

文章编号:1000-8055(2013)12-2759-12

基于正则化多核判别分析的航空发动机 滚动轴承早期故障融合诊断方法

郝腾飞¹, 陈 果¹, 廖仲坤², 程小勇¹, 赵 斌¹, 王海飞¹

(1. 南京航空航天大学 民航学院, 南京 210016;

2. 中国航天科工集团公司 飞航技术研究院 北京动力机械研究所, 北京 100074)

摘 要: 针对基于机匣测点信号的航空发动机滚动轴承早期故障诊断问题, 提出了一种基于正则化多核判别分析的融合诊断方法. 该方法首先提取多种类型的滚动轴承故障特征; 然后采用相同的一组核参数为不同类型的特征分别构造一组核矩阵, 并将所有核矩阵组合在一起; 最后通过求解一个半无限线性规划得到该组核矩阵关于正则化核判别分析的目标函数的最优线性组合系数, 进一步采用该系数计算所有核矩阵的线性组合, 从而实现多种类型特征信息的融合. 实验结果表明: 该方法诊断正确率与采用单一类型特征诊断的最高正确率相比提高了 9.25%, 同时可以避免核矩阵需要人工选择的问题, 从而进一步提高了故障诊断的自动化水平.

关 键 词: 航空发动机; 滚动轴承; 融合诊断; 多核学习; 正则化核判别分析

中图分类号: V263.6

文献标志码: A

Approach for incipient fusion fault diagnosis of rolling bearing of aero-engine based on regularized multiple kernel discriminant analysis

HAO Teng-fei¹, CHEN Guo¹, LIAO Zhong-kun²,
CHENG Xiao-yong¹, ZHAO Bin¹, WANG Hai-fei¹

(1. College of Civil Aviation,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. Beijing Power Machinery Research Institute,

Aerodynamic Missile Technology Academy,

China Aerospace Science and Industry Corporation, Beijing 100074, China)

Abstract: To solve the problem of incipient fault diagnosis of rolling bearing of aero-engine based on the testing signal from engine case, a fusion fault diagnosis approach based on regularized multiple kernel discriminant analysis was proposed. In this method, firstly, several different types of features for the fault diagnosis of rolling bearing are extracted. Secondly, for each of these types of features, a group of kernel matrices are computed by the same set of kernel parameters respectively, then all of the kernel matrices are combined together. Finally, the optimal linear combination coefficients of the kernel matrices for the objective function of regularized kernel discriminant analysis are obtained by solving a semi-infi-

收稿日期: 2012-11-12

网络出版地址: <http://www.cnki.net/kcms/detail/11.2297.V.20131111.1602.018.html>

基金项目: 国家自然科学基金(61179057)

作者简介: 郝腾飞(1983—), 男, 河南林州人, 博士生, 主要从事航空发动机状态监测与故障诊断研究.

nite linear program, then the linear combination of the kernel matrices was obtained by the combination coefficients to fuse the information of different types of features. The experimental results demonstrate that the proposed fusion fault diagnosis method can improve the accuracy of fault diagnosis about 9.25% significantly when compared with the diagnosis method using a single type of features, and can also improve the level of automation of fault diagnosis by avoiding the problem that kernel matrix must be selected manually.

Key words: aero-engine; rolling bearing; fusion diagnosis;
multiple kernel learning; regularized kernel discriminant analysis

滚动轴承是航空发动机中的一种重要部件,高转速、高负荷和高温的工作环境决定了滚动轴承在工作过程中易出现各种故障.若能在滚动轴承故障发生的早期,即对发动机性能产生影响较小,没有造成飞行事故之前,将其诊断出来并及时采取应对措施,制定维修决策,将有效地降低事故发生率^[1].

基于振动信号进行滚动轴承故障诊断是一种非常有效的方法.这种方法一般涉及到两个方面的问题:一是利用信号分析技术进行故障特征提取;二是利用模式识别技术进行状态识别.在特征提取方面,首先,直接计算滚动轴承原始振动信号的峰值指标、脉冲指标、峭度指标等时域特征是一种简单而有效的特征提取方法^[2];其次,当滚动轴承发生故障时,其振动信号的包络谱中同样含有丰富的故障特征信息,通过在包络谱中寻找不同部件的故障特征频率可以实现对滚动轴承不同部件故障的准确定位^[3-4];再次,当滚动轴承发生局部损伤时,受载运行过程中产生的冲击会激起系统的高频固有振动,从而会导致不同频带的能量分布发生变换,因此也可以通过提取滚动轴承振动信号不同频带的能量特征进行故障诊断^[5].除以上三种常用的反映滚动轴承故障的特征外,一些学者还提出了一些其他类型的特征,这些特征均是利用经验模式分解^[6]来构造的,即首先采用经验模式分解对原始振动信号进行分解,得到一系列本征模函数,然后从本征模函数中提取滚动轴承故障的特征.例如对由本征模函数构成的矩阵进行奇异值分解,将分解得到的奇异值作为滚动轴承故障的特征^[7].对各个本征模函数建立AR(auto-regressive)模型,然后提取AR模型的自回归参数和残差的方差作为滚动轴承故障的特征^[8];计算本征模函数的Renyi熵并将其作为滚动轴承故障的特征^[9]等.在状态识别方面,核方法^[10]是模式识别领域的一场革命,其首先通过核函数将原始样本隐含地映射到一个高维特征空间,然后在该空间中执行相应的线性算法.由于核

函数隐含地实现了一个非线性映射,同时又避开了维数灾难,因此,核方法可以高效地解决非线性模式识别问题.目前,许多核方法已被应用于航空发动机或滚动轴承故障诊断的状态识别^[4,8-9,11-13].

