

基于特征融合技术的发动机故障诊断

许丽佳¹, 康志亮¹, 黄诚惕²

(1. 四川农业大学信息与工程技术学院, 雅安 625014; 2. 电子科技大学自动化工程学院, 成都 611731)

摘要: 为了提高发动机的故障识别率, 设计了一种将 B&B 算法与广义判别分析 (GDA) 相结合的多类特征融合方法。从发动机转子的振动信号中提取出频谱特征集和纹理特征集, 用 B&B 算法删去 2 类特征集中信息量少的特征, 并用 GDA 和支持向量机 (SVM) 分类器进行特征融合和分类识别。发动机的转子故障试验结果表明, 该方法获得的融合特征包含有更多的类别信息, 用于转子故障获得的识别率为 98.21%, 且不受分类器核参数的影响; 而频谱特征、纹理特征输入 SVM 分类器后获得的故障识别率仅为 92.86% 和 89.29%。该研究为发动机的故障诊断提供了一种有效、实用的特征提取方法。

关键词: 发动机, 故障诊断, 特征提取, 广义判别分析, 特征融合

doi: 10.3969/j.issn.1002-6819.2010.11.023

中图分类号: V263.6

文献标志码: A

文章编号: 1002-6819(2010)-11-0130-06

许丽佳, 康志亮, 黄诚惕. 基于特征融合技术的发动机故障诊断[J]. 农业工程学报, 2010, 26(11): 130—135.

Xu Lijia, Kang Zhiliang, Huang Chengti. Fault diagnosis for engine based on feature fusion[J]. Transactions of the CSAE, 2010, 26(11): 130—135. (in Chinese with English abstract)

0 引言

发动机的故障诊断是国内外专家公认的研究热点和难点, 其本身就是一个结构很复杂的机电设备, 长期处于高温、高负荷和高速运转状态, 故障率高且故障种类众多, 一类故障可以诱发多种故障征兆, 而一种故障征兆又可能是多类故障引起, 使得发动机故障的诊断难度增加。传统的故障诊断法是主观经验判断法和接触式传感器检测分析法, 通过检测如噪声、振动、排气等物理量并依靠经验来判断, 此类方法很大程度上依赖人的经验故局限性很大^[1-2]。近年来随着人工智能技术的发展, 神经网络、小波分析、模糊理论及支持向量机^[3-8]等愈来愈多用于故障诊断。

故障诊断分为 2 个步骤: 特征提取和故障识别, 而特征提取的设计则是提高故障识别率的关键。现有文献提出了各类特征提取法, 如免疫提取, 粗糙核鉴别分析, 主成分分析及线性判别分析等^[9-12], 但都是用单类特征进行诊断, 或用 D-S 理论进行决策级融合诊断^[13], 诊断准确度还有待提高。单一故障特征包含故障信息是有限的, 多种类型的特征融合可包含丰富的故障信息, 本文拟从发动机转子的振动信号中提取出频谱特征和纹理特征, 利用特征选择技术 (B&B 算法) 和广义判别分析 (generalized discriminant analysis, GDA) 来设计有效的融合方法以实现对此 2 类特征的非线性融合, 使融合后的特征包含有更多的类别信息, 并将支持向量机作为分

类器, 以期获得较高的故障识别率。

1 发动机 2 类故障特征的提取

发动机故障的发生必定会导致振动、温度、压力、噪声及排气量等参数的变化, 依据这些变化可以实时监测发动机的状态并诊断其故障。发动机的故障主要有气缸活塞故障、润滑系统故障、燃油系统故障、进排气系统故障、冷却系统及曲柄连杆故障等, 其中磨损是导致发动机出现早期故障的主要原因, 所以本文主要研究转子轴承的磨损故障。振动信号通常是诊断发动机故障的首选信号, 包含了丰富的故障信息且易于采集, 从中提取的特征参数能够反映发动机的运行状态。下面主要研究转子不平衡、油膜涡动和转子碰磨共 3 类故障。

1.1 频谱特征

发动机转子的振动信号主要是由旋转运动引起的时变非平稳信号, 对其进行频谱分析是旋转机械故障诊断中的基本方法, 即从振动信号的频谱图中提取相关的特征量, 确定各特征频率及其对应的幅值。

