

基于小波包分析与多核学习的 滚动轴承故障诊断

郑 红¹, 周 雷¹, 杨 浩²

(1. 北京航空航天大学 自动化科学与电气工程学院, 北京 100191;

2. 中国民用航空局 中国民航科学技术研究院, 北京 100028)

摘 要: 为了更准确地诊断滚动轴承故障,提出了一种基于小波包分析与多核学习的滚动轴承故障诊断方法.该方法首先对振动信号进行 3 层小波包分解,将振动信号分解为不同频带的信号,提取各频带的相对能量特征,构建特征向量;然后采用多核学习算法从训练样本集中学习核函数与分类器;最后使用训练出的分类器识别滚动轴承故障类型.为了验证方法的有效性,进行了滚动轴承故障诊断实验,实验结果表明该方法的故障诊断准确率达到 98.25%,与传统的基于小波包与支持向量机的滚动轴承故障诊断方法相比,其故障诊断准确率更高,同时由于避免了核函数的选择问题,该方法更便于实际应用.

关 键 词: 滚动轴承; 故障诊断; 小波包; 多核学习; 故障识别

中图分类号: V231.92; TH133.3; TH165

文献标志码: A

Rolling bearing fault diagnosis based on wavelet packet analysis and multi kernel learning

ZHENG Hong¹, ZHOU Lei¹, YANG Hao²

(1. School of Automation Science and Electrical Engineering,
Beijing University of Aeronautics and Astronautics, Beijing 100191, China;

2. China Academy of Civil Aviation Science and Technology,
Civil Aviation Administration of China, Beijing 100028, China)

Abstract: To diagnose the rolling bearing fault more accurately, a method based on wavelet packet analysis and multi kernel learning was proposed for rolling bearing fault diagnosis. Firstly, the three-level wavelet packet decomposition algorithm was used to decompose the vibration signals into different frequency bands. The relative energies of each frequency band were computed to form the feature vector. Secondly, multi kernel learning was employed to learn a kernel function and classifier from the training samples. Finally, the trained classifier was used to identify the fault type of rolling bearing. To validate the proposed method, an experiment of fault diagnosis for the rolling bearings was carried out. The results show that the fault diagnosis accuracy rate of the proposed method reaches 98.25%, higher than the traditional rolling bearing fault diagnosis method based on the wavelet packet and support vector machine. Since the problem of kernel function selection is a voided, the proposed method is more convenient for practical application.

Key words: rolling bearings; fault diagnosis; wavelet packet; multi kernel learning; fault identification

滚动轴承是旋转机械中最重要、最常用的部件之一,因此,针对滚动轴承的基于振动的状态监测是一个被广泛研究的课题^[1-2].滚动轴承故障诊断实质是一个模式分类问题,即首先采集滚动轴承故障振动信号,然后提取出能够反映故障模式的特征,最后通过分类器给出诊断结果^[3].分类器的性能直接影响故障诊断的精度,因此选择性能优异的分类器具有重要意义.

支持向量机(SVM)由于结构风险最小化,具有良好的分类性能,取得了广泛的应用.然而,SVM 的分类性能受核函数的影响较大,并且核函数的选择取决于使用者的经验.多核学习(MKL)同时学习核函数与分类器,能够有效解决核函数选择的问题,同时 MKL 得到的核函数具有更大的灵活性,使其分类精度更高. MKL 最初是由 Lanckriet 等^[4]提出的,被公式化为一个二次约束二次规划(QCQP)问题,由于这是一个凸的、非光滑的优化问题,因而只适合处理小规模样本以及核的学习问题. Bach 等^[5]提出了一种类似序贯最小优化(SMO)的算法能够解决中等规模的问题. Sonnenburg 等^[6]将 MKL 问题公式化为一个半无限的线性规划(SILP)问题,通过迭代解决一个经典的 SVM 问题和一个约束数随迭代增加的线性规划问题,来解决 MKL 问题. Rakotomamonjy 等^[7]对 MKL 问题进行重新公式化,用加权 l_2 范数正则化代替混合范数正则化,得到一个凸的、光滑的优化问题,并通过混合范数正则化的变分公式证明了该公式化等价于 Lanckriet, Bach 和 Sonnenburg 等使用的公式化,同时给出了一种解决 MKL 问题的高效算法,该算法基于 SVM 目标函数值的梯度下降,并通过实例证明了其效率要优于 Sonnenburg 等提出的算法. 目前, MKL 在很多领域都有成功应用,如图像分类^[8]、遥感图像目标检测^[9]、故障诊断^[10-12]等.

