	4	87.3	92.9	94.1	97.1

表 4 神经网络和支持向量机对不同特征集的分类正确率比较

Table 4 Comparison of different features classification accuracy by SVM and ANN

特征集	分类正确率/ %	
	神经网络	支持向量机
原始特征空间的 前 4 个特征	85.7	90.2
FDA 提取的 4 个特征	90.6	94.0
KFDA 提取的 4 个特征	93.1	95.3
RKFDA 提取的 4 个特征	97.2	97.7

从表 4 可以看出,对于神经网络和支持向量机分类器,RKFDA 提取的特征都具有最好的分类能力,说明 RKFDA 提取的特征对不同种类的分类器具有较好的鲁棒性.

3 结 论

本文研究了粗糙集的属性约简与核 Fisher 鉴别分析方法相结合在故障特征提取中的应用问题,提出了一种基于粗糙核 Fisher 鉴别分析方法的故障特征提取方法,并应用在发动机滑油系统的故障特征提取及故障识别中.所取得的结果或结论总结如下:

1) 基于启发式的粗糙集理论属性约简方法不需要事先预知额外信息,约简与分类无关或关系不大的特征,降低了输入特征维数,排除干扰特征的影响,减小了特征提取的计算量;而核 Fisher 鉴别分析方法则不但适合处理非线性问题,且在提取特征时充分考虑到了类别信息,提取的特征识别效果更优.

2) 通过对 RKFDA ,KFDA 和 FDA 三种方法分别提取的特征进行样本集的可分性和分类器的分类性能的比较,结果表明本文进行特征约简和采用非线性特征提取方法均是有效的,均使整个样本集的可分性变大,从而提高了分类器的分类正确率;而且在提高分类正确率的同时,还有效地降低了描述问题所需的特征数目,提高了分类效率.

(3) 通过取不同支持向量机核函数参数的分类效果比较,表明 RKFDA 获取的特征对分类器

的适应性更强;而神经网络和支持向量机分类器的对比实验表明,RKFDA 获取的特征对不同分类器具有较强的鲁棒性.

参考文献:

[1] 高秀梅. 基于核投影分析的特征抽取及应用研究[D]. 南京:南京理工大学,2004.
GAO Xiumei. Research on kernel projection analysis based feature extraction and applications[D]. Nanjing: Nanjing University of Science and Technology,2004. (in Chinese)

[2] Guo Y F, Shu T T, Yang L Y, et al. Feature extraction method based on the generalized Fisher discriminant criterion and face recognition[J]. Pattern Analysis & Application, 2001, 4(1) :61-66.

[3] 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 TieLing, YANG Shuzi. Mechanical fault classification using nonlinear discriminant analysis [J]. Journal of Vibration Engineering, 2005, 18(2) :133-138. (in Chinese)

[4] 李应红,尉询楷,刘建勋. 支持向量机的工程应用[M]. 北京:兵器工业出版社,2004.

[5] 曾黄麟. 粗集理论及其应用[M]. 重庆:重庆大学出版社,1998.

[6] 谢忠时,李军,李晓堂,等. 基于粗集理论的约简算法[J]. 吉林大学学报,2003, 33(1) :82-87.
XIE Zhongshi, LI Jun, LI Xiaotang, et al. Research of reduced algorithm based on rough set theory[J]. Journal of Jilin Universtiy, 2003, 33(1) :82-87. (in Chinese)

[7] 肖健华,吴今培,樊可清,等. 粗糙金成分分析在齿轮故障特征提取中的应用[J]. 振动工程学报,2003,16(2) :166-170.
XIAO Jianhua, WU Jinpei, FAN Keqing, et al. Rough principal component analysis and its application on feature extraction for gears[J]. Journal of Vibration Engineering, 2003,16(2) :166-170.

[8] Mika S, Ratsch G, Weston I, et al. Fisher discriminant analysis with kernels[J]. In IEEE Neural Networks for Signal Processing Workshop, 1999, 41-48.

[9] 潘励,张祖勋,张剑清. 粗糙集理论在图像特征选择中的应用[J]. 数据采集与处理,2002, 17(1) : 42-45.
PAN Li, ZHANG ZuXun, ZHANG Jianqing. Application of rough sets in image feature selection[J]. Journal of Data Acquisition & Processing, 2002, 17(1) : 42-45. (in Chinese)

[10] Bezdek J C, Pal N R. Some new index of cluster Validity [J]. IEEE Trans. SMC, 1998, 28(3) :301-315.

[11] Hsu C W, Lin C J. A comparison of methods for multi-class support vector machines[J]. IEEE Trans. Neural Netw. 2002, 13(2) :415-425.