基于振动信号对航空发动机滚动轴承进行故障诊断时,通常是通过安装在滚动轴承附近的发动机机匣上的振动传感器测取振动信号.由于航空发动机的结构非常复杂,振动传递过程中要通过柔性支承结构,并且振动传递路线较长,导致所测得的与滚动轴承状态有关的信号通常比较微弱并包含有较多的噪声^[14].在这种情况下,如果仅提取单一类型的特征进行故障诊断,一般难以取得较高的诊断正确率.而根据上文,当滚动轴承发生故障时,其振动信号会从多个角度(如时域、包络谱、能量的角度)表现出故障特征,如果能够利用不同类型特征的互补性,融合多种类型的特征进行诊断,可望显著提高诊断的正确率.因此,为提高航空发动机滚动轴承故障诊断的正确率,有必要研究提取多种类型特征进行融合诊断的方法.目前,针对航空发动机故障融合诊断问题,已有一些方法被提出,例如基于证据理论的方法^[1,15-19]和基于神经网络的方法^[20-21].

多核学习方法^[22-26]是核方法发展的新阶段.其基本思想为:事先给定一组核矩阵,然后通过求解一个凸优化问题得到该组核矩阵在某个准则下的最优线性组合.与传统的单核学习方法相比,多核学习方法的意义主要在于两个方面:一是实现了核矩阵的自动选择;二是提供了一种信息融合的新方法.正则化多核判别分析^[27-28]是正则化核判别分析^[29-30]的多核推广.基于此,本文提出了一种基于正则化多核判别分析的航空发动机滚动轴承早期故障融合诊断方法.该方法的主要思想为:对于滚动轴承的振动信号,首先提取多种类型的特征,然后采用相同的一组核参数为不同类型的特征分别构造一组核矩阵,最后将多组核矩阵组合在一起,通过多核学习得到一个在正则化核

判别分析的目标函数下的最优核矩阵(以一组核矩阵的线性组合表示),从而实现不同类型特征之间的融合.该方法的有效性通过一个具体的航空发动机滚动轴承故障诊断实例进行了验证.

1 正则化多核判别分析

正则化核判别分析^[29-30]的基本原理为:首先使用核技巧将原始样本隐含地映射到一个高维特征空间;然后在该空间中寻找一组投影方向,使得特征空间中的样本向该组方向投影后,不同类别的样本尽量远离,同类样本尽量靠近,即使样本之间的判别性最大化.

给定 n 个训练样本 $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$, 其中 $\mathbf{x}_i$ 表示第 i 个训练样本的示例, $\mathbf{x}_i \in \mathbb{R}^d$; y_i 表示第 i 个训练样本的类别标记, $y_i \in \{1, 2, \dots, k\}$, n 为样本个数, d 为样本维数, k 为类别数. 令 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$ 表示训练样本矩阵, $\phi_K(\cdot)$ 表示由核函数 K 隐含定义的非线性映射, 则在正则化核判别分析中, 通常最大化以下目标函数^[28]:

$$F(\mathbf{W}) = \text{trace}\{[\mathbf{W}^T(\mathbf{S}_t^\phi + \lambda \mathbf{I})\mathbf{W}]^{-1}\mathbf{W}^T\mathbf{S}_b^\phi\mathbf{W}\} \quad (1)$$

式中 $\mathbf{W}$ 为投影矩阵, λ 为正则化参数, $\mathbf{I}$ 为单位矩阵, $\mathbf{S}_t^\phi$ 为特征空间中的整体离散度矩阵

$$\mathbf{S}_t^\phi = \phi_K(\mathbf{X})\mathbf{P}\phi_K(\mathbf{X})^T \quad (2)$$

式中 $\mathbf{P} = \mathbf{I} - \frac{1}{n}\mathbf{e}_n\mathbf{e}_n^T$, $\mathbf{e}_n$ 是分量全部为 1 的 n 维列向量. $\mathbf{S}_b^\phi$ 为特征空间中的类间离散度矩阵

$$\mathbf{S}_b^\phi = \phi_K(\mathbf{X})\mathbf{H}\mathbf{H}^T\phi_K(\mathbf{X})^T \quad (3)$$

式中 $\mathbf{H} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_k]$, $\mathbf{h}_i$ 为 n 维列向量, 其第 j 个分量由下式决定:

$$\mathbf{h}_i(j) = \begin{cases} \sqrt{\frac{n}{n_i}} - \sqrt{\frac{n_i}{n}} & \text{如果第 } j \text{ 个样本属于第 } i \text{ 类} \\ -\sqrt{\frac{n_i}{n}} & \text{否则} \end{cases} \quad (4)$$

$\text{trace}(\cdot)$ 表示矩阵的迹.