图 1 为转子在某未知状态下的振动信号及其频谱图, 其中旋转频率 $f_n = 60$ Hz。通常转子故障信号的最低倍频在 f_n 的 0.5 倍以下, 最高倍频则在 10 倍以上。本文选取 $0.2f_n$ 、 $0.25f_n$ 、 $0.33f_n$ 、 $0.43f_n$ 、 $0.5f_n$ 、 $0.55f_n$ 、 $0.67f_n$ 、 $0.75f_n$ 、 $0.85f_n$ 、 f_n 、 $1.5f_n$ 、 $2f_n$ 、 $3f_n$ 、 $4f_n$ 、 $5f_n$ 、 $6f_n$ 、 $7f_n$ 、 $8f_n$ 、 $9f_n$ 、 $10f_n$ 共 20 个频谱特征。

1.2 纹理特征


小波变换是目前广泛应用的特征提取技术, 已有文献^[14]将连续小波变换用于转子碰磨时的振动信号以获其尺度谱, 并利用尺度谱的变化来诊断转子的碰磨故障, 但没有从尺度谱上提取出数字特征因而该方法在实际中难以应用。对此文献^[15]提出从尺度谱图像中提取出纹理

收稿日期: 2010-02-09 修订日期: 2010-11-11

基金项目: 四川省教育厅自然科学重点项目 (08ZA067); 四川省教育厅青年基金项目 (08zb028)

作者简介: 许丽佳 (1973—), 女, 四川通桥人, 副教授, 博士, 主要从事故障预测与健康管理、故障诊断、信息处理等方向的理论与技术研究。雅安 四川农业大学信息与工程技术学院, 625014. Email: lijiaxu01@sohu.com

特征, 把尺度谱上人眼观测的差异转化成纹理特征的变化以便于实现转子故障的诊断, 文中用此方法来获取转子振动信号的尺度谱纹理特征。



注: 旋转频率 $f_n = 60 \text{ Hz}$

图 1 转子振动信号及其频谱图

Fig.1 Rotor's vibration signal and its spectrum

用 $P(i, j, d, \theta)$ 表示转子振动信号的尺度谱图像的方向为 θ 、间隔为 d 的正规化灰度共生矩阵, i, j 为矩阵 P 的行和列。设置 $d=1$, $\theta=0^\circ, 45^\circ, 90^\circ, 135^\circ$ 共 4 个方向, 从而可获得以下 20 个纹理特征: 角二阶矩 ($f_{11}, f_{12}, f_{13}, f_{14}$)、对比度 ($f_{21}, f_{22}, f_{23}, f_{24}$)、相关度 ($f_{31}, f_{32}, f_{33}, f_{34}$)、方差 ($f_{41}, f_{42}, f_{43}, f_{44}$)、逆矩阵 ($f_{51}, f_{52}, f_{53}, f_{54}$)。

2 特征融合的研究

单类特征包含的故障信息较少易导致故障识别率低, 因而对上述 2 类特征进行选择 and 融合, 以期获得较高的故障识别率。若将 2 类特征直接组合则组合特征的高维性和冗余性易使得分类器的识别能力下降。此处设计的特征融合是先对单类特征进行特征选择, 以删去无用或包含故障信息较少的特征, 接着将保留下来的特征进行组合并利用 GDA 对组合特征融合提取, 提取出的低维融合特征将包含有最多的故障类别信息, 将此融合特征输入分类器也必将获得最高的故障识别率。

2.1 B&B 算法及其适应度函数

单类特征常包含了一些无用或类别信息很少的特征, 若在组合之前删去此类特征并用 GDA 对保留下来的特征进行非线性融合, 这样不仅会减轻 GDA 的计算负荷且可避免核映射矩阵的奇异性。B&B 算法^[16]是保证选择的特征在某一评价指标下是全局最优且无需穷尽搜索的方法, 该算法要求适应度函数 $J(X)$ (也称评价函数) 满足单调性

$$J(X_s) \geq J(X_t), \text{ 若 } X_s \supseteq X_t \quad (1)$$

式中, X_s, X_t 为特征集, $J(X_s), J(X_t)$ 是 X_s, X_t 对应的适应度函数值。B&B 算法的搜索空间是一棵树, 是在算法运行时自上而下按照深度优先的秩序生成。若从包含 D 个特征的集合中选择出有 d 个特征的子集且 $d < D$ (以 $D =$

