

优化支持向量机及其在智能故障诊断中的应用*

王保健¹, 张小丽², 傅杨奥骁¹, 陈雪峰¹

(1. 西安交通大学机械基础国家级实验教学示范中心 西安, 710049)

(2. 长安大学道路施工技术装备教育部重点实验室 西安, 710064)

摘要 单一支持向量机在轴承齿轮故障诊断中精度较低, 为了提高支持向量机在轴承齿轮故障诊断中的精度, 对支持向量机的样本特征提取方法以及支持向量机参数优化的方法进行了研究。首先, 通过核主成分分析方法构造支持向量机的输入样本, 可以减少数据间的冗余, 提取数据的高维信息; 其次, 通过粒子群优化算法优化支持向量机核函数参数和惩罚因子; 最后, 使用优化后的支持向量机模型进行故障诊断。通过实际轴承齿轮故障诊断对比实验, 结果表明, 所提方法相比一般的支持向量机诊断方法诊断精度大幅提高, 验证了该混合智能诊断方法的有效性和优势。

关键词 支持向量机; 核主成分; 粒子群优化算法; 故障诊断

中图分类号 TH17; TP18

引言

随着中国制造 2025 的提出, 自动化、智能化成为我国制造业的发展方向。故障诊断技术已经发展到了智能故障诊断阶段, 其中支持向量机 (support vector machine, 简称 SVM) 作为智能故障诊断技术领域的热点之一, 以其基于统计学习理论的特点, 非常适合故障诊断这种典型的小样本问题。目前, 支持向量机在轴承、齿轮、电机等机械状态监测与故障诊断中得到了广泛应用, 取得了良好的效果。根据文献[1-2], 将改进核函数的支持向量机智能诊断方案用于轴承的故障诊断, 将局部均值分解与支持向量机相结合用于电机的故障诊断, 以及将主成分分析和 SVM 结合的方法用于内燃机的故障诊断等都取得较好结果。文献[3-6]将神经网络和 SVM 的超参数优化用于离心泵的故障诊断, 将基于物理模型的 SVM 用于滚动轴承的故障诊断, 也取得了较好的效果。但是, 目前标准的支持向量机算法通常对样本的分布假设过于理想, 样本构造复杂, 样本间数据存在冗余、无法提取数据间高维信息及预测速度慢、预测精度低的问题, 在处理工程实际问题时容易出现问題。SVM 的性能取决于训练样本数据的质量和 SVM 核函数参数 g 和惩罚因子 C 的选择,

因此, 笔者对支持向量机的样本特征提取方法以及支持向量机参数优化的方法进行了研究。

1 SVM 基本理论介绍

SVM 是一种针对小样本和少样本情况下的机器学习的新方法。支持向量机不同于传统的基于经验风险最小化原则的学习方法, 它是基于结构风险最小化的原则, 在解决小样本、非线性及高维问题时表现出很多独特的优势^[7-8]。

支持向量机的基础是寻找在线性可分条件下的最优分类超平面。首先给定一个样本集 $S = \{(x_i, y_i)\}_{i=1}^n \mid x_i \in R^d, y_i \in \{+1, -1\}, i = 1, 2, \dots, n\}$ 其中: x_i 为数据; y_i 为数据所属的类别。

若超平面方程 $wx + b = 0$ 达到了最优分类平面的标准 (即在分类间隔最大的情况下将样本正确地分开), 则求解最优分类平面的问题可以转换为下述目标函数和约束条件

$$\begin{cases} \min \frac{1}{2} \|w\|^2 \\ \text{s. t. } y_i (wx_i + b) \geq 1 \quad (i = 1, 2, \dots, n) \end{cases} \quad (1)$$

其中: w 为权重向量; b 为偏置向量。

在许多情况下, 一些样本往往不能被正确地分类, 为了确保分类的准确性, 这里引入了松弛因子

* 航空科学基金资助项目 (20151070005); 国家自然科学基金资助项目 (51405028); 中国博士后科学基金资助项目 (2015M572552)