对于某一特定的核矩阵 $\mathbf{G}$ 和正则化参数 λ , 正则化核判别分析的目标函数的最大值为

$$F^*(\mathbf{G}, \lambda) = \text{trace}[(\mathbf{G}\mathbf{P}\mathbf{G} + \lambda\mathbf{G})^{-1}\mathbf{G}\mathbf{H}\mathbf{H}^T\mathbf{G}] \quad (5)$$

为使投影之后的样本具有最佳的判别性, 需要恰当地选择核矩阵 $\mathbf{G}$ 和正则化参数 λ , 使得式(5)最大化. 目前, 核矩阵 $\mathbf{G}$ 和正则化参数 λ 一般通过交

叉验证的方法选取. 然而, 该方法计算量很大, 并且只能在给定的多组参数中选择一组最优的参数, 因此, 无法保证找到全局最优的参数.

多核学习^[22-26]是近年来出现的一种解决核矩阵选择问题的新方法, 其基本思想为: 事先给定一组核矩阵, 然后通过求解一个凸优化问题得到该组核矩阵关于某个性能度量准则的最优线性组合. Kim 等^[27]和 YE 等^[28]将多核学习的思想引入正则化核判别分析, 提出了正则化多核判别分析.

给定 p 个核矩阵 $\mathbf{G}_1, \dots, \mathbf{G}_p$, 在正则化多核判别分析中, 核矩阵以事先给定的一组核矩阵的线性组合表示

$$\tilde{\mathbf{G}} = \left\{ \tilde{\mathbf{G}} = \sum_{i=1}^p \theta_i \mathbf{G}_i \mid \sum_{i=1}^p \theta_i r_i = 1, \theta_i \geq 0 \right\} \quad (6)$$

式中 $\tilde{\mathbf{G}}_i = \mathbf{P}\mathbf{G}_i\mathbf{P}$, $r_i = \text{trace}(\tilde{\mathbf{G}}_i)$, $\mathbf{P} = \mathbf{I} - \frac{1}{n}\mathbf{e}_n\mathbf{e}_n^T$, $\mathbf{e}_n$ 是分量全部为 1 的 n 维列向量.

根据式(6), 求解最优的核矩阵转化为求解最优的线性组合系数. 根据 YE 等^[28]的研究, 使式(5)取得最大值的最优线性组合系数和正则化参数可通过求解以下半无限线性规划(semi-infinite linear programming, SILP)问题获得

$$\begin{aligned} & \max_{\tilde{\mathbf{G}}, \gamma} \gamma \\ & \text{Subject to } \tilde{\mathbf{G}} \geq 0, \\ & \tilde{\mathbf{G}}^T \mathbf{r} = 1, \\ & \sum_{i=0}^p \theta_i S_i(\boldsymbol{\beta}) \geq \gamma, \text{ for all } \boldsymbol{\beta} \end{aligned} \quad (7)$$

式中 $S_i(\boldsymbol{\beta}) = \sum_{j=1}^k \left[\frac{1}{4} \boldsymbol{\beta}_j^T \tilde{\mathbf{G}}_i \boldsymbol{\beta}_j - r_i \boldsymbol{\beta}_j^T \mathbf{h}_j \right]$, $i = 0, \dots, p$; $\gamma = \min_{\boldsymbol{\beta}} \sum_{i=0}^p \theta_i S_i(\boldsymbol{\beta})$; $\mathbf{r} = [r_0, \dots, r_p]^T$, $r_i = \text{trace}(\tilde{\mathbf{G}}_i)$; $\tilde{\mathbf{G}} = [\theta_0, \theta_1, \dots, \theta_p]^T$, $\theta_0 = \lambda$; $\tilde{\mathbf{G}}_0 = \mathbf{I}$; $\boldsymbol{\beta}$ 为 Lagrange 乘子向量.

关于正则化多核判别分析的详细推导参见文献^[28].

2 基于正则化多核判别分析的融合诊断方法

本文提出的基于正则化多核判别分析的融合诊断方法的流程如图 1 所示. 从图中可以看出, 该方法包括三个阶段: 特征提取及初始核矩阵集合构造阶段、模型训练阶段和融合诊断阶段.