5, $d=2$ 为例), 则搜索过程类似深度优先的 A* 算法 (见图 2)。详细的步骤参见文献[16]。




图 2 B&B 算法的搜索树

Fig.2 Search tree of B&B algorithm

本文选用最近邻分类法的分类率作适应度函数。设有 C 类模式样本 X_1, X_2, \dots, X_C , 每类有 n_i 个特征样本 ($i=1, 2, \dots, C$), X 为待分类样本, 则最近邻的判别函数为

$$d_i(X) = -\min_k \|X - X_{ik}\|, \quad k=1, 2, \dots, n \quad (2)$$

式中, $d_i(X)$ 表示 X 属于第 i 类的概率值; X_{ik} 表示第 i 类特征集中的第 k 个特征。若有 $d_i(X) > d_j(X)$ 且 $i \neq j$, 则把 X 分到第 i 类中。对已知的样本进行选择并将选择后的特征构造训练样本和测试样本, 用最近邻法来识别测试样本, 获得的识别率即为 $J(X)$; 并不断重复选择直至获得最大的 $J(X)$ 时所对应的特征即为优选特征

$$X_a = \max_{X \subset X_b} J(X), \quad a < b \quad (3)$$

式中, X_a 是从特征集 X_b 中按使最近邻法的分类率最大而优选出来的子特征集; X 是特征集 X_b 的任一子集; a, b 分别为 X_a 和 X_b 的维数 ($a < b$)。

2.2 广义判别分析法 (GDA)

GDA^[17]本质上是一种核映射: 将低维输入空间中的线性不可分特征, 通过非线性映射函数将输入向量映射到一个高维的空间 H , 然后在此高维空间中可以进行线性可分, 并用核函数计算特征空间中样本的内积。设有特征样本 $X = \{x_1, x_2, \dots, x_n\}$ 且 $x \in R^n$, 样本类别为 C 。第 i 类样本子集为 X_i , 样本数量为 n_i , 第 i 类样本的均值

$$u_i = \frac{1}{n} \sum_{j=1}^{n_i} x_j^i. \text{ 经非线性映射函数 } \Phi \text{ 映射后的样本向量}$$

$\Phi(x) \in H$ (即高维空间), 在 H 空间样本的类内离散矩阵 S_w^Φ 、类间离散矩阵 S_B^Φ 为

$$S_B^\Phi = \frac{\sum_{i=1}^C \sum_{j=1}^C (u_i - u_j)(u_i - u_j)^T}{C(C-1)} \quad (4)$$

$$S_w^\Phi = \frac{1}{C} \sum_{i=1}^C \frac{1}{n_i} \sum_{x_j \in X_i} (\Phi(x_j^i) - u_i^\Phi)(\Phi(x_j^i) - u_i^\Phi)^T \quad (5)$$

式中, $u_i^\Phi = \frac{1}{n_i} \sum_{x_j \in X_i} \Phi(x_j^i)$, u_j 表示第 j 类样本的均值; S_w^Φ

和 S_B^Φ 都是非负定矩阵。

高维空间 H 中的 Fisher 判别准则为

$$J(\omega_{\text{opt}}) = \arg \max \frac{\omega^T S_B^\Phi \omega}{\omega^T S_W^\Phi \omega} \quad (6)$$

式中, $\omega \in H$ 为特征核映射后的特征向量; ω_{opt} 是通过求解 $(S_W^\Phi)^{-1} S_B^\Phi$ 的特征值并按从大到小排序获得的前 r 个主要特征向量, 从而实现降维, 并且 ω 满足 $\omega_j^T \omega_j = 0$, $j=1, \dots, r$, 也一定位于 H 空间中所有训练样本 $\Phi(x)$ 张成的空间内; $J(\omega_{\text{opt}})$ 表示 ω_{opt} 所对应的适应度值。根据再生核理论, 解得

$$\omega = \sum_{x_j \in X_i} \alpha_i \Phi(x_j) = \Phi \alpha \quad (7)$$

式中, α 为 H 空间中 ω 的最佳核判别方向。将式 (6) 与式 (7) 联合可得

$$J(\alpha) = \arg \max \frac{\alpha^T K_b \alpha}{\alpha^T K_w \alpha} \quad (8)$$

式中 K_b 、 k_w 是依据核距离 μ_i 计算出来的数值^[17], 无量纲。 μ_i 定义为

$$\mu_i = \frac{1}{n_i} \left[\sum_{x \in X_i} K(x_1, x), \sum_{x \in X_i} K(x_2, x), \dots, \sum_{x \in X_i} K(x_n, x) \right]^T \quad (9)$$