本文将 MKL 应用于滚动轴承故障诊断中,提出了一种基于小波包分析与 MKL 的滚动轴承故障诊断方法,该方法首先对滚动轴承振动信号进行小波包分解,提取小波包特征,然后采用 MKL 算法从训练样本中学习核函数与分类器,最后使用分类器识别滚动轴承故障类型.

1 小波包特征提取

小波包分析是小波分析的推广.小波分析仅分解近似部分,对信号的高频部分的分辨率较差,而小波包分析同时分解近似部分和细节部分,对

信号的高频部分和低频部分都能够给出很好的分辨率.图 1 为一个两层小波包分解树.符号 d_j^n 表示第 j 层的第 n 个节点的小波包系数. f_s 表示信号的采样频率.小波包分解树中的每个节点对应一个频率范围.




图 1 两层小波包分解树

Fig. 1 Two-level wavelet packet decomposition tree

给定一个信号 $s(k)$,小波包系数能够通过下面的式(1)迭代计算出来^[13-14]:

$$\begin{aligned} d_j^{2^n}(k) &= \sum_m h(m-2k)d_{j-1}^n(m) \\ d_j^{2^{n+1}}(k) &= \sum_m g(m-2k)d_j^{2^n}(m) \end{aligned} \tag{1}$$

式中 $d_0^0(k)=s(k)$, $h(m)$ 和 $g(m)$ 是正交镜像滤波器组.

对于第 j 层的第 n 个节点,小波包系数能量为

$$E_j^n = \sum_k |d_j^n(k)|^2, n = 1, 2, \dots, 2^j - 1 \tag{2}$$

对一个 3 层小波包分解树,特征向量 $\mathbf{F}$ 表示为

$$\mathbf{F} = [E_3^0, E_3^1, \dots, E_3^7] / \sum_{i=0}^7 E_3^i \tag{3}$$

小波滤波器的长度越长,对不同频带信号分离效果越好,频带之间的混叠程度越低,但是其计算量也越大.图 2~图 3 分别为采用 db2 类型的小波和 db20 类型的小波对信号进行 3 层小波包分解时不同频带之间的混叠.从图 2~图 3 中可以看出,采用 db2 类型的小波时,混叠较严重,而使用 db20 类型的小波时,混叠较轻. db2 类型的小波滤波器的长度为 4,而 db20 类型的小波滤波器的长度为 40,使用 db20 类型的小波对信号进行 3 层小波包分解时计算量远大于采用 db2 类型的小波时的计算量.因此,在实际应用中应综合考虑计算量和频带混叠这两个因素,选择合适的小波类型.




图 2 采用 db2 类型的小波时不同频带之间的混叠
Fig. 2 Aliasing of different frequency bands using db2 wavelet




图 3 采用 db20 类型的小波时不同频带之间的混叠
Fig. 3 Aliasing of different frequency bands using db20 wavelet

2 MKL 理论

2.1 MKL 优化问题

在 SVM 方法中,判别函数的形式为^[15-16]

$$f(x) = \sum_{i=1}^l \alpha_i^* K(x, x_i) + b^* \quad (4)$$

式中 $K(\cdot, \cdot)$ 是给定的正定核,它对应一个再生核希尔伯特空间(RKHS) H ; x_i 为第 i 个训练样本; x 为待分类样本; α_i^* 和 b^* 为判别函数中的未知系数,通过求解下面优化问题的对偶问题得到

$$\begin{aligned} \min_{f, b, \xi} \quad & \frac{1}{2} \|f\|_H^2 + C \sum_i \xi_i \\ \text{s. t.} \quad & y_i [f(x_i) + b] \geq 1 - \xi_i \quad \forall i \\ & \xi_i \geq 0 \quad \forall i \end{aligned} \quad (5)$$

式中 C 为正则化参数,用来平衡分类间隔与经验误差; ξ_i 为松弛变量,引入 ξ_i 的目的是允许错分; y_i 为 x_i 的类别标签; b 为标量实数; f 为属于再生核希尔伯特空间 H 的函数。

