

单类学习下基于 VSAPSO-BP 的掘进机异常检测方法^{*}

杨健健， 唐至威， 王晓林， 王子瑞， 吴 森

(中国矿业大学(北京)机电与信息工程学院 北京,100083)

摘要 针对掘进机回转台异常检测中故障数据缺失以及故障程度划分的问题,提出一种单类学习下基于 VSAPSO-BP 的掘进机异常检测方法。使用支持向量数据描述(support vector data description,简称 SVDD)方法对回转台健康数据进行单类学习,根据现场经验构造非健康样本数据集,以 SVDD 对非健康样本数据集的识别率为依据,把非健康样本数据分为故障临界数据与故障数据,提出变异自适应粒子群优化(variation self-adapting particle swarm optimization,简称 VSAPSO)算法,构建 VSAPSO-BP 神经网络对健康、故障临界与故障 3 类数据进行检测,检测准确率为 91.7%,与传统 PSO-BP 方法相比具有更高的准确性与稳定性。实验结果表明,采用单类学习下基于 VSAPSO-BP 的掘进机异常检测方法可以准确有效地检测掘进机回转台异常,具有较高的应用价值。

关键词 掘进机回转台;异常检测;支持向量数据描述;粒子群优化算法;BP 神经网络

中图分类号 TD421.5;TD63;TH165.3

引 言

在实际的工业生产过程中,针对昂贵、关键的重型装备开展故障诊断异常检测研究具有重要的经济和社会效益。其中,掘进机是煤矿井下巷道掘进的关键装备,在煤矿安全高效生产中发挥着关键作用。由于煤矿井下作业空间狭窄、空气潮湿、煤岩性质复杂,恶劣的工作环境使得无人化掘进对掘进机的智能控制要求越来越要,因此对掘进机故障诊断异常检测技术的研究具有实际的工程应用价值。针对上述现状,当前关键问题主要体现在故障数据的缺失和整体系统状态数据的异常识别两个方面^[1-2]。生产实践经验表明,机械设备的振动与其运行状态之间有密切关系,相关部件运行过程突发故障或衍生故障等都会通过振动信号体现出来^[3]。

缺少故障振动数据是目前大型机械整体部件故障诊断研究中的一大难点。支持向量数据描述算法是一种典型的单分类方法,只需对健康数据进行训练,便可对部件的健康状态与非健康状态进行分类。目前,SVDD 已在电力系统^[4-5]、发动机^[6]及压缩机^[7]等故障诊断中应用。仅对设备的健康与非健康状态进行分类无法得知部件的故障程度,具有模糊性,对设备使用与维修的指导意义不大,因此需要对设备的故障程度进行划分。BP 神经网络是一种有

效解决数据分类问题的工具,其算法存在收敛速度慢以及容易陷入局部极小值的问题。国内外研究人员尝试使用不同算法优化 BP 神经网络,其中粒子群优化算法(particle swarm optimization,简称 PSO)的应用较为广泛且效果较好^[8]。为了进一步提升 PSO 算法的全局搜索能力与局部搜索能力,研究人员提出了多种 PSO 优化方法^[9-11]。改进型 PSO 算法性能各异,适用于不同工程研究领域,为使 PSO 算法能够更加适合掘进机故障诊断,需对 PSO 算法进行改进。

为解决掘进机回转台故障诊断研究中缺少故障数据以及需要对故障程度进行划分的问题,笔者提出了一种基于单分类健康数据的 VSAPSO-BP 网络掘进机回转台故障诊断方法。以 EBZ160 型掘进机的回转台(整体部件)为例,使用 SVDD 对健康样本集进行训练,根据现场经验构造非健康数据集,利用 SVDD 对非健康数据集的识别率,把非健康数据分为故障临界数据与故障数据两类。综合建立健康、故障临界及故障 3 类数据样本集,使用新型改进 PSO 对 BP 神经网络的权值参数进行优化,提出了一种变异自适应粒子群优化算法替代了 BP 神经网络原有的梯度下降算法,使 VSAPSO-BP 神经网络应用于掘进机回转台故障诊断异常检测具有更快的收敛速度和更高的识别精度。

^{*} 国家重点基础研究发展计划(“九七三”计划)资助项目(2014CB046306);国家自然科学基金资助项目(51874308)
收稿日期:2017-04-26;修回日期:2017-06-22