图1 基于正则化多核判别分析的融合诊断方法的流程

Fig. 1 Flow chart of the fusion diagnosis approach based on regularized multiple kernel discriminant analysis

在特征提取及初始核矩阵集合构造阶段,首先使用振动传感器从机匣上某个合适位置采集发动机运行的振动信号;然后从采集的振动信号中分别提取三种类型的滚动轴承故障特征:五个无量纲时域特征、四个本征模函数(intrinsic mode function, IMF)包络谱特征、四个IMF能量特征;最后采用相同的一组核参数为不同类型的特征分别构造一组核矩阵,然后将三组核矩阵组合到一起作为下面进行特征融合的初始核矩阵集合。

提取的五个无量纲时域特征分别为:波形指标、峰值指标、脉冲指标、裕度指标、峭度指标。

提取的四个IMF包络谱特征分别为IMF包络谱中旋转频率的包络谱值、外圈故障特征频率的包络谱值、内圈故障特征频率的包络谱值、滚动体故障特征频率的包络谱值。IMF包络谱特征的

具体提取方法如下:

1) 确定要计算的IMF数量 N 。由于采用经验模态分解(empirical mode decomposition, EMD)方法对原始振动信号进行分解得到的IMF分量依频率从高到低排列,且滚动轴承的故障信息主要包含在高频IMF分量中,因此本文选择前四个IMF分量进行计算,即取 $N=4$ 。

2) 获取各IMF分量的包络谱。首先采用EMD方法对原始振动信号进行分解,得到一系列IMF分量;然后对前 N 个IMF分量分别进行Hilbert变换和傅里叶变换,得到各IMF分量的包络谱。

3) 从各IMF分量的包络谱中提取相应的包络谱值。由于滚动轴承的旋转频率和理论计算的故障特征频率与实际IMF包络谱中的旋转频率

和故障特征频率可能存在一定差异,因此旋转频率和故障特征频率的包络谱值需要在一定的频率范围内寻找,设其频率误差最大为 Δf ,本文取 $\Delta f=2\text{Hz}$. 令 $W_l(f)$ 表示第 l 个 IMF 分量的包络谱, f_r, f_o, f_i, f_b 分别表示旋转频率、外圈故障特征频率、内圈故障特征频率和滚动体故障特征频率, $F_{l1}, F_{l2}, F_{l3}, F_{l4}$ 分别表示第 l 个 IMF 分量的包络谱中旋转频率的包络谱值、外圈故障特征频率的包络谱值、内圈故障特征频率的包络谱值和滚动体故障特征频率的包络谱值,则相应的包络谱值可以根据下式提取:

$$\begin{cases} F_{l1} = \max W_l(f_r - \Delta f \leq f \leq f_r + \Delta f) \\ F_{l2} = \max W_l(f_o - \Delta f \leq f \leq f_o + \Delta f) \\ F_{l3} = \max W_l(f_i - \Delta f \leq f \leq f_i + \Delta f) \\ F_{l4} = \max W_l(f_b - \Delta f \leq f \leq f_b + \Delta f) \end{cases} \quad (8)$$

4) 将各 IMF 分量的包络谱中相应包络谱值的最大值作为最终的特征值. 提取出前 N 个 IMF 分量的各个包络谱值后,根据人工诊断经验,当观察到某个 IMF 分量的包络谱中出现了某种故障的特征频率,并且取值比较大时,即可判断该故障发生,据此,可以比较所有 IMF 分量的包络谱中相应的包络谱值,将其最大值作为最终的特征值,即

$$\bar{F}_i = \max_l F_{li} \quad l = 1, 2, \dots, N; \quad i = 1, 2, 3, 4 \quad (9)$$

5) 将上述四个 IMF 包络谱值构成一个特征向量,即

$$\bar{\mathbf{F}} = [\bar{F}_1, \bar{F}_2, \bar{F}_3, \bar{F}_4] \quad (10)$$

6) 对 IMF 包络谱值进行归一化处理,即

$$\mathbf{F} = [\bar{F}_1 / \max_i \bar{F}_i, \bar{F}_2 / \max_i \bar{F}_i, \bar{F}_3 / \max_i \bar{F}_i, \bar{F}_4 / \max_i \bar{F}_i] \quad i = 1, 2, 3, 4 \quad (11)$$

提取的四个 IMF 能量特征分别是采用 EMD 方法对原始振动信号进行分解得到的前四个 IMF 分量的相对能量. IMF 能量特征的具体计算方法如下:

1) 确定要计算的 IMF 数量 N , 本文取 $N=4$.

2) 采用 EMD 方法对原始振动信号进行分解,得到一系列 IMF 分量.

3) 根据下式计算前 N 个 IMF 分量的能量

$$\bar{E}_i = \sum_{n=1}^M |c_i(n)|^2; \quad i = 1, 2, \dots, N \quad (12)$$

式中 $c_i(n)$ 表示第 i 个 IMF 分量, M 表示 IMF 分量的长度.

4) 将 N 个 IMF 能量值构成一个特征向量

$$\bar{\mathbf{F}} = [\bar{E}_1, \bar{E}_2, \dots, \bar{E}_N] \quad (13)$$

5) 计算相对能量

$$\mathbf{F} = [\bar{E}_1 / E, \bar{E}_2 / E, \dots, \bar{E}_N / E] \quad (14)$$

其中 $E = \sum_{i=1}^N \bar{E}_i$.


在模型训练阶段. 首先,在由训练样本计算得到的初始核矩阵集合的基础上,求解式(7)中的半无限线性规划,得到最优的正则化参数和最优的核矩阵组合系数;然后,采用最优的核矩阵组合系数计算训练阶段的最优核矩阵;接着,进一步采用最优的正则化参数和最优的核矩阵,求解正则化核判别分析,得到最优的投影矩阵;最后,基于最优的投影矩阵,将训练样本投影到一个最优的子空间,得到子空间中的训练样本,在该子空间内,训练样本具有最佳的判别性.