在 MKL 框架中,所使用的核 $K(x, x')$ 为一组基础核的凸线性组合

$$\begin{aligned} K(x, x') &= \sum_m d_m K_m(x, x') \\ d_m &\geq 0, \sum_m d_m = 1 \end{aligned} \quad (6)$$

式中 d_m 为通过样本学习得到的核权重向量 $\mathbf{d}$ 的第 m 个元素, MKL 得到如下形式的判别函数

$$f(x) = \sum_m f_m(x) + b \quad (7)$$

式中每个函数 f_m 属于不同的再生核希尔伯特空间 H_m , H_m 与核 K_m 相对应. Rakotomamonjy 等提出通过求解下面的凸优化问题来解决 MKL 问题^[7].

$$\begin{aligned} \min_{\{f_m\}, b, \xi, d} \quad & \frac{1}{2} \sum_m \frac{1}{d_m} \|f_m\|_{H_m}^2 + C \sum_i \xi_i \\ \text{s. t.} \quad & y_i \sum_m f_m(x_i) + y_i b \geq 1 - \xi_i \quad \forall i \\ & \xi_i \geq 0 \quad \forall i \\ & \sum_m d_m = 1, \quad d_m \geq 0 \quad \forall m \end{aligned} \quad (8)$$

式中 f_m 为属于再生核希尔伯特空间 H_m 的函数. 每个 d_m 调整目标函数中 f_m 的平方范数, f_m 的平滑程度通过 $\|f_m\|_{H_m}$ 来度量. d_m 越小, $\|f_m\|_{H_m}$ 将越小,函数 f_m 将越平滑. 当 $d_m = 0$ 时, $\|f_m\|_{H_m}$ 也将等于 0,从而使目标函数是一个有限值. 向量 $\mathbf{d}$ 上的 l_1 范数约束是一个稀疏约束,它将迫使一些 d_m 为 0,从而使核线性组合是稀疏的. MKL 的判别函数的具体形式为

$$f(x) = \sum_i \alpha_i^* y_i \left[\sum_m d_m K_m(x, x_i) \right] + b^* \quad (9)$$

式中 α_i^* , b^* 和 $\mathbf{d}$ 为判别函数中的未知系数,通过求解优化问题(8)得到。

2.2 MKL 学习算法

Rakotomamonjy 采用梯度法求解 MKL 问题,计算目标函数关于 d_m 的梯度,根据该梯度迭代更新 d_m ,直到满足停止条件^[7]. 将问题(8)改写为求解如下的约束优化问题

$$\begin{aligned} \min_{\mathbf{d}} \quad & J(\mathbf{d}) \\ \text{s. t.} \quad & \sum_{m=1}^M d_m = 1, \quad d_m \geq 0 \end{aligned} \quad (10)$$

式中

$$\begin{aligned} J(\mathbf{d}) = \quad & \begin{cases} \min_{\{f\}, b, \xi} \frac{1}{2} \sum_m \frac{1}{d_m} \|f_m\|_{H_m}^2 + C \sum_i \xi_i & \forall i \\ \text{s. t.} \quad y_i \sum_m f_m(x_i) + y_i b \geq 1 - \xi_i \\ \xi_i \geq 0 & \forall i \end{cases} \end{aligned} \quad (11)$$

式(11)的对偶问题为

$$\begin{aligned} \max_{\alpha} & \left[\frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \sum_m d_m K_m(x_i, x_j) + \sum_i \alpha_i \right] \\ \text{s. t.} & \quad \sum_i \alpha_i y_i = 0 \\ & \quad C \geq \alpha_i \geq 0 \quad \forall i \end{aligned} \tag{12}$$

上式为使用组合核 $K(x_i, x_j) = \sum_m d_m K_m(x_i, x_j)$ 的标准 SVM 对偶问题,采用经典的 SVM 优化算法得到 $J(\mathbf{d})$ 为

$$\begin{aligned} J(\mathbf{d}) = & \\ -\frac{1}{2} \sum_{i,j} \alpha_i^* \alpha_j^* y_i y_j \sum_m d_m K_m(x_i, x_j) + \sum_i \alpha_i^* & \end{aligned} \tag{13}$$

$J(\mathbf{d})$ 关于 d_m 的微分为

$$\frac{\partial J}{\partial d_m} = -\frac{1}{2} \sum_{i,j} \alpha_i^* \alpha_j^* y_i y_j K_m(x_i, x_j) \quad \forall m \tag{14}$$

由式(14)可知,梯度的计算复杂度为 $O(M \cdot n_{sv}^2)$, M 为核的个数, n_{sv} 为当前 $\mathbf{d}$ 对应的支持向量个数.