H 空间中的正交约束条件式等价于

$$\omega_i^T \omega_j = \alpha_i^T \Phi_j^T \Phi_j \alpha_j = 0, \quad \forall i \neq j \quad (10)$$

因而可以推导得

$$\langle \omega, \Phi(x) \rangle = \sum_{i=1}^n \alpha_i K(x_i, x) \quad (11)$$

式中 $K(x_i, x)$ 为核函数。

2.3 多类特征的融合

不同类型的特征包含了发动机在不同状态空间中的故障信息, 对上述 2 类特征 (即频谱特征和纹理特征) 进行融合设计, 融合诊断的详细过程见图 3。

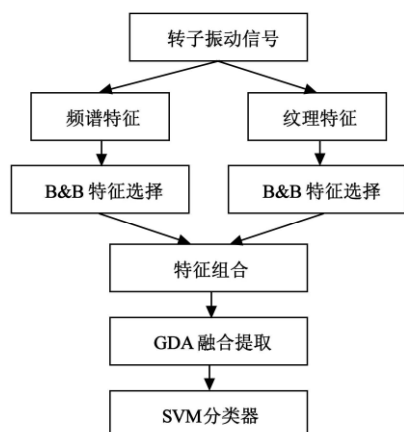


图 3 特征融合的故障诊断流程

Fig.3 Flow chart of fault diagnose based on fused features

3 应用实例

利用多功能转子故障模拟试验台和 DH5922 动态信号测试分析系统获取了不同转速下的不平衡故障样本、

碰磨故障样本各 30 个, 油膜涡动故障样本 35 个, 将它们作为下面试验的使用数据。

3.1 各类特征的分布对比试验

选取 3 类故障各 13 个作为训练样本, 选择转子不平衡故障样本 13 个, 转子碰磨故障样本和油膜涡动故障样本各 16 个作为测试样本。选取频谱特征和纹理特征的前 2 个特征投影到 2 维空间 (见图 4)。从该图可知原始特征的分类性能并不好, 纹理特征比频谱特征包含的类别信息略少些。

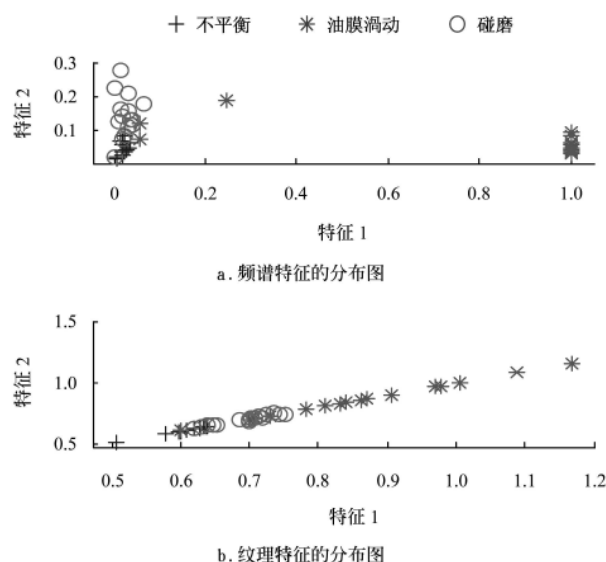


图 4 原始特征的分布图

Fig.4 Distribution of the original features

利用线性判别分析 (linear discriminant analysis, LDA) 对原始特征提取, 经其提取后的特征分布见图 5。

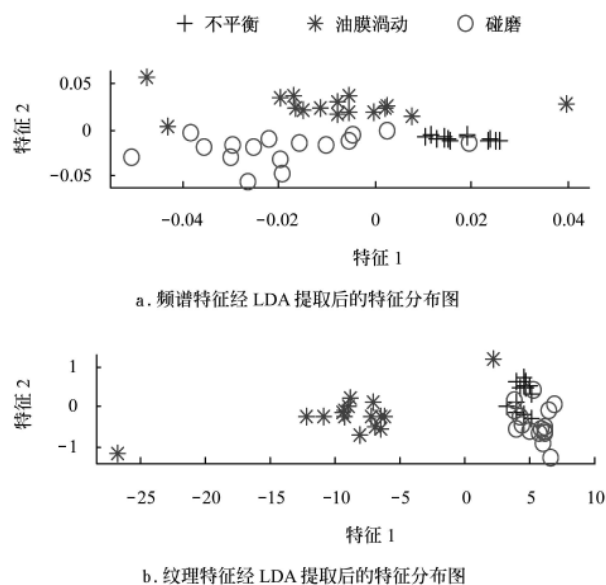


图 5 单类特征经 LDA 提取后的特征分布图

Fig.5 Distribution of the single-class features projected by linear discriminant analysis (LDA)