在融合诊断阶段. 首先,在由待诊断样本和训练样本计算得到的核矩阵集合的基础上,采用训练阶段得到的最优核矩阵组合系数,计算融合诊断阶段的最优核矩阵;然后,采用训练阶段求解得到的最优投影矩阵,将待诊断样本投影到一个最优的子空间,得到子空间中的待诊断样本;最后,在该子空间内,采用最近邻分类器进行故障识别.


3 融合诊断实例

3.1 实验数据获取

为验证所提方法的有效性,基于航空发动机压气机实验器进行了滚动轴承故障模拟实验,获取了滚动轴承实验数据. 航空发动机压气机实验器如图 2 所示,是由哈尔滨东安发动机(集团)有限公司航空产品设计所研制. 在实验器中,电动机、增速器、转矩转速传感器、传动轴联轴器和压气机依次连接,实验器通过增速器增速后,经转矩转速传感器带动压气机旋转. 实验中使用了四个轴承,其中一个为正常轴承,另外三个轴承分别使



(a) 实验器组成



(b) 压气机

图2 航空发动机压气机实验器

Fig.2 Aero-engine compressor test rig

用电火花线切割技术在外圈、内圈和滚动体上加工有凹槽,以模拟外圈故障、内圈故障和滚动体故障.通过安装在压气机机匣上的振动加速度传感器获取了滚动轴承在四种状态下(正常状态、外圈故障、内圈故障和滚动体故障)的振动信号,各种状态下原始振动信号的典型时域波形如图3所示.




图3 原始振动信号的时域波形

Fig.3 Time domain waveform of original vibration signals

3.2 特征提取

本节通过分别提取图3中四个滚动轴承振动信号的 IMF 包络谱特征和 IMF 能量特征,表明融合多种类型特征进行诊断的必要性.首先采用 EMD 方法对图3中的四个振动信号进行分解,得到的前四个 IMF 分量如图4所示,进一步对这些 IMF 分量进行 Hilbert 变换和傅里叶变换,得到的各 IMF 分量的包络谱如图5所示.

从图5可以看出,当滚动轴承无故障时,在前四个 IMF 分量的包络谱中均没有明显表现出任一部件的故障特征频率,在第2个 IMF 分量的包络谱中可以清楚地发现滚动轴承的旋转频率 f_r ;当滚动轴承存在外圈故障时,在前4个 IMF 分量的包络谱中均可以清楚地发现外圈的故障特征频率 f_o ,其中,在第1个 IMF 分量的包络谱中还可以清楚地发现 $2f_o$ 和 $3f_o$;当滚动轴承存在内圈故障时,在第1个 IMF 分量的包络谱中可以清楚地发现内圈的故障特征频率 f_i 和 $2f_i$;当滚动轴承存在滚动体故障时,在前4个 IMF 分量的包络谱中均没有明显表现出滚动体的故障特征频率 f_b ,只有在第2个 IMF 分量的包络谱中表现出了滚动轴承的旋转频率 f_r .

进一步基于各 IMF 分量的包络谱提取四个信号的 IMF 包络谱特征,结果如图6所示,图中的横坐标 1,2,3,4 分别表示旋转频率、外圈故障特征频率、内圈故障特征频率和滚动体故障特征频率.可以看出,图6中提取的 IMF 包络谱特征与图5中反映的滚动轴承状态信息完全一致:当滚动轴承无故障时,旋转频率的包络谱值 F_1 为1,其他包络谱值均较小;当滚动轴承存在外圈故障时,外圈故障特征频率的包络谱值 F_2 为1,其他包络谱值均较小;当滚动轴承存在内圈故障时,内圈故障特征频率的包络谱值 F_3 为1,其他包络谱值均较小;当滚动轴承存在滚动体故障时,由于相应的包络谱中没有明显地表现出滚动体的故障特征频率,导致旋转频率的包络谱值 F_1 为1,其他包络谱值均较小,此时容易将滚动体故障误判为正常状态.总之,从图5和图6可以看出,采用 IMF 包络谱特征可以准确地诊断出外圈故障和内圈故障,但难以诊断出滚动体故障,因此,有必要进一步提取其他类型的特征进行诊断.