MKL 算法流程如图 4 所示.




图 4 MKL 算法流程图
Fig. 4 MKL algorithm flow chart

3 基于小波包与 MKL 的滚动轴承故障诊断

当滚动轴承无故障时,其振动信号中的频谱成分主要集中在低频段;而当滚动轴承出现局部损伤故障时,其振动信号中会出现由局部损伤引起的高频共振成分,从而使得振动信号在不同频带的能量分布发生改变.不同故障类型所引起的这种能量分布的改变也不相同.因此,振动信号在不同频带的能量分布能够反映滚动轴承的故障类型.小波包能量特征正是计算振动信号在不同频带的能量分布,因而是一种有效的特征.在 SVM

中,通过一个与核函数相对应的非线性映射将样本从原始的低维空间变换到高维空间,从而使得在原始低维空间中难以线性区分的样本在高维空间中能够线性区分.核函数决定样本数据在高维空间中的表示.因此,核函数的选择对 SVM 的分类性能影响较大.通常是根据使用者的经验选择某种类型的核函数,并设置核参数,然而这种方式得到的核函数并不能很好地适应样本,从而影响分类性能.MKL 算法能够从数据中学习核函数,因而得到的核函数能够更好地适应样本,获得更好的分类性能.基于小波包与 MKL 的滚动轴承故障诊断原理如图 5 所示,其具体步骤如下:

- 1) 分别对正常、外圈故障、内圈故障、滚动体故障 4 种状态的滚动轴承进行测试,在测试过程中采集振动信号,每种状态类别采集 N 个样本,总共采集 $4N$ 个样本.
- 2) 对每种状态的振动信号进行 3 层小波包分解,得到 8 个小波包节点分量.
- 3) 计算 8 个小波包节点的相对能量值,构建特征向量.
- 4) 采用“一对多”策略实现多类区分,训练 4 个二类 MKL 分类器,MKL1 区分正常与其余类别的样本,MKL2 区分外圈故障与其余类别的样本,MKL3 区分内圈故障与其余类别的样本,MKL4 区分滚动体故障与其余类别的样本,最后将训练出的 4 个二类 MKL 分类器综合成一个多类 MKL 分类器(MC-MKL).
- 5) 使用训练出的 MC-MKL 分类器对未知状态的测试样本进行分类,给出其故障类别.




图 5 基于小波包与 MKL 的滚动轴承故障诊断原理图
Fig. 5 Schematic diagram of rolling bearing fault diagnosis based on wavelet packet and MKL

4 实 验

实验数据来自轴承测试台.测试轴承为 6203 型深沟球轴承,内径为 17 mm,外径为 40 mm,宽度为 12 mm,转速为 1500 r/min.使用电火花加工制造单点故障.使用加速度传感器采集振动信号,采样频率为 8 kHz,每次采集的数据长度为 4096.

分别采集正常、外圈故障、内圈故障、滚动体

故障共 4 种类别的样本,每类采集的样本数为 160. 从每类样本中随机选取 37.5% 的样本作为训练集,剩余 62.5% 的样本为测试样本. 图 6 分别为这 4 类滚动轴承状态的振动信号. 从图 6 中难以辨别出滚动轴承状态类别.




图 6 不同滚动轴承状态检测到的振动信号
Fig. 6 Vibration signals collected in different rolling bearing states

对每个样本数据进行 3 层小波包分解,综合考虑计算量和频带混叠程度后选择 db16 类型的小波进行分解,计算小波包相对能量特征,得到 8 维的小波包特征向量. 图 7~图 10 分别为滚动轴承处于正常、外圈故障、内圈故障和滚动体故障状态下的特征向量. 从图 7~图 10 可以看出区分能力强的特征主要集中在低频段和高频段,即特征




图 7 滚动轴承正常状态下的特征向量
Fig. 7 Feature vector of rolling bearing in normal state




图 8 滚动轴承外圈故障状态下的特征向量
Fig. 8 Feature vector of rolling bearing in outer race fault




图 9 滚动轴承内圈故障状态下的特征向量
Fig. 9 Feature vector of rolling bearing in inner race fault




图 10 滚动轴承滚动体故障状态下的特征向量
Fig. 10 Feature vector of rolling bearing in rolling fault

F_0, F_1, F_2, F_6, F_7 , 而中频段的特征 F_3, F_4, F_5 几乎没有区分能力.