1 基于 SVDD 的数据描述

通过对 EBZ160 型掘进机回转台振动特征的分析,选择回转台水平测点振动加速度的有效值、方差和峭度作为特征向量。如何针对现实状况中只有健康稳定状态的单类数据特征进行有效的异常检测是解决掘进机故障诊断方法的关键问题。

令掘进机回转台振动加速度信号特征向量为 $\mathbf{X}=[x_1, x_2, \dots, x_n]$, 振动加速度信号特征向量的故障阈值为 $\mathbf{Y}=[y_1, y_2, \dots, y_n]$, 笔者将掘进机回转台的运行状态分为 3 类数据集合, 其定义如下。

定义 1 表征设备的健康状态数据集合 $H = \{x \in X | x_i < y_i, i=1, 2, \dots, N\}$ 。

定义 2 机器出现的故障短时间内不影响机器运行, 为了不影响生产效率, 仍可继续运行等待检修, 表征设备处于故障临界状态数据集合 $C = \{x \in X | y_i - x_i / y_i \leq \sigma; i=1, 2, \dots, N\}$, 其中: σ 为常数, 通常取 0.3。

定义 3 表征机器出现故障影响正常运行并危及人员的安全, 需立刻停止运行并检修严重故障状态数据集合 $C = \{x \in X | y_i - x_i / y_i > \sigma; i=1, 2, \dots, N\}$, 其中: σ 为常数, 通常取 0.3。

SVDD 算法^[10]可将已知的单一健康状态运行样本数据压缩在一个高维特征空间, 构造一个能够描述健康数据范围的封闭紧凑的最小超球体, 如图 1 所示。该方法能够对健康状态与非健康状态进行区分。




图 1 SVDD 单分类示意图

Fig. 1 SVDD single classification diagram

令测试样本集 $\mathbf{Z}=[z_1, z_2, \dots, z_i, \dots]$, 其中 $i=1, 2, \dots, N$, \mathbf{Z} 中样本 z_i 到球心 a 的平均距离 $\bar{D} = \frac{1}{N} \sum_{i=1}^N D(z_i)$, $\delta = |R - \bar{D}|$ 。对数据幅值的放大过程即为 \bar{D} 的放大过程。

当 $\bar{D} < R$ 且 δ 较大时, 大部分样本被超球面包络, 此时 SVDD 识别率较高, 数据为健康数据。当 $\bar{D} \approx R$ 且 δ 较小时, 被超球面包络的样本与散落在超球面外的样本数量相对均衡, 此时 SVDD 的识别率降

低, 但仍有 30%~70% 的数据可以被识别, 数据为轻微故障数据。当 $\bar{D} > R$ 且 δ 较大时, 大部分样本散落在超球面外, 此时 SVDD 识别率较低甚至完全不识别, 数据为严重故障数据。其数据分类如图 2 所示。




图 2 数据分类示意图

Fig. 2 Data classification diagram

根据经验, 数据的准确率与数据类型的关系为

$$Z(A) = \begin{cases} 1 & (A > 70\%) \\ 0 & (30\% < A < 70\%) \\ -1 & (A < 30\%) \end{cases} \quad (1)$$

其中: $Z(A)$ 为指示函数; A 为识别准确率; 1 代表该数据为健康数据; 0 代表该数据为故障临界数据; -1 代表该数据为严重故障数据。

根据上述原则, 笔者选取一组在非训练样本数据集中可被 SVDD 完全识别的健康数据作为测试样本, 根据 SVDD 分类算法识别率分别确定健康状态、故障临界状态与严重故障状态的取值范围, 将该线性权值作为故障样本的取值依据, 建立健康状态、轻微故障状态与严重故障状态的样本数据集。

2 VSAPSO-BP 神经网络

为克服传统 BP 网络算法收敛速度慢且容易陷入局部极小值的缺陷, 本研究提出 VSAPSO 算法代替优化 BP 网络原有的梯度下降算法来调整 BP 网络参数中的权值和阈值。

2.1 VSAPSO 算法

标准粒子群优化算法公式如式(2)~(5)所示。

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)) \quad (2)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (3)$$

$$v_{id} = \begin{cases} v_{\max} & (v_{id} > v_{\max}) \\ -v_{\max} & (v_{id} < -v_{\max}) \\ v_{id} & (|v_{id}| < v_{\max}) \end{cases} \quad (4)$$

$$\omega(t) = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{T_{\max}} t \quad (5)$$