进一步计算图3中四个振动信号的 IMF 能量特征,结果如图7所示.可以看出,当滚动轴承无故障时,第2个和第3个 IMF 分量的能量较大,第1个和第4个 IMF 分量的能量稍小,但总的





图 4 采用 EMD 对原始振动信号进行分解得到的前 4 个 IMF 分量

Fig. 4 First 4 IMF components obtained by the decomposition of original vibration signals through EMD






图5 前4个IMF分量的包络谱

Fig. 5 Envelope spectrum of the first 4 IMF components




图6 IMF包络谱特征

Fig. 6 IMF envelope spectrum features




图7 IMF能量特征

Fig. 7 IMF energy features

来说,滚动轴承振动信号的能量在4个IMF分量之间分布相对比较均匀。由于存在故障的滚动轴承在运行时会激起系统的高频固有振动,因此,当滚动轴承存在外圈故障、内圈故障或滚动体故障时,高频成分的能量显著增加,低频成分的能量相应减少,滚动轴承振动信号的能量主要集中在第1个

IMF分量,其他3个IMF分量的能量均较小。

综合图6和图7进行分析可知,IMF包络谱特征对于诊断外圈故障和内圈故障非常理想,但是对于诊断滚动体故障不是很好;IMF能量特征对于区分滚动轴承是正常状态还是发生故障非常有效,但是对于区分具体是哪一种故障不是十分

理想. 对于采用 IMF 包络谱特征不太容易区分的滚动体故障和正常状态, 采用 IMF 能量特征却很容易区分出来. 因此, 在滚动轴承故障诊断中, 有必要融合多种类型的特征进行诊断.

3.3 融合诊断

为进行融合诊断实验, 分别获取滚动轴承在正常、外圈故障、内圈故障和滚动体故障情况下的样本各 200 个, 对于每一种情况下的样本, 随机选取 100 个样本用于训练, 剩下的 100 个样本用于测试, 即训练样本和测试样本均为 400 个. 实验中, 核函数选取高斯径向基核函数 (Gaussian RBF kernel), 对于无量纲时域特征、IMF 包络谱特征、IMF 能量特征, 分别采用参数 0.10, 0.22, 0.46, 1.00, 2.15, 4.46, 10.00, 21.54, 46.42, 100.00 构造 10 个核矩阵. 为验证融合诊断方法的有效性, 同时使用三种单一类型的特征进行诊断. 在采用单一类型特征进行诊断时, 仅使用每一种类型特征对应的 10 个核矩阵; 在进行融合诊断时, 使用所有的 30 个核矩阵. 采用不同类型特

征进行诊断时, 测试样本投影到子空间后的结果如图 8 所示, 学习到的核矩阵系数如图 9 所示, 最终的诊断正确率如表 1 所示.

从图 8 可以看出, 无量纲时域特征对于外圈故障和其他状态之间具有较好的区分性, 对于内圈故障和其他状态之间也有一定的区分性, 但是对于正常状态和滚动体故障之间几乎没有区分性, 最终的诊断正确率仅为 61.00%; IMF 包络谱特征对于外圈故障和其他状态之间具有非常好的区分性, 对于内圈故障和其他状态之间也具有比较好的区分性, 但是对于正常状态和滚动体故障之间的区分性比较差, 最终的诊断正确率为 82.25%; IMF 能量特征对于正常状态和其他故障状态之间的区分性非常好, 但是对于外圈故障、内圈故障和滚动体故障之间的区分性不是十分理想, 最终的诊断正确率为 90.75%. 对比 IMF 包络谱特征和 IMF 能量特征的投影结果, 可以看出, 这两种特征的互补性非常强. 在多种类型特征融合下, 滚动轴承四种状态相互之间的区分性均




图 8 采用不同类型特征进行诊断时测试样本的投影结果

Fig. 8 Projection results of testing examples when diagnosis is performed by different types of features




图9 采用不同类型特征进行诊断时学习到的核矩阵系数

Fig. 9 Learned coefficients of kernel matrix when diagnosis is performed by different types of features

表1 不同方法的诊断正确率
Table 1 Accuracy of fault diagnosis with different methods


诊断方法	诊断正确率/%
无量纲时域特征	61.00
IMF 包络谱特征	82.25
IMF 能量特征	90.75
多种特征特征融合	100.00

非常好,最终的诊断正确率达到了100.00%,明显高于采用任何单一类型特征进行诊断的结果。


从图9可以看出,当采用单一类型特征进行诊断时,大部分核矩阵的系数为0,其中,对于无量纲时域特征和IMF能量特征,只有第一个核矩阵的系数不为0,表明采用同一类型的特征构造的多个核矩阵很少提供互补的信息。当采用多种类型的特征进行融合诊断时,虽然大部分核矩阵的系数也为0,但是在每一种类型特征对应的核矩阵中至少有一个核矩阵的系数不为0,表明在进行融合诊断时三种不同类型的特征均可以提供互补的信息。

为进一步验证基于正则化多核判别分析的融

合诊断方法可以实现核矩阵的自动选择,对于三种单一类型的特征,分别采用构造的10个核矩阵中的每一个单一核矩阵进行诊断,结果如图10所



(a) 无量纲时域特征



(b) IMF包络谱特征




图10 采用单一类型特征进行诊断时的单核学习与多核学习的诊断正确率

Fig. 10 Accuracy of single kernel learning and multiple kernel learning when diagnosis is performed by a single type of features

示。从图中可以看出,对于三种单一类型的特征,多核学习的诊断正确率均高于或等于采用单一核矩阵进行诊断的最高诊断正确率,表明正则化多核判别分析可以有效地实现核矩阵的自动选择。