收稿日期: 2016-09-06; 修回日期: 2016-11-07

$\xi_i \geq 0, i = 1, 2, \dots, n$, 则优化问题可以表示为

$$\begin{cases} \min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i & (\xi_i \geq 0) \\ \text{s. t. } \begin{cases} \mathbf{y}_i(\mathbf{w}\mathbf{x}_i + \mathbf{b}) \geq 1 - \xi_i & (i = 1, 2, \dots, n) \\ C \geq 0 \end{cases} \end{cases} \quad (2)$$

其中: C 为惩罚因子。

由于算法复杂程度与分类精度之间的矛盾, 通过调节惩罚因子的大小来实现折中。式(2)则变成了一个二次规划问题, 通过求拉格朗日函数的鞍点得到问题的最优解。

由最优化条件(karush-kuhn-tucker, 简称 KKT)定理得知最初的求解最优超平面的问题被转换为求解二次优化问题

$$\begin{cases} \max Q(\alpha) = -\frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j \mathbf{y}_i \mathbf{y}_j (\mathbf{x}_i \mathbf{x}_j) + \sum_{i=1}^n \alpha_i \\ \text{s. t. } \sum_{i=1}^n \alpha_i \mathbf{y}_i = 0 \quad (0 \leq \alpha_i \leq C; i = 1, 2, \dots, n) \end{cases} \quad (3)$$

通过求解式(3)中的函数就可以得到前述的拉格朗日算子 α_i , 然后通过任意一个已知支持向量 \mathbf{x}_k 以及其所对应的 α_k 便可以计算得到偏置 \mathbf{b} 。对所给的未知类型的样本 \mathbf{x} , 只需计算 $f(\mathbf{x}) = \text{sign}[(\mathbf{w}\mathbf{x}) + \mathbf{b}]$ 即可判断该样本所属的类别。

至于非线性条件下的分类问题, 支持向量机的基本思想是通过核函数实现从低维向高维的映射, 然后在高维特征空间中使用支持向量机进行线性分类, 其具体是通过核函数来实现。现在常用的核函数包括线性核函数、高斯径向基核函数、多项式核函数及指数径向核函数等, 使用不同的核函数所产生的支持向量机会得到不同的分类和预测结果。

2 智能故障诊断方法

在轴承与齿轮的故障诊断中, 最常用的方法是使用各种现代信号处理方法去提取被检测信号中的故障特征频率部分。通常情况下, 轴承、齿轮的故障特征频率可以通过各种一般公式直接求得; 但是也

有一些情况下, 其故障特征频率不容易求得, 或者即使求得了故障特征频率, 在故障早期及噪声大的情况下也很难准确分析出特征频率。智能诊断方法不求特征频率, 而是从信号的指标上进行自学习及分类。笔者采用的基于核主成分及粒子群参数优化的支持向量机智能故障诊断方法是针对设备振动信号的诊断方法, 首先, 采集设备振动信号; 然后, 采用信号的时域指标直接构造故障样本, 故障样本采用核主成分进行降维及减少冗余处理, 处理后的样本用于 SVM 训练样本, 支持向量机的惩罚因子 C 和核函数参数 g 采用粒子群算法进行优化; 最后, 使用优化 SVM 对测试样本进行分类诊断。具体的方法流程图见图 1。

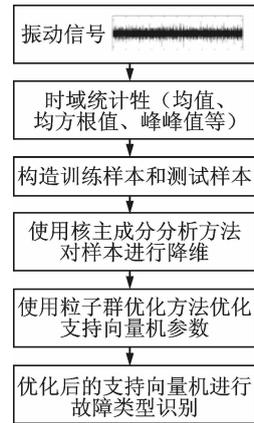


图 1 方法流程图

Fig. 1 Method flow chart

2.1 样本构造

在众多的基于支持向量机的智能故障诊断方法中, 时域指标由于其简单、可靠、直接, 因此被广泛的使用, 其振动信号的几种简单的时域统计特征见表 1。其中: $x(i)$ 为信号序列; $i = 1, 2, \dots, N$ 为序列点数; $tp_1 \sim tp_{16}$ 分别为均值、均方根值、方根幅值、绝对平均值、偏斜度、峭度、方差、最大和最小值、峰峰值、波形指标、峰值指标、脉冲指标、裕度指标、偏斜度指标及峭度指标。前 10 项为有量纲指标, 后 6 项为无量纲指标。