采用 MKL 算法同时学习核函数和分类器, 设置正则化参数 C 为 100, 候选核函数分别包含不同核参数的 Gaussian 核函数与 polynomial 核

函数, 详细如下:

- 1) 17 个不同带宽的 Gaussian 核函数, 带宽 σ 分别为 $[0.01\ 100]$ 区间上按照对数尺度均匀采样.
- 2) 3 个不同阶的 polynomial 核函数, 阶次分别为 1, 2, 3.

这些核函数分别作用于单个特征和全部特征, 因此全部的候选核的数量为 180.

利用训练集数据, 按照“一对多”策略, 训练 4 个二类 MKL 分类器, 并综合出一个多类 MKL 分类器(MC-MKL).

表 1 为 MKL 算法选择出的核的数量以及占全部候选核的比例. 从表 1 中可以看出, 权向量具有很好的稀疏性, 大部分核函数的权重为 0, 最终学习到的核函数仅为少数核函数的线性组合. 图 11~图 14 分别为 MKL1~MKL4 学习得到的核权重. 图中核编号 1~20, 21~40, $\cdots$, 141~160, 161~180 分别为作用于特征 $F_0, F_1, \cdots, F_7$ 全部特征上的核. 从图 11~图 14 可以看出作用于特征 F_3, F_4, F_5 上的核权重均为 0. 由于特征 F_3, F_4, F_5 几乎没有区分能力, 作用于这些特征上的核在 MKL 过程中被剔除, MKL 在选择核的同时也间接选择了特征, 因此 MKL 也具有特征选择能力.

表 1 MKL 后得到的核

分类器	权系数非 0 的核的数量	占全部核的 百分比/%
MKL1	7	3.89
MKL2	6	3.33
MKL3	10	5.56
MKL4	11	6.11




图 11 MKL1 得到的核权重
Fig. 11 Weights obtained by MKL1 for the kernels




图 12 MKL2 得到的核权重
Fig. 12 Weights obtained by MKL2 for the kernels




图 13 MKL3 得到的核权重
Fig. 13 Weights obtained by MKL3 for the kernels




图 14 MKL4 得到的核权重
Fig. 14 Weights obtained by MKL4 for the kernels

表 2 为 MKL 的分类精度和训练时间. 从表 2 中可以看出, MKL 具有很高的分类精度, 同时其训练时间很短, 这是由于训练样本数较少. 表 3 为部分测试样本的分类结果. 对表 3 中的测试样本均给出了准确的分类结果.

表 2 MKL 分类精度和训练时间

Table 2 Classification accuracy and training time of MKL

分类器	分类精度/%	训练时间/s
MKL1	100	10.574 2
MKL2	96.25	5.194 9
MKL3	98.75	9.626 9
MKL4	98.50	16.269 3
MC-MKL	98.25	

表 3 部分测试样本的分类结果

Table 3 Classification results of part of the test samples

测试样本	相对能量值								$f(x)$				分类结果
	F_0	F_1	F_2	F_3	F_4	F_5	F_6	F_7	MKL1	MKL2	MKL3	MKL4	
正常	0.524	0.241	0.030	0.191	0	0.001	0.002	0.009	1.003	-1.001	-1.004	-0.998	正常
正常	0.353	0.568	0.006	0.067	0	0.001	0.001	0.002	1.068	-1.008	-1.002	-1.001	正常
外圈故障	0.085	0.042	0.184	0.016	0.014	0.031	0.524	0.100	-1.095	0.798	-1.004	-1.044	外圈故障
外圈故障	0.092	0.039	0.175	0.018	0.031	0.040	0.486	0.116	-1.079	0.881	-1.045	-1.062	外圈故障
内圈故障	0.033	0.016	0.325	0.022	0.001	0.006	0.492	0.102	-1.197	-1.036	0.864	-1.069	内圈故障
内圈故障	0.041	0.119	0.279	0.075	0.001	0.003	0.411	0.069	-1.154	-1.000	0.872	-1.004	内圈故障
滚动体故障	0.115	0.037	0.285	0.021	0.001	0.014	0.492	0.031	-1.199	-1.050	-1.058	0.957	滚动体故障
滚动体故障	0.149	0.060	0.307	0.024	0.000	0.002	0.449	0.006	-1.176	-0.962	-1.143	0.866	滚动体故障