从图 5 可知, 经 LDA 提取的特征所包含的类别信息不但没增加反而变少了, 这是因为转子故障的振动信号

是非线性很强的复杂信号，从中提取出的频谱特征和纹理特征也具有很强的关联性和非线性，因此用 LDA 对其进行线性去冗并不合适。

对 2 类原始特征用 GDA 提取 (GDA 是 LDA 通过核方法的非线性推广)，获得的特征分布见图 6。从该图可知，GDA 提取的特征明显比原始特征经 LDA 提取的特征所包含的类别信息多，当然纹理特征经 GDA 提取的特征仍然比频谱特征经 GDA 提取的特征所包含的类别信息稍少些。

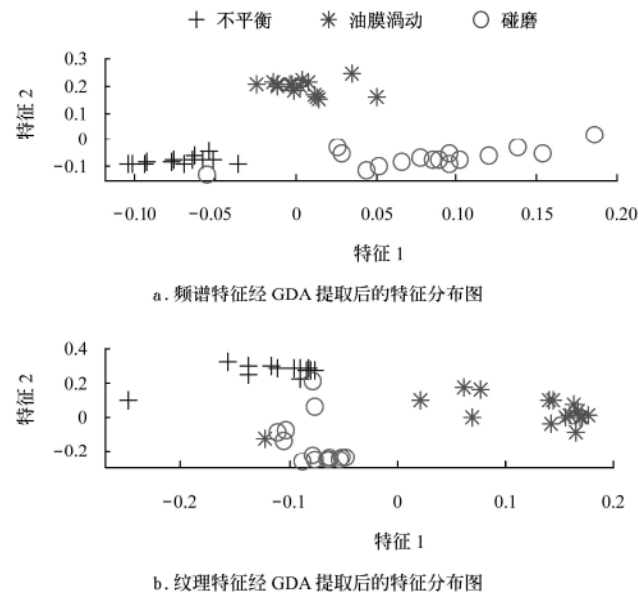


图 6 单类特征经 GDA 提取后的特征分布图

Fig.6 Distribution of the single-class features projected by generalized

对 2 类原始特征按图 3 所示的设计流程进行融合提取，获得的融合特征的分布见图 7。从该图可以看出，融合特征的同类样本聚集成团，不同类别之间则彼此分离、相隔明显，具有很好的紧致性和分类性，明显优于原始特征经 LDA 或 GDA 提取后的单类特征。




图 7 融合特征的分布图

Fig.7 Distribution of fused features

3.2 基于单类特征的故障诊断试验

支持向量机 (support vector machine, SVM) [18]是近年来机器学习的一项重要研究成果，它是利用线性可分情况下的最优分类面来将所有训练样本进行正确分类，而且使训练样本中离分类面最近的点到分类面的距离最大。其优点是能够用小样本进行训练和学习，以解决多维向量空间下的模式识别问题，因此此处采用 SVM 作为

分类器。选取 SVM 的核函数为径向基函数并采用一对多分类策略，核参数 $\sigma=2$ ，正则参数 $C=1$ ，训练精度 $\epsilon=0.001$ 。选取每类故障的 13 个样本为训练样本，剩余样本为测试样本。基于单类特征的故障识别结果见表 1 和表 2。

表 1 频谱特征的故障识别率

Table 1 Fault recognition rate based on the spectrum features

%				
特征类型	不平衡故障	油膜涌动故障	碰磨故障	平均值
频谱特征	100	96.30	81.25	92.86
频谱特征+B&B	100	96.30	81.25	92.86
频谱特征+LDA	100	81.48	87.50	87.50
频谱特征+GDA	100	96.30	93.75	96.43

注：LDA 为线性判别分析；GDA 为广义判别分析，下同。

表 2 纹理特征的故障识别率

Table 2 Fault recognition rate based on the texture features

%				
特征类型	不平衡故障	油膜涌动故障	碰磨故障	平均值
频谱特征	100	85.19	87.50	89.29
频谱特征+B&B	100	85.19	87.50	89.29
频谱特征+LDA	76.92	96.30	81.25	87.50
频谱特征+GDA	100	88.89	87.50	91.07