表 1 几种时域统计特征

Tab. 1 Several time domain statistical features

时域统计特征	时域统计特征	时域统计特征	时域统计特征
$tp_1 = \frac{1}{N} \sum_{i=1}^N x(i)$	$tp_5 = \frac{1}{N} \sum_{i=1}^N (x(i) - tp_1)$	$tp_9 = \min(x(i))$	$tp_{13} = tp_8 / tp_4$
$tp_2 = \sqrt{\frac{1}{N} \sum_{i=1}^N (x(i))^2}$	$tp_6 = \frac{1}{N} \sum_{i=1}^N (x(i) - tp_1)$	$tp_{10} = tp_7 - tp_8$	$tp_{14} = tp_8 / tp_3$
$tp_3 = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{ x(i) } \right)^2$	$tp_7 = \frac{1}{N-1} \sum_{i=1}^N (x(i) - l)$	$tp_{11} = tp_2 / tp_4$	$tp_{15} = tp_5 / (tp_7)^{3/2}$
$tp_4 = \frac{1}{N} \sum_{i=1}^N x(i) $	$tp_8 = \max(x(i))$	$tp_{12} = tp_8 / tp_2$	$tp_{16} = tp_6 / (tp_7)^2$

2.2 基于核主成分分析的样本处理方法

在构造时域统计特征训练样本时,时域变量(如均方根、峭度等)之间存在相关的关系,信息之间存在冗余,直接构造难免使得训练样本复杂化,进而影响分类精度。运用核主成分分析(kernel principal component analysis,简称 KPCA)方法提取这些统计特征样本的有效信息,去除冗余信息,同时减小数据的维数,可以减小计算量,加快分类速度^[9-10]。

核主成分基本理论如下:将输入空间通过一种非线性的映射方法映射到某个高维空间(通常称为特征空间),然后在此特征空间中使用主成分分析。假设映射为 Φ ,通过映射 Φ 实现点 x 到特征空间 F 的映射,并且假设映射而得的特征空间中数据满足中心化的条件,即 $\sum_{\mu=1}^M \Phi(x_{\mu})=0$,则特征空间中的协方差矩阵为

$$C = \frac{1}{M} \sum_{\mu=1}^M \Phi(x_{\mu}) \Phi^T(x_{\mu}) \quad (4)$$

在特征空间中使用主成分分析方法,即求解方程 $Cv = \lambda v$ 中的特征值 λ 和特征向量 v ,即有

$$[\Phi(x_v)Cv] = \lambda [\Phi(x_v)v] \quad (5)$$

其中所有的特征向量可表示为 $\Phi(x_1), \Phi(x_2), \dots, \Phi(x_M)$ 的线性表达,即 $v = \sum_{i=1}^M \alpha_i \Phi(x_i)$,则可得

$$\frac{1}{M} \sum_{\mu=1}^M \alpha_{\mu} \left[\sum_{w=1}^M \Phi(x_w) \Phi(x_v) \right] [\Phi(x_w) \Phi(x_{\mu})] = \lambda \sum_{\mu=1}^M \alpha_{\mu} [\Phi(x_v) \Phi(x_{\mu})] \quad (6)$$