表 4 SVM 的分类结果

Table 4 Classification results of SVM

分类器	分类精度/%	
	采用 Gaussian 核函数	采用 polynomial 核函数
SVM1	100.00	100.00
SVM2	92.75	89.25
SVM3	96.75	94.25
SVM4	95.75	88.00
MC-SVM	93.75	90.50

5 结 论

本文提出了一种基于小波包分析与 MKL 的滚动轴承故障诊断方法,通过实验研究得到如下结论。

1) MKL 算法从训练样本中学习出的核函数权向量具有很好的稀疏性,最终学习到的核函数仅为少数候选核函数的凸线性组合。同时,MKL

将本文方法与基于小波包与 SVM 的滚动轴承故障诊断方法进行对比分析^[17-18]。SVM 的核函数分别使用 Gaussian 型核函数和 polynomial 型核函数,通过 5-折交叉验证设置 SVM 的最佳核参数。使用训练集样本训练出 SVM 分类器,使用测试集样本评估 SVM 的分类性能,结果如表 4 所示。对比表 2 与表 4 可以看出,本文方法的分类性能要优于传统的基于小波包与 SVM 的滚动轴承故障诊断方法。

在学习核的过程中能够间接选择特征。

2) MKL 算法具有很高的分类精度,其分类性能优于 SVM 的分类性能,并且 MKL 算法的训练效率较高,处理小规模样本时训练时间较短。

3) 结合小波包与 MKL 的滚动轴承故障诊断方法能够准确识别滚动轴承故障类型,适合应用于实际的滚动轴承故障诊断工程中。

参考文献:

[1] 何正嘉,陈进,王太勇,等.机械故障诊断理论及应用[M].北京:高等教育出版社,2010:1-9.

[2] 徐亚军,于德介,刘坚.基于线调频小波路径追踪阶比循环平稳解调的滚动轴承故障诊断[J].航空动力学报,2013,28(11):2600-2608.

XU Yajun, YU Dejie, LIU Jian. Fault diagnosis of roller bearings based on chirplet path pursuit and order cyclostationary demodulation[J]. Journal of Aerospace Power, 2013, 28(11): 2600-2608. (in Chinese)

[3] 胥永刚,孟志鹏,陆明.基于双树复小波包变换和 SVM 的滚动轴承故障诊断方法[J].航空动力学报,2014,29(1):67-73.