从表 1 和表 2 可知，单类特征+GDA 所包含的类别信息最多，将其应用于 SVM 获得的识别率最高，单类特征+LDA 应用于 SVM 获得的识别率最低。单类特征+B&B 所获得的识别率没变，这说明 B&B 算法主要是删去无用或信息量少的特征，以减小 GDA 的计算负荷且可避免核映射矩阵的奇异性，而单类特征用于诊断转子故障时添加 B&B 算法的效果并不明显。

3.3 基于融合特征的故障诊断试验

有效的特征融合方法将会使得融合后的特征包含更多的类别信息，所以本文设计了几种不同的融合方法，并将融合后的特征输入 SVM 进行发动机的故障诊断，试验结果见表 3。

表 3 各类融合特征的故障识别率

Table 3 Fault recognition rate based on the fused features

%				
特征类型	不平衡故障	油膜涌动故障	碰磨故障	平均值
组合特征	100	100	87.25	96.43
B&B+组合	100	100	87.50	96.43
组合特征+GDA	100	96.30	93.75	96.43
融合特征	100	100	93.75	98.21

注：组合特征为将频谱特征和纹理特征直接组合；B&B+组合为将频谱特征和纹理特征分别经 B&B 算法选择后再组合；组合特征+GDA 为将组合特征经 GDA 提取；融合特征为将频谱特征和纹理特征分别经 B&B 算法选择后再经 GDA 融合提取。

从表 3 可知，前 3 种特征融合法获得的平均故障识别率是相同。与单类特征相比，组合特征包含有更多的类别信息，但该类特征冗余性较大且维数最高。分别经 B&B 选择后再组合的特征与组合特征相比其维数略低些，可以一定程度上减小 SVM 的计算量，但其包含的类

别信息基本不变。组合特征+GDA 虽然消除了融合特征的冗余性,但由于组合特征包含了较多的无用特征,此类特征的存在导致 GDA 提取出的特征所包含的类别信息并没增加。而图 3 所示的融合设计法不仅有利于 GDA 核矩阵的计算,而且获得的融合特征也包含最多的类别信息,提高了故障识别率,表中试验结果也验证了此结论。

3.4 训练样本数、核参数 σ 与识别性能的关系

GDA 的训练时间是由参与训练的样本数目决定,已证明了其算法复杂度为 $O(m^3)^{[9]}$,其中 m 为训练样本个数,这就意味着 GDA 的计算时间随着样本数的增加而急剧增加。下面研究了在不同训练样本个数下转子故障的识别率变化,试验结果见表 4。

表 4 不同训练样本数时的故障识别率

Table 4 Fault recognition rate corresponding to the training samples of different numbers %

训练样本数	融合特征	组合特征	幅频特征	纹理特征
10	96.92	96.92	93.85	83.08
11	96.77	96.77	93.55	88.71
12	98.31	96.61	93.22	89.83
13	98.21	96.43	92.86	89.29
14	98.11	96.23	92.45	88.68
15	98.00	96.00	92.00	88.00

注:融合特征为将频谱特征和纹理特征分别经 B&B 算法选择后再经 GDA 融合提取;组合特征为将频谱特征和纹理特征直接组合。

通常认为若训练样本越多,识别性能也会越好,但是从表 4 可知,对于融合特征和纹理特征而言,训练样本数为 12 时具到最高的识别率,幅频特征和组合特征的最佳训练样本数则为 10。当超过了此训练样本数,则识别率反而有些许下降,这是由于训练数据通常含有一定的噪声数据,训练样本数越大则噪声数据也就越多,因此训练样本数的增加有时会使得其中的噪声数据降低了分类器的训练准确性,这意味着不同的特征集有对应的最佳训练样本数(通过多次试验来获取)。从表 4 可得结论:在相同的训练样本个数下,融合特征输入 SVM 总能维持最高的故障识别率。

通常分类器 SVM 的核参数 σ 会影响故障诊断的准确性,为了考察各类特征受 σ 的影响程度,在 σ 取不同值时将各类特征输入 SVM 获得的平均故障识别率见表 5。

表 5 核参数取不同值时的平均故障识别率

Table 5 Recognition results corresponding to the different values of kernel parameter %

核参数	融合特征	组合特征	幅频特征	纹理特征
0.01	98.21	92.86	92.86	83.93
0.25	98.21	94.64	92.86	83.93
2	98.21	96.43	92.86	89.29
5	98.21	92.86	92.86	89.29
10	98.21	87.50	94.64	87.50