4 结 论

1) 针对基于机匣测点信号的航空发动机滚动轴承早期故障诊断问题,本文提出了一种基于正则化多核判别分析的融合诊断方法。该方法采用相同的一组核参数为不同类型的特征分别构造一组核矩阵,然后将所有核矩阵组合到一起,最后通过对该组核矩阵的融合来实现多特征信息的融合。

2) 基于机匣测点信号对航空发动机滚动轴承早期故障进行诊断时,仅采用单一类型的特征通常难以取得较高的诊断正确率,而采用多种类型的特征,基于正则化多核判别分析进行融合诊断可以显著提高诊断的正确率。

3) 基于正则化多核判别分析进行融合诊断时,最优的核矩阵以事先给定的一组核矩阵的线性组合表示,其组合系数可以通过求解一个半无限线性规划获得,因此,所提融合诊断方法实现了核矩阵的自动选择,从而可以进一步提高故障诊断的自动化水平。

参考文献:

[1] 翟旭升,胡金海,谢寿生,等.基于DSmT的航空发动机早期振动故障融合诊断方法[J].航空动力学报,2012,27(1):1-6.
ZHAI Xusheng, HU Jinhai, XIE Shousheng, et al. Diagnosis of aero-engine with early vibration fault symptom using DSmT[J]. Journal of Aerospace Power, 2012, 27(1): 1-6.

(in Chinese)

[2] 易良策. 简易振动诊断现场实用技术[M]. 北京:机械工业出版社,2003.

[3] 陈果. 滚动轴承早期故障的特征提取与智能诊断[J]. 航空学报,2009,30(2):362-367.
CHEN Guo. Feature extraction and intelligent diagnosis for ball bearing early faults[J]. Acta Aeronautica et Astronautica Sinica, 2009, 30(2): 362-367. (in Chinese)

[4] 杨宇,王欢欢,程军圣,等. 基于LMD的包络谱特征值在滚动轴承故障诊断中的应用[J]. 航空动力学报,2012,27(5):1153-1158.
YANG Yu, WANG Huanhuan, CHENG Junsheng, et al. Application of envelope spectrum characteristics based on LMD to roller bearing fault diagnosis[J]. Journal of Aerospace Power, 2012, 27(5): 1153-1158. (in Chinese)

[5] YANG Yu, YU Dejie, CHENG Junsheng. A roller bearing fault diagnosis method based on EMD energy entropy and ANN[J]. Journal of Sound and Vibration, 2006, 294(1): 269-277.

[6] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.

[7] 杨宇,于德介,程军圣. 基于EMD的奇异值分解技术在滚动轴承故障诊断中的应用[J]. 振动与冲击, 2005, 24(2): 12-16.
YANG Yu, YU Dejie, CHENG Junsheng. Application of EMD based singular value decomposition technique to fault diagnosis for roller bearing[J]. Journal of Vibration and Shock, 2005, 24(2): 12-16. (in Chinese)

[8] 程军圣,于德介,杨宇. 基于EMD和SVM的滚动轴承故障诊断方法[J]. 航空动力学报,2006,21(3):575-580.
CHENG Junsheng, YU Dejie, YANG Yu. Fault diagnosis of roller bearing based on EMD and SVM[J]. Journal of Aerospace Power, 2006, 21(3): 575-580. (in Chinese)

[9] 王太勇,何慧龙,王国锋,等. 基于经验模式分解和最小二乘支持向量机的滚动轴承故障诊断[J]. 机械工程学报, 2007, 43(4): 88-92.
WANG Taiyong, HE Huilong, WANG Guofeng, et al. Rolling-bearings fault diagnosis based on empirical mode decomposition and least square support vector machine[J]. Chinese Journal of Mechanical Engineering, 2007, 43(4): 88-92. (in Chinese)

[10] Muller K R, Mika S, Ratsch G, et al. An introduction to kernel-based learning algorithms[J]. IEEE Transactions on Neural Networks, 2001, 12(2): 181-201.

[11] HU Qiao, HE Zhengjia, ZHANG Zhousuo, et al. Fault diagnosis of rotating machinery based on improved wavelet package transform and SVMs ensemble[J]. Mechanical Systems and Signal Processing, 2007, 21(2): 688-705.

[12] 陶新民,杜宝祥,徐勇. 基于HOS奇异值谱的SVDD轴承故障检测方法[J]. 振动工程学报, 2008, 21(2): 203-208.