XU Yonggang, MENG Zhipeng, LU Ming. Fault diagnosis

- method of rolling bearing based on dual-tree complex wavelet packet transform and SVM[J]. Journal of Aerospace Power, 2014, 29(1): 67-73. (in Chinese)
- [4] Lanckriet G, Cristianini N, Bartlett P, et al. Learning the kernel matrix with semi-definite programming[J]. Journal of Machine Learning Research, 2004, 5(1): 27-72.
- [5] Bach F, Lanckriet G, Jordan M. Multiple kernel learning, conic duality, and the SMO algorithm[C]// Proceedings of the 21st International Conference on Machine Learning. Banff, Canada: ACM, 2004: 41-48.
- [6] Sonnenburg S, Ratsch G, Schafer C, et al. Large scale multiple kernel learning[J]. Journal of Machine Learning Research, 2006, 7(1): 1531-1565.
- [7] Rakotomamonjy A, Bach F R, Canu S, et al. Simple MKL[J]. Journal of Machine Learning Research, 2008, 9(1): 2491-2521.
- [8] 程东阳, 蒋兴浩, 孙钊锋. 基于稀疏编码和多核学习的图像分类算法[J]. 上海交通大学学报, 2012, 46(11): 1789-1793.
- CHENG Dongyang, JIANG Xinghao, SUN Tanfeng. Image classification using multiple kernel learning and sparse coding[J]. Journal of Shanghai Jiaotong University, 2012, 46(11): 1789-1793. (in Chinese)
- [9] 李湘眷, 孙显, 王宏琦. 基于多核学习的高分辨率遥感图像目标检测方法[J]. 测绘科学, 2013, 38(5): 84-87.
- LI Xiangjuan, SUN Xian, WANG Hongqi. Objects detection in high-resolution remote sensing images using multiple kernel learning[J]. Science of Surveying and Mapping, 2013, 38(5): 84-87. (in Chinese)
- [10] 郭创新, 朱承治, 张琳, 等. 应用多分类多核学习支持向量机的变压器故障诊断方法[J]. 中国电机工程学报, 2010, 30(13): 128-134.
- GUO Chuangxin, ZHU Chengzhi, ZHANG Lin, et al. A fault diagnosis method for power transformer based on multiclass multiple-kernel learning support vector machine[J]. Proceedings of the CSEE, 2010, 30(13): 128-134. (in Chinese)
- [11] 尹玉娟, 王媚, 张金江, 等. 一种自主核优化的二值粒子群优化-多核学习支持向量机变压器故障诊断方法[J]. 电网技术, 2012, 36(7): 249-254.
- YIN Yujuan, WANG Mei, ZHANG Jinjiang, et al. An automatic kernel optimization method to diagnose transformer faults by multi-kernel learning support vector classifier based on binary particle swarm optimization[J]. Power System Technology, 2012, 36(7): 249-254. (in Chinese)
- nese)
- [12] 郝腾飞, 陈果, 廖仲坤, 等. 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[J]. 航空动力学报, 2013, 28(12): 2759-2770.
- HAO Tengfei, CHEN Guo, LIAO Zhongkun, et al. An approach for incipient fusion fault diagnosis of rolling bearing of aero-engine based on regularized multiple kernel discriminant analysis[J]. Journal of Aerospace Power, 2013, 28(12): 2759-2770. (in Chinese)
- [13] 刘明才. 小波分析及其应用[M]. 2版. 北京: 清华大学出版社, 2013: 105-114.
- [14] 孙健, 王成华, 杜庆波. 基于小波包能量谱和 NPE 的模拟电路故障诊断[J]. 仪器仪表学报, 2013, 34(9): 2021-2027.
- SUN Jian, WANG Chenghua, DU Qingbo. Analog circuit fault diagnosis based on wavelet packet energy spectrum and NPE[J]. Chinese Journal of Scientific Instrument, 2013, 34(9): 2021-2027. (in Chinese)
- [15] 蒋永华, 程光明, 阚君武, 等. 基于 NGA 优化 SVM 的滚动轴承故障诊断[J]. 仪器仪表学报, 2013, 34(12): 2684-2689.
- JIANG Yonghua, CHENG Guangming, KAN Junwu, et al. Rolling bearing fault diagnosis based on NGA optimized SVM[J]. Chinese Journal of Scientific Instrument, 2013, 34(12): 2684-2689. (in Chinese)
- [16] 史丽萍, 王攀攀, 胡泳军, 等. 基于骨干微粒群算法和支持向量机的电机转子断条故障诊断[J]. 电工技术学报, 2014, 29(1): 147-155.
- SHI Liping, WANG Panpan, HU Yongjun, et al. Broken rotor bar fault diagnosis of induction motors based on bare-bone particle swarm optimization and support vector machine[J]. Transactions of China Electrotechnical Society, 2014, 29(1): 147-155. (in Chinese)
- [17] 田野, 陆爽. 基于小波包和支持向量机的滚动轴承故障模式识别[J]. 机床与液压, 2006, 34(6): 236-240.
- TIAN Ye, LU Shuang. Fault pattern recognition of rolling bearing based on wavelet packet and support vector machine[J]. Machine Tool and Hydraulics, 2006, 34(6): 236-240. (in Chinese)
- [18] 陈季云, 李娟. 基于小波包-支持向量机的滚动轴承故障诊断[J]. 化工自动化及仪表, 2010, 37(9): 50-52.
- CHEN Jiyun, LI Juan. Fault diagnosis of rolling bearings based on wavelet packet and support vector machine[J]. Control and Instruments in Chemical Industry, 2010, 37(9): 50-52. (in Chinese)

(编辑: 陈 越)