注:融合特征—将频谱特征和纹理特征分别经 B&B 算法选择后再经 GDA 融合提取;组合特征—将频谱特征和纹理特征直接组合。

从表 5 可知,无论 σ 取何值,融合特征输入 SVM 获得的识别率总是维持不变,而其余特征输入 SVM 获得的

识别率则随 σ 值的变化而变化。这说明融合特征不仅包含最多的类别信息,而且不受分类器核参数 σ 的影响,这利于该方法在工程中的应用。

4 结 论

1) 与单类特征和其他类型的融合特征相比,本文设计的融合特征包含最多的类别信息。将该融合特征用于支持向量机获得的故障识别率(98.21%)高于其他组合特征用于支持向量机获得的故障识别率(96.43%),也远远高于频谱特征、纹理特征用于支持向量机获得的故障识别率(92.86%和 89.29%),更有利于转子故障的诊断。

2) 通过线性判别分析(LDA)和广义判别分析(GDA)的试验对比可知,转子振动信号具有很强的非线性,线性的特征提取方法是不适合的。将频谱特征分别经 LDA 和 GDA 提取后输入支持向量机,获得的平均故障识别率分别为 87.50%和 96.43%;将纹理特征分别经 LDA 和 GDA 提取后输入分类器,获得的平均故障识别率分别为 87.50%和 91.07%。

3) 在不同的训练样本数下,融合特征输入支持向量机总是具有最高的故障识别率,并且即使在较少训练样本数时也仍然具有良好的识别能力,例如当训练样本数仅为 12 时,获得的融合故障识别率为 98.31%。

4) 试验也同样验证了融合特征输入支持向量机所获得的故障识别率几乎不受其核参数的影响,当核参数分别取值为 0.01、0.25、2、5 和 10 时,获得的故障识别率均为 98.21%,这说明本文方法具有很强的适应性,具有工程应用价值。

[参 考 文 献]

- [1] 陈长征,胡立新,周勃,等. 设备振动分析与故障诊断技术[M]. 北京:科学出版社,2007.
- [2] 钟秉林,黄仁. 机械故障诊断学[M]. 北京:高等教育出版社,2002.
- [3] 王祝平,王为,李小昱,等. 基于 EMD 与神经网络的内燃机气门间隙故障诊断[J]. 农业机械学报,2009,38(12): 133—136.
Wang Zhuping, Wang Wei, Li Xiaoyu, et al. Fault diagnosis of engine valve based on EMD and artificial neural network[J]. Transactions of the CSAM, 2009, 38(12): 133—136. (in Chinese with English abstract)
- [4] 文振华,左洪福. 基于粗糙集-集成神经网络的航空发动机磨损故障诊断方法[J]. 中国机械工程,2007,18(21): 2580—2584.
Wen Zhenhua, Zuo Hongfu. A diagnosis method for aero engine wear fault based on rough sets theory and integrated neural network[J]. China Mechanical Engineering, 2007, 18(21): 2580—2584. (in Chinese with English abstract)
- [5] Francis E H T, Shen L X. Fault diagnosis based on rough set theory[J]. Engineering Application of Artificial Intelligence, 2003, 16(1): 39—43.
- [6] 蔡开龙,谢寿生,吴勇. 航空发动机的模糊故障诊断研究[J]. 航空动力学报,2007,22(5): 833—837.
Cai Kailong, Xie Shousheng, Wu Yong. Study on fuzzy fault diagnosis of aero-engine[J]. Journal of Aerospace Power,

- 2007, 22(5): 833—837. (in Chinese with English abstract)
- [7] 蒋爱华, 李小昱, 王为, 等. 基于小波分析的发动机气缸失火故障诊断[J]. 农业工程学报, 2007, 23(4): 153—157. Jiang Aihua, Li Xiaoyu, Wang Wei, et al. Misfire failure diagnosis of engine based on wavelet analysis[J]. Transactions of the CSAE, 2007, 23(4): 153—157. (in Chinese with English abstract)
- [8] 唐浩, 屈梁生. 基于支持向量机的发动机故障诊断[J]. 西安交通大学学报, 2007, 41(9): 1124—1126. Tang Hao, Qu Liangshen. Fault diagnosis of engine based on support vector machine[J]. Journal of Xi'an Jiaotong University, 2007, 41(9): 1124—1126. (in Chinese with English abstract)
- [9] 胡金海, 谢寿生, 汪诚, 等. 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[J]. 航空动力学报, 2008, 23(7): 1346—1352. Hu Jinhai, Xie Shousheng, Wang Chen, et al. Feature extraction based on rough kernel Fisher discriminant analysis and its application on aeroengine fault diagnosis[J]. Journal of Aerospace Power, 2008, 23(7): 1346—1352. (in Chinese with English abstract)
- [10] 候胜利, 李应红, 尉询楷. 基于遗传规划和线性鉴别分析的故障特征提取模型及其应用[J]. 推进技术, 2006, 27(3): 270—275. Hou Shengli, Li Yinghong, Wei Xunkai. Feature extraction based on genetic programming and linear discriminant analysis for fault diagnosis and its application[J]. Journal of Propulsion Technology, 2006, 27(3): 270—275. (in Chinese with English abstract)
- [11] 梁霖, 徐光华, 刘弹. 免疫编程的故障特征构造方法[J]. 西安交通大学学报, 2007, 41(9): 1036—1039. Liang Lin, Xu Guanghua, Liu Dan. Features generation in fault diagnosis based on immune programming[J]. Journal of Xi'an Jiaotong University, 2007, 41(9): 1036—1039. (in Chinese with English abstract)
- [12] 李增芳, 何勇, 宋海燕. 基于主成分分析和集成神经网络
- 的发动机故障诊断模型研究[J]. 农业工程学报, 2006, 22(4): 131—134.
- Li Zengfang, He Yong, Song Haiyan. Fault diagnosis model for engines based on principal component analysis and integrated neural network[J]. Transactions of the CSAE, 2006, 22(4): 131—134. (in Chinese with English abstract)
- [13] 王仲生, 赵鹏. 基于多源信息融合的发动机转子早期故障识别[J]. 西北工业大学学报, 2009, 27(3): 326—329. Wang Zhongsheng, Zhao Peng. Applying method of multi-source information fusion to achieving early diagnosis of aero-engine rotor fault[J]. Journal of Northwestern Polytechnical University, 2009, 27(3): 326—329. (in Chinese with English abstract)
- [14] Peng Z, He Y, Lu Q, et al. Feature extraction of the rub-impact rotor system by means of wavelet analysis[J]. Journal of Sound and Vibration, 2003, 259(4): 1000—1010.
- [15] 邓堰. 转子故障智能诊断中的特征提取与选择技术研究[D]. 南京: 南京航空航天大学民航学院, 2008. Deng Yan. The Study on Feature Extraction and Feature Selection in Rotor Fault Intelligent Diagnosis[D]. Nanjing: College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, 2008. (in Chinese with English abstract)
- [16] Yu B, Yuan B Z. A more efficient branch and bound algorithm for feature selection[J]. Pattern Recognition, 1993, 26(6): 883—889.
- [17] Baudat G, Fatiha A. Generalized discriminant analysis using a kernel approach[J]. Neural Computation, 2000, 1(12): 2385—2404.
- [18] Chapelle O, Vapnik V, Bacsquest O, et al. Choosing multiple parameters for support vector machine[J]. Machine Learning, 2002, 46(1): 131—159.
- [19] Baudat G, Anouar F. Kernel-based methods and function approximation[C]//Proceedings of the International Joint Conference on Neural Networks: Washington, DC, 2001: 1244—124.

Fault diagnosis for engine based on feature fusion

Xu Lijia¹, Kang Zhiliang¹, Huang Chengti²

(1. School of Information and Engineering Technology, Sichuan Agricultural University, Ya'an 625014, China;

2. School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: In order to achieve higher fault recognition rate of engine, the paper proposed a multi-class feature fusion method which combined B&B algorithm with generalized discriminant analysis (GDA). Firstly, the spectrum feature set and texture feature set were extracted from the vibration signal of engine rotor. Subsequently, B&B algorithm was used to remove the information-lacked features from these feature sets. Finally, the GDA and SVM classifier were used to implement feature fusion and fault recognition. The experiment results indicated that this method can make the fused features contain more category information, and it can reach 98.21% of fault recognition rate for engine rotor fault diagnosis, moreover, it was almost free from the kernel parameter of support vector machine (SVM). While the spectrum features and texture features were directly inputted to SVM classifier, the fault recognition rate can be reached to only 92.86% and 89.29%, respectively. This study provides an effective and useful feature extraction method for engine fault diagnosis.

Key words: engines, fault diagnosis, feature extraction, generalized discriminant analysis (GDA), feature fusion