其中: $v=1,2,\dots,M$ 。

定义 $M \times M$ 的矩阵 K

$$K_{\mu\nu} = [\Phi(x_{\mu}) \Phi(x_{\nu})]$$

则式(6)可以简化为 $M\lambda K\alpha = K^2\alpha$,通过对上式的求解,即可以得到所要求的特征值 λ 和特征向量 v 。

2.3 粒子群优化算法优化 SVM 参数

支持向量机的惩罚因子 C 和核函数 g 的选择对预测分类精度影响很大,采用粒子群优化方法优化支持向量机参数 C 和 g ^[11-13]。粒子群优化算法(particle swarm optimization algorithm,简称 PSO)基本理论如下。

假设种群中一共有 n 个维度为 q 的粒子,则优化问题就可以表示为一个包含了 n 个粒子的种群在 q 维的空间中寻优。其中,这个种群中的每个粒子可以表示为 $x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,q})$,与之对应的每

个粒子的速度表示为 $v_i = (v_{i,1}, v_{i,2}, \dots, v_{i,q})$,在每个粒子寻优的过程中,它们都需要借鉴和考虑两个重要的因素。

1) 自身搜索到的历史最优值

$$p_i = (p_{i,1}, p_{i,2}, \dots, p_{i,q}) \quad (i=1,2,\dots,n)$$

2) 全部粒子搜索到的最优值

$$p_g = (p_{g,1}, p_{g,2}, \dots, p_{g,q})$$

之后每个粒子则会按照式(7)来更新自己所处的位置和此时的速度

$$\begin{cases} v_{id}(t) = \omega v_{id}(t-1) + c_1 \xi(p_{id}(t-1) - x_{id}(t-1)) + c_2 \eta(p_{gd} - x_{id}(t-1)) \\ x_{id}(t) = x_{id}(t-1) + r v_{id}(t) \end{cases} \quad (7)$$

其中: ω 为惯性权重,是粒子保持自己之前的速度的权重系数; c_1 为粒子根据自身经验寻找最优值的权重系数,一般取 2; c_2 为粒子根据群体经验寻找最优值的权重系数,一般也取为 2; ξ, η 为区间 $[0,1]$ 之间均匀分布的随机数; r 为约束因子,通常取 1。

粒子群优化算法流程见图 2。

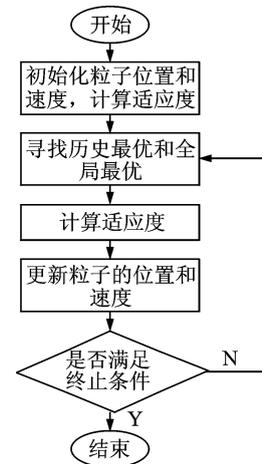


图 2 粒子群优化算法流程图

Fig. 2 Flow chart of particle swarm optimization algorithm

3 轴承齿轮系统故障诊断实验

笔者所提方法经过仿真数据实验,结果表明本方法比直接用 SVM 诊断精度大为提高。为了进一步验证所提方法有效性,在故障模拟实验台上进行了轴承和齿轮的故障模拟实验。实验系统结构如图 3 所示,实物如图 4 所示。该系统主要包括 SQI (MFS-PK4)故障模拟实验台(转子由 2 个轴承支撑,电机用过联轴器带动转子旋转,转子通过皮带轮带动齿轮箱运动)、PCB 加速度传感器及东华数据

采集系统。通过更换转子系统的支撑轴承来模拟不同故障的轴承,包括正常轴承、内圈故障、外圈故障、滚动体故障及混合故障 5 种情况;通过更换齿轮箱的齿轮来模拟不同齿轮故障,包括正常齿轮、齿轮缺齿、齿轮断齿及齿轮均匀磨损 4 种情况,其中齿轮均匀磨损有一个专用的齿轮箱来模拟。一个加速度传感器置于右端轴承座上方(按照径向方向)采集轴承振动信号,另一个置于齿轮箱上方采集齿轮振动信号,采样频率为 12.8kHz。实验用故障轴承及故障齿轮如图 5 所示。

使用所采集振动信号的前一半样本作为训练样本集,后一半样本作为测试样本集,得到了 70 个训练集样本和 70 个测试集样本。由于径向基核函数(rbf)具有很好的学习能力,所以本研究中 SVM 的核函数均采用径向基核函数。