其中: v_{id} 为当前粒子 i 的速度; x_{id} 为当前粒子 i 的位置; c_1, c_2 为学习因子; r_1, r_2 为 $[0, 1]$ 之间的随机数; p_{id} 为粒子 i 发现的个体最优位置; p_{gd} 为粒子 i 发现的全局最优位置; v_{\max} 为最大速度; ω_{\max} 为最大惯性

权重, w_{\min} 为最小惯性权重, t 为迭代次数, T_{\max} 为最大迭代次数。

该方法虽然原理简单、受控参数少和收敛速度快,但也有易于收敛到局部最优和搜索精度不高的缺点^[8]。

APSO 算法^[13]采用自适应调整惯性权重的方式提高了标准 PSO 算法的全局和局部搜索能力,但是该方法 w 调整范围较小,导致算法的搜索能力稍显不足,且容易使搜索陷入局部极小值。因此,笔者提出了一种 VSAPSO 算法。

首先,VSAPSO 算法修改了 APSO 算法的惯性权重公式,即

$$w = w_{\max} - \frac{(w_{\max} - w_{\min})(f_{\max} - F(i))}{f_{\max} - f_{\min}} \quad (6)$$

其中: w_{\max} , w_{\min} 分别为惯性权重的最大值和最小值; $F(i)$ 为每代第 i 个粒子的适应值; f_{\max} 为每代粒子的最大适应值; f_{\min} 为每代粒子的最小适应值。

该方法可以根据当前粒子适应值的好坏自动调整惯性权重 w 的参数。当适应度值较大时, w 值变大,可以提高粒子的搜索速度及全局搜索能力。当适应度值较小时, w 值变小,可以降低粒子的搜索速度,提高粒子的局部搜索能力。修改后的惯性权重 w 具有更大的调整范围,提高了算法的搜索能力。

其次,笔者使用遗传算法中变异方式让粒子按一定几率将位置随机重置,使其跳出原位置重新搜索,降低了粒子群陷入局部极小值的几率,变异方式为

$$x_{id} = \begin{cases} x_{\max}R(1,D) & (R() \leq p) \\ x_{id} & (R() > p) \end{cases} \quad (7)$$

其中: p 为变异概率; x_{\max} 为位置所允许的最大值; $R(1,D)$ 为 D 个 0~1 之间的随机数。

笔者分别使用 Griewank 测试函数、Rosenbrock 测试函数和 Ackley 函数将标准 PSO 算法、自适应粒子群优化算法 (adaptive particle swarm optimization, 简称 APSO) 与 VSAPSO 算法进行测试,验证该方法提高了算法寻优能力。其适应度值变化如图 3~5 所示。可见,笔者提出的 VSAPSO 算法收敛速度相对较优。




图 3 Griewank 函数下适应度值变化对比
Fig. 3 Comparison of fitness values under Griewank function




图 4 Rosenbrock 函数下适应度值变化对比
Fig. 4 Comparison of fitness values under Rosenbrock function




图 5 Ackley 函数下适应度值变化对比
Fig. 5 Comparison of fitness values under Ackley function

当达到最大迭代次数时,3 种算法的最小适应度如表 1 所示。由表 1 可知,VSAPSO 算法的最小适应度值最小,寻优能力高于其他两种 PSO 算法。

表 1 3 种测试函数下最小适应度

Tab. 1 Minimum fitness under three test functions			
测试函数	PSO	APSO	VSAPSO
Griewank	0.012 6	0.009 9	0
Rosenbrock	0.079 5	0.004 7	$1.849\ 6 \times 10^{-14}$
Ackley	0.056 3	0.008 7	$6.921\ 9 \times 10^{-9}$

2.2 VSAPSO-BP 神经网络算法流程

笔者提出的 VSAPSO-BP 神经网络算法流程主要步骤如下。

- 1) 对 BP 网络的拓扑结构和神经元数目进行初始化。
- 2) 根据 BP 网络的拓扑结构和神经元数目,对 PSO 算法的种群规模、最大迭代次数、惯性权重、学习因子、最大迭代次数、适应度函数、粒子位置和速度初始化,根据式(8)确定每个粒子的维数。

$$D = (S_1 + 1) S_2 + (S_2 + 1) S_3 \quad (8)$$

其中: S_1 为输入层神经元数; S_2 为隐含层神经元数; S_3 为输出层神经元数。

- 3) 利用提出的自适应调整惯性权重和变异算子相结合的方式对粒子的速度与位置进行更新。

- 4) 对每个粒子位置对应的适应度值进行计算,得到粒子的个体适应度值与群体适应度值,并将个体最佳适应度值作为群体适应度值。

- 5) 达到最大迭代次数后,使用群体最优位置对

BP 神经网络的权值阈值进行赋值,使用该网络对样本进行训练,得到输出值。

3 实例数据分析

3.1 样本数据提取

笔者使用的数据为中国矿业大学(北京)研制的大容量数据记录仪在煤矿井下采集的 EBZ160 型掘进机回转台振动加速度数据,其采样频率为 10 kHz,原始波形如图 6 所示。




图 6 回转台振动数据原始波形图

Fig. 6 Original waveform of rotary table vibration data

使用 Matlab 对振动加速度信号进行分析,得到如图 7 所示的振动加速度有效值、方差和峭度的归一化波形图。由于回转台的健康状态可由回转时的振动加速度信号体现,且为了排除截割时的较大扰动,选取掘进机在非截割状态下掘进机回转台正常工作时振动加速度的特征值作为训练样本。在目标数据中选取 250 组数据作为样本,其中 200 组为训练样本,50 组为测试样本,部分样本数据如表 2 所示。




图 7 特征值归一化波形图

Fig. 7 Eigenvalue normalized waveform

表 2 部分样本数据

Tab. 2 Part of the sample data

有效值/(10m·s ⁻²)	方差/(10m·s ⁻²)	峭度
0.040 1	0.076 8	3.243 7
0.047 7	0.109 3	3.397 1
0.042 8	0.087 8	3.160 2
0.033 9	0.054 9	4.184 7
0.035 9	0.061 9	3.835 3
0.035 5	0.060 5	3.737 8
0.038 9	0.072 2	3.677 7
0.037 8	0.068 6	3.412 5
0.036 5	0.064 1	3.873 3
0.037 8	0.068 4	3.751 5

3.2 非健康数据构造

得到样本数据后,使用 SVDD 方法对训练样本进行训练,使用测试样本对训练好的 SVDD 进行测试,结果如图 8 所示。由图 8 可知,建立的 SVDD 网络可以对非截割状态下回转台回转时健康数据进行识别,准确率为 100%。




图 8 SVDD 测试结果

Fig. 8 SVDD test results

根据提出的原则对测试样本进行处理,得到线性权值与识别准确率关系如表 3 所示。

表 3 线性权值与识别准确率关系

Tab. 3 The relationship between linear weights and recognition accuracy

线性权值	准确率/%	线性权值	准确率/%
1.1 倍	100	1.5 倍	70
1.2 倍	100	1.6 倍	30
1.3 倍	100	1.7 倍	0
1.4 倍	100	1.8 倍	0

由表 3 可知,当分类准确率大于 70% 时,线性权值在 1~1.5 之间,可将该线性权值区间内的数据归类为健康数据。当分类准确率为 30%~70% 时,线性权值在 1.5~1.6 之间,可将该线性权值区间内的数据归类为故障临界数据。当分类准确率小于 30% 时,线性权值大于 1.6,由于发生故障时特征向量的值可能会达到健康时特征值的 8 倍以上,因此笔者将线性权值的上限暂设为 8,线性权值取值为 1.6~8,可将该线性权值区间内的数据归类为故障数据。该线性权值与分类准确率的关系即为非健康数据构造的依据。各类数据的线性权值取值范围及数据构造公式如表 4 所示。表 4 中: S_{1i} 为第 i 个健康数据; S_{2i} 为第 i 个故障临界数据; S_{3i} 为第 i 个故障数据; s_i 为第 i 个原始健康数据; R_1 为 1~1.5 之间的随机数; R_2 为 1.5~1.6 之间的随机数; R_3 为 1.6~8 之间的随机数, $i=1, 2, \dots, 250$ 。

笔者使用 200 组训练样本和 50 组测试样本,共 250 组样本按照表 4 的数据构造公式进行数据构造,共构造健康、故障临界与故障 3 组数据,每组数据各 250 个样本。图 9 为目标数据特征值在二维空间的 SVDD 分类。

表 4 各类数据线性权值取值范围及数据构造公式
Tab. 4 The linear weights range and data construction formula of various types of data

数据类型	线性权值	数据构造公式
健康数据	1~1.5	$S_{1i} = s_i R_{1i}$
故障临界数据	1.5~1.6	$S_{2i} = s_i R_{2i}$
故障数据	1.6~8	$S_{3i} = s_i R_{3i}$




图 9 基于 SVDD 的目标数据划分

Fig. 9 Target data division based on SVDD

3.3 目标数据状态识别

将该三维向量作为 BP 网络的输入向量,因此 BP 网络的输入层神经元个数为 3 个。由于笔者将数据分为健康、故障临界与故障 3 类,数据标签分别为[1],[0],[−1],因此 BP 网络输出层神经元个数为 3 个。由于 1 个隐含层即可解决此类分类问题,因此使用 1 个隐含层,隐含层神经元数目为 7 个。经过数据归一化,输入向量在[0,1]之间,因此输入层激活函数设定为 logsig,输出向量为[0,1],输出层激活函数设定为 tansig。

经测试,PSO 算法的粒子群规模 $N=40$ 为宜,最大迭代次数 $M=1\,000$,最大惯性权重 $\omega_{\max}=0.9$,最小惯性权重 $\omega_{\min}=0.4$,学习因子 $c_1=c_2=2.05$,由于输入向量取值在[0,1]之间,因此最大速度

$v_{\max}=1$ 。适应度函数的选择对 BP 网络的训练效果影响较大,选择适应度函数为 BP 网络目标输出与实际输出的均方差,适应度值的大小与误差大小成正相关。适应度函数为

$$F = \frac{1}{n} \sum_{i=1}^n (P_i - T_i)^2 \quad (i = 1, 2, \dots, n) \quad (9)$$

其中: n 为样本个数; P_i 为第 i 个样本的理想输出值; T_i 为第 i 个样本的实际输出值。

将构造的健康、故障临界与严重故障训练样本带入 PSO-BP 神经网络、APSO-BP 神经网络和笔者构建的 VSAPSO-BP 网络进行训练。目标数据在 BP 神经网络的适应度下降曲线如图 10 所示。可见,相较于 PSO-BP 和 APSO-BP 神经网络,VSAPSO-BP 神经网络的适应度值下降速度更快。




图 10 适应度下降曲线

Fig. 10 Fitness decline curve

将训练完成的神经网络用测试样本进行测试,结果如表 5 所示。由于健康数据与故障数据的特征都比较明显,因此识别率均较高。故障临界数据的特征比较模糊,因此识别率相对较低。测试结果表明,笔者建立的 VSAPSO-BP 神经网络对数据的识别准确率较高且平均误差较小,分类性能优于 PSO-BP 神经网络和 APSO-BP 神经网络。

表 5 测试结果
Tab. 5 Test results

方法	PSO-BP			APSO-BP			VSAPSO-BP		
状态	健康	临界	严重	健康	临界	严重	健康	临界	严重
识别率/%	95	70	100	100	70	100	100	75	100
总计/%	88.3			90			91.7		
平均误差	0.085 7			0.082 6			0.075 6		

4 结 论

1) 针对大型装备仅具有单类健康数据样本的问题,提出了一种基于 SVDD 的非健康数据描述方法,定义了健康、故障临界与严重故障数据的划分依据,为单类数据的异常检测提供了一种可行方法。

2) 提出了 VSOPSO 算法,使用自适应惯性权重与变异方法相结合的方法提高了 PSO 算法的局部搜索能力、全局搜索能力以及 PSO 算法的寻优精度与速度,降低了 PSO 算法寻优时陷入局部极小值的几率。

3) 针对实际工况中掘进机回转台健康状态诊断的问题,给出了详细的实验步骤与实验数据。结

果表明,该方法能够准确有效地对掘进机回转台健康状态进行诊断,在掘进机故障诊断方面应用价值较高,为解决并普及适用仅具有单类健康数据的大型机械故障诊断异常检测问题提供了一种新的方法与思路。

参 考 文 献

- [1] 张天瑞,于天彪,赵海峰,等. 数据挖掘技术在全断面掘进机故障诊断中的应用[J]. 东北大学学报:自然科学版,2015,36(4):527-531,541.
Zhang Tianrui, Yu Tianbiao, Zhao Haifeng, et al. Application of data mining technology in fault diagnosis of tunnel boring machine[J]. Journal of Northeastern University: Natural Science, 2015, 36(4): 527-531, 541. (in Chinese)
- [2] 邵晋敏. EBZ160TY 型掘进机故障诊断专家系统的研究[J]. 煤矿机械,2013,34(6):265-267.
Shao Jinmin. Research of fault diagnosis expert system on EBZ160TY roadheader [J]. Coal Mine Machinery, 2013, 34(6): 265-267. (in Chinese)
- [3] 尹同舟,唐至威,杨健健,等. 基于多传感器 BP 网络掘进机截割部故障诊断研究[J]. 煤炭科学技术,2016,44(9):134-139.
Yin Tongzhou, Tang Zhiwei, Yang Jianjian, et al. Study on failure diagnosis of cutting unit in roadheader based on BP network of multi sensor [J]. Coal Science and Technology, 2016, 44(9): 134-139. (in Chinese)
- [4] 罗慧,王友仁. 基于 GSM-SVDD 的模拟电路故障诊断方法[J]. 电机与控制学报,2013,17(1):108-113.
Luo Hui, Wang Youren. A GSM-SVDD method for analog circuits fault diagnosis [J]. Electric Machines and Control, 2013, 17(1): 108-113. (in Chinese)
- [5] 付文龙,周建中,李超顺,等. 基于模糊 K 近邻支持向量数据描述的水电机组振动故障诊断研究[J]. 中国电机工程学报,2014,34(32):5788-5795.
Fu Wenlong, Zhou Jianzhong, Li Chaoshun, et al. Vibrant fault diagnosis for hydro-electric generating unit based on support vector data description improved with fuzzy K nearest neighbor [J]. Proceedings of the CSEE, 2014, 34(32):5788-5795. (in Chinese)
- [6] 张玲玲,廖红云,贾继德,等. 基于 SVDD 与 D-S 证据理论的发动机故障诊断研究[J]. 汽车工程,2013,35(1):23-26,50.
Zhang Lingling, Liao Hongyun, Jia Jide, et al. A research on engine fault diagnosis based on SVDD and D-S evidence theory [J]. Automotive Engineering, 2013, 35(1): 23-26, 50. (in Chinese)
- [7] 张敏龙,王涛,王旭平,等. 带故障样本的弹性双阈值 SVDD 在线故障诊断算法及其应用[J]. 振动工程学

报,2016,29(3):555-560.

- Zhang Minlong, Wang Tao, Wang Xuping, et al. On-line fault diagnosis algorithm based on variable dual-threshold SVDD with negative samples and its application [J]. Journal of Vibration Engineering, 2016, 29(3):555-560. (in Chinese)
- [8] 陈喜阳,闫海桥,孙建平. 基于 PSO-BP 与组合矩的水电机组轴心轨迹识别[J]. 振动、测试与诊断,2016,36(1):108-114.
Chen Xiyang, Yan Haiqiao, Sun Jianping. Research on the identification of axis orbit in hydro-generator unit base on PSO-BP and combined moment invariants [J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(1): 108-114. (in Chinese)
- [9] 王东风,孟丽,赵文杰. 基于自适应搜索中心的骨干粒子群算法[J]. 计算机学报,2016,39(12):2652-2667.
Wang Dongfeng, Meng Li, Zhao Wenjie. Improved bare bones particle swarm optimization with adaptive search center [J]. Chinese Journal of Computers, 2016, 39(12): 2652-2667. (in Chinese)
- [10] 徐卫亚,徐飞,刘大文. 位移时序预测的 APSO-WLSS-VM 模型及应用研究[J]. 岩土工程学报,2009,31(3):313-318.
Xu Weiya, Xu Fei, Liu Dawen. Study and application of displacement time series forecast based on APSO-WLSSVM [J]. Chinese Journal of Geotechnical Engineering, 2009, 31(3): 313-318. (in Chinese)
- [11] 高保龙,李景灿,韩力,等. 基于改进 PSO 的无刷双馈风力发电机优化设计[J]. 太阳能学报,2015,36(8):1833-1840.
Gao Baolong, Li Jingcan, Han Li, et al. Design optimization of burshless doubly-fed wind power generator based on improved PSO algorithm [J]. Acta Energiæ Solaris Sinica, 2015, 36(8): 1833-1840. (in Chinese)
- [12] 李冠男,胡云鹏,陈焕新,等. 基于 SVDD 的冷水机组传感器故障检测及效率分析[J]. 化工学报,2015,66(5):1815-1820.
Li Guannan, Hu Yunpeng, Chen Huanxin, et al. SVDD-based chiller sensor fault detection method and its detection efficiency [J]. Journal of Chemical Industry and Engineering(China), 2015, 66(5):1815-1820. (in Chinese)



第一作者简介:杨健健,男,1988 年 4 月生,博士、硕士生导师。主要研究方向为矿山机械自动化与智能化、智能监测与控制、设备状态监测与故障诊断和无线传感器及其网络。曾发表《基于模糊判据的煤岩性状截割硬度识别》《煤炭学报》2015 年第 40 卷 S2 期)等论文。
E-mail: yangjiannedved@163.com