- TAO Xinmin, DU Baoxiang, XU Yong. Bearing fault detection using SVDD based on HOS-singular value spectrum[J]. Journal of Vibration Engineering, 2008, 21(2): 203-208. (in Chinese)
- [13] 孙超英, 刘鲁, 刘传武, 等. 基于 Boosting-SVM 算法的航空发动机故障诊断[J]. 航空动力学报, 2010, 25(11): 2584-2588.
- SUN Chaoying, LIU Lu, LIU Chuanwu, et al. Aero-engine fault diagnosis based on boosting-SVM[J]. Journal of Aerospace Power, 2010, 25(11): 2584-2588. (in Chinese)
- [14] 卢艳辉, 尹泽勇. 基于小波包分析方法的航空发动机滚动轴承故障诊断[J]. 燃气涡轮试验与研究, 2005, 18(1): 35-38.
- LU Yanhui, YIN Zeyong. Fault diagnosis of aero-engine rolling element bearing based on the wavelet packet analysis[J]. Gas Turbine Experiment and Research, 2005, 18(1): 35-38. (in Chinese)
- [15] 陈果. 基于神经网络和 D-S 证据理论的发动机磨损故障融合诊断[J]. 航空动力学报, 2005, 20(2): 303-308.
- CHEN Guo. Fusion diagnosis of engine wearing fault based on neural networks and D-S evidence theory[J]. Journal of Aerospace Power, 2005, 20(2): 303-308. (in Chinese)
- [16] 杨建平, 黄洪钟, 苗强, 等. 基于证据理论的航空发动机早期故障诊断方法[J]. 航空动力学报, 2008, 23(12): 2327-2331.
- YANG Jianping, HUANG Hongzhong, MIAO Qiang, et al. Diagnosis method of aeroengine early fault based on the Dempster-Shafer evidence theory[J]. Journal of Aerospace Power, 2008, 23(12): 2327-2331. (in Chinese)
- [17] 陈立波, 宋兰琪, 陈果. 航空发动机滑油综合监控中的磨损故障融合诊断研究[J]. 航空动力学报, 2009, 24(1): 169-175.
- CHEN Libo, SONG Lanqi, CHEN Guo. Study on fusion diagnosis techniques of wear faults in synthesized monitoring of aero-engine[J]. Journal of Aerospace Power, 2009, 24(1): 169-175. (in Chinese)
- [18] 鲁峰, 黄金泉, 陈煜. 航空发动机部件性能故障融合诊断方法研究[J]. 航空动力学报, 2009, 24(7): 1649-1653.
- LU Feng, HUANG Jinquan, CHEN Yu. Research on performance fault fusion diagnosis of aero-engine component[J]. Journal of Aerospace Power, 2009, 24(7): 1649-1653. (in Chinese)
- [19] 王古常, 成坚, 鲍传美, 等. 模糊推理和证据理论融合的航空发动机故障诊断[J]. 航空动力学报, 2011, 26(9): 2101-2106.
- WANG Guchang, CHENG Jian, BAO Chuanmei, et al. Diagnosis method of aero-engine fault based on fuzzy inference and evidence theory[J]. Journal of Aerospace Power, 2011, 26(9): 2101-2106. (in Chinese)
- [20] 赵世荣, 黄向华. 应用神经网络信息融合诊断航空发动机故障[J]. 航空动力学报, 2008, 23(1): 163-168.
- ZHAO Shirong, HUANG Xianghua. Fault diagnosis for aeroengine gas path components based on neural network multisensory data fusion[J]. Journal of Aerospace Power, 2008, 23(1): 163-168. (in Chinese)
- [21] 曲建岭, 唐昌盛, 肖辉雄, 等. 人工神经网络融合诊断航空发动机气路故障[J]. 航空动力学报, 2008, 23(11): 2124-2127.
- QU Jianling, TANG Changsheng, XIAO Huixiong, et al. Integrated diagnosis of aeroengines' gas path faults using artificial neural network[J]. Journal of Aerospace Power, 2008, 23(11): 2124-2127. (in Chinese)
- [22] Lanckriet G R G, Cristianini N, Bartlett P, et al. Learning the kernel matrix with semidefinite programming[J]. Journal of Machine Learning Research, 2004, 5(1): 27-72.
- [23] Sonnenburg S, Ratsch G, Schafer C, et al. Large scale multiple kernel learning[J]. Journal of Machine Learning Research, 2006, 7(7): 1531-1565.
- [24] Zien A, Ong C S. Multiclass multiple kernel learning[C]// Proceedings of the 24th International Conference on Machine learning. New York, USA: ACM, 2007: 1191-1198.
- [25] Rakotomamonjy A, Bach F R, Canu S, et al. Simple MKL[J]. Journal of Machine Learning Research, 2008, 9(11): 2491-2521.
- [26] Lin Y, Liu T L, Fuh C S. Multiple kernel learning for dimensionality reduction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(6): 1147-1160.
- [27] Kim S J, Magnani A, Boyd S. Optimal kernel selection in kernel fisher discriminant analysis[C]// Proceedings of the 23rd International Conference on Machine learning. New York, USA: ACM, 2006: 465-472.
- [28] YE Jieping, JI Shuiwang, CHEN Jianhui. Multi-class discriminant kernel learning via convex programming[J]. Journal of Machine Learning Research, 2008, 9(4): 719-758.
- [29] ZHANG Zhihua, DAI Guang, XU Congfu, et al. Regularized discriminant analysis, ridge regression and beyond[J]. Journal of Machine Learning Research, 2010, 11(8): 2199-2228.
- [30] CAI Deng, HE Xiaofei, HAN Jiawei. Speed up kernel discriminant analysis[J]. The VLDB Journal, 2011, 20(1): 21-33.