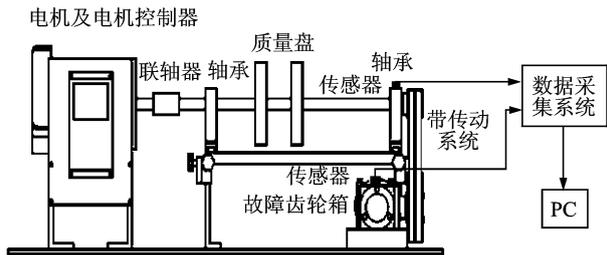


图 3 实验系统结构示意图

Fig. 3 Schematic diagram of experimental system structure



图 4 实验系统实物图

Fig. 4 Physical picture of experimental system



图 5 故障轴承及故障齿轮

Fig. 5 Fault bearing and fault gear

为了验证所提方法的有效性,笔者采用了不同方法对比的研究思路,具体如下。

对比测试 1:使用 16 个时域指标构造样本,直

接使用不经过优化的支持向量机进行分类,参数为 $C = 3, \text{ker} = \text{rbf}, g = 2$, 实验分类精度 $\text{Acc} = 87.14\% (61/70)$, 如图 6 所示。其中:圈表示测试样本的标签;星号表示支持向量机判别的对应样本的标签。如果星号与圈重合,则判别正确;否则判别错误。

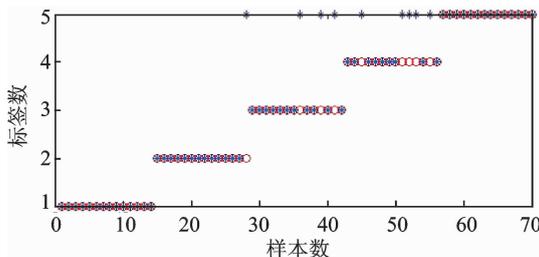


图 6 轴承对比测试 1 的实验结果

Fig. 6 Experimental results of bearing contrast test 1

对比测试 2:使用 16 个时域指标构造样本,使用经过粒子群优化的支持向量机进行分类,优化结果为 $C = 4.487, \text{ker} = \text{rbf}, g = 0.514$, 实验结果为 $\text{Acc} = 92.86\% (65/70)$ 。

对比测试 3:使用主成分分析方法重构样本,再使用粒子群优化参数后的支持向量机进行分类,参数优化后为 $C = 56.45, \text{ker} = \text{rbf}, g = 5.13$, 实验结果为 $\text{Acc} = 97.14\% (68/70)$, 如图 7 所示。

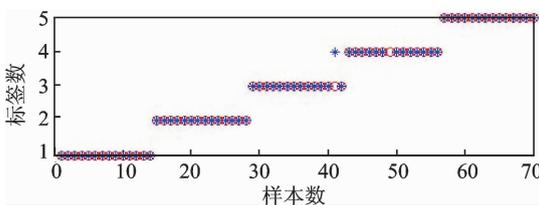


图 7 轴承对比测试 3 的实验结果

Fig. 7 Experimental results of bearing contrast test 3

对比测试 4:使用 16 个时域统计特征作为核主成分分析的输入矩阵,通过核主成分分析方法,选取主成分矩阵前 l 列累计贡献率达到 95% 的主成分作为支持向量机的输入样本,在轴承实验中前 2 列的累计贡献率达到 99%,在齿轮试验中前 4 列的累计贡献率达到 99%。轴承和齿轮的主成分累计贡献率如图 8 所示。

使用粒子群优化参数后的支持向量机进行分类,参数优化后为: $C = 33.2, \text{ker} = \text{rbf}, g = 61.4$, 实验结果为 $\text{Acc} = 100\% (70/70)$, 如图 9 所示。从图中可以看出,所有的样本均被正确分类。

