

基于支持向量数据描述的网络可生存性综合评估^{*}

梁 霄, 孟相如, 陈铎龙, 庄绪春
(空军工程大学 信息与导航学院, 西安 710077)

摘 要: 针对网络可生存性综合评估方法中指标权重难以确定的问题, 提出了基于支持向量数据描述(SVDD)的网络可生存性综合评估方法。该方法分析了SVDD的几何意义, 采用二进制粒子群(BPSO)算法对建立的评估特征指标集进行特征选择, 将所得的特征指标集视为整体来建立SVDD分类模型, 并以测试样本点与模型的相对距离为依据评估系统的可生存性, 避免了综合评估中指标权重确定的主观性。最后通过网络实例验证了评估模型的有效性。

关键词: 网络可生存性; 综合评估; 支持向量数据描述; 二进制粒子群算法; 特征选择; 相对距离

中图分类号: TP393.08 **文献标志码:** A **文章编号:** 1001-3695(2013)03-0853-03

doi:10.3969/j.issn.1001-3695.2013.03.054

Comprehensive evaluation for network survivability based on support vector data description

LIANG Xiao, MENG Xiang-ru, CHEN Duo-long, ZHUANG Xu-chun
(Information & Navigation Institute, Air