轴承故障诊断的 4 次对比测试结果汇总于表 2, 齿轮故障诊断的 4 次对比测试结果见表 3。

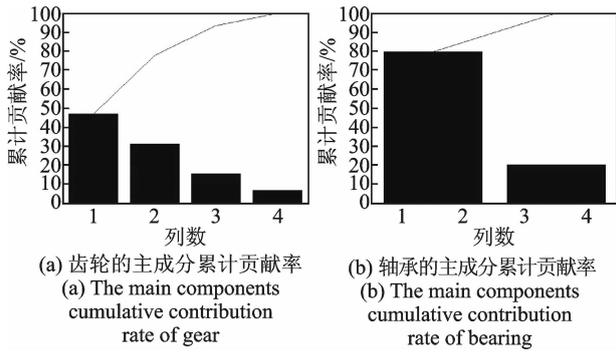


图 8 轴承和齿数的主成分累计贡献率

Fig. 8 The main components cumulative contribution rate of bearing and gear

间高维的信息,进一步提高了精度。

4 结束语

采用核主成分加粒子群算法优化支持向量机参数的方法,构造了一套混合智能故障诊断系统。核主成分分析方法方便了样本矩阵的构造,减小了数据的冗余,提取了样本数据之间的高维信息,采用粒子群优化算法对支持向量机核函数参数 g 及惩罚因子 C 进行了优化,完成了机械故障模拟实验台上轴承和齿轮的故障诊断实验。通过与使用一般时域指标方法、使用主成分分析方法两种构造样本方法及 SVM 参数不优化和优化进行实验对比,结果表明,所提方法在轴承和齿轮两种数据样本上的诊断上精度非常高,证明了所提方法的科学性和有效性。

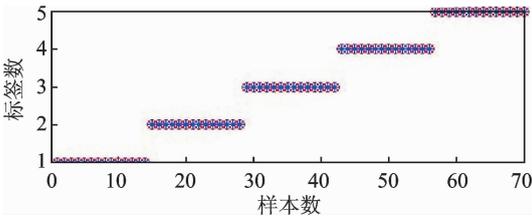


图 9 轴承对比测试 4 的实验结果

Fig. 9 Experimental results of bearing contrast test 4

参 考 文 献

表 2 轴承对比实验结果

Tab. 2 Bearing contrast test results

编号	方法	实验结果/%
1	SVM	87.14
2	PSO-SVM	92.86
3	PCA-PSO-SVM	97.14
4	KPCA-PSO-SVM	100.00

SVM 为支持向量机; PSO 为粒子群优化算法; PCA 为主成分分析; KPCA 为核主成分分析

表 3 齿轮对比实验结果

Tab. 3 Gear contrast test results

编号	方法	实验结果/%
1	SVM	88.75
2	PSO-SVM	90.00
3	PCA-PSO-SVM	95.00
4	KPCA-PSO-SVM	100.00

从轴承和齿轮单独样本的故障诊断结果来看,粒子群算法优化支持向量机 (PSO-SVM) 的参数后,分类精度提高了。在此基础之上使用主成分分析方法构造样本 (PCA-PSO-SVM), 去除了原有样本中的冗余信息, 简化了样本的构造, 精度进一步提高。使用核主成分分析构造样本时 (KPCA-PSO-SVM), 较主成分分析而言, 其能够提取样本数据之

[1] 刘永斌,何清波,孔凡让. 基于 PCA 和 SVM 的内燃机故障诊断[J]. 振动、测试与诊断, 2012, 32(2): 250-255.
Liu Yongbin, He Qingbo, Kong Fanrang. Fault diagnosis of internal combustion engine based on PCA and SVM[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 250-255. (in Chinese)

[2] 鞠华,沈长青,黄伟国. 基于支持向量回归的轴承故障定量诊断应用[J]. 振动、测试与诊断, 2014, 34(4): 767-771.
Ju Hua, Shen Changqing, Huang Weiguo. Application of bearing fault quantify diagnosis based on support vector regression[J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(4): 767-771. (in Chinese)

[3] Azadeh A, Saberi M, Kazem A, et al. A flexible algorithm for fault diagnosis in a centrifugal pump with corrupted data and noise based on ANN and support vector machine with hyper-parameters optimization [J]. Applied Soft Computing, 2013, 13(3): 1478-1485.

[4] Gryllias K C, Antoniadis I A. A support vector machine approach based on physical model training for rolling element bearing fault detection in industrial environments[J]. Engineering Applications of Artificial Intelligence, 2012, 25(2): 326-344.

[5] Chen Fafa, Tang Baoping, Song Tao, et al. Multi-fault diagnosis study on roller bearing based on multi-

- kernel support vector machine with chaotic particle swarm optimization [J]. *Measurement*, 2014, 47: 576-590.
- [6] Kuang Fangjun, Zhang Siyong, Jin Zhong, et al. A novel SVM by combining kernel principal component analysis and improved chaotic particle swarm optimization for intrusion detection [J]. *Soft Computing*, 2015, 19(5): 1187-1199.
- [7] Shen Zhongjie. Remaining life predictions of rolling bearing based on relative features and multivariable support vector machine[J]. *Journal of Mechanical Engineering*, 2013, 49 (2): 183-189.
- [8] 郭明玮,赵宇宙,项俊平. 基于支持向量机的目标检测算法综述[J]. *控制与决策*, 2014(2):193-200.
Guo Mingwei, Zhao Yuzhou, Xiang Junping. A review of the target detection algorithm based on support vector machine [J]. *Control and Decision*, 2014 (2): 193-200. (in Chinese)
- [9] 彭令,牛瑞卿,赵艳南. 基于核主成分分析和粒子群优化支持向量机的滑坡位移预测[J]. *武汉大学学报*, 2013,38(2):148-452.
Peng Ling, Niu Ruiqing, Zhao Yannan. Landslide displacement prediction based on kernel principal component analysis and particle swarm optimization support vector machine [J]. *Journal of Wuhan University*, 2013,38(2):148-452. (in Chinese)
- [10] 李平,李学军,蒋玲莉. 基于 KPCA 和 PSOSVM 的异步电机故障诊断[J]. *振动、测试与诊断*, 2014, 34(4): 616-620.
Li Ping, Li Xuejun, Jiang Lingli. Fault diagnosis of induction motor based on KPCA and PSOSVM [J]. *Journal of Vibration, Measurement & Diagnosis*, 2014, 34(4):616-620. (in Chinese)
- [11] 聂立新,张天侠,赵波. 粒子群算法优化双核支持向量机及应用[J]. *振动、测试与诊断*, 2014, 34(4):565-569.
Nie Lixin, Zhang Tianxia, Zhao Bo. Particle swarm optimization algorithm for dual core support vector machine and its application[J]. *Journal of Vibration, Measurement & Diagnosis*, 2014, 34(4):565-569. (in Chinese)
- [12] 谷文成,柴宝仁,滕艳平. 基于粒子群优化算法的支持向量机研究[J]. *北京理工大学学报*, 2014(7):705-709.
Gu Wencheng, Chai Baoren, Teng Yanping. Research on support vector machine based on particle swarm optimization algorithm[J]. *Journal of Beijing Institute of Technology*, 2014(7):705-709. (in Chinese)
- [13] 张周锁,侯照文,孙闯. 应用粒计算的混合智能故障诊断技术研究[J]. *西安交通大学学报*, 2011,45(1):48-53.
Zhang Zhousuo, Hou Zhaowen, Sun Chuang. Research on the technology of hybrid intelligent fault diagnosis based on granular computing [J]. *Journal of Xi'an Jiaotong University*, 2011,45(1):48-53. (in Chinese)



第一作者简介: 王保建,男,1983年5月生,博士生、工程师。主要研究方向为机械系统故障诊断。曾发表《基于“双导师制 CDIO”本科生课程教学改革与实践》(《实验室研究与探索》2016年第35卷第3期)等论文。
E-mail:wangbaojian@mail.xjtu.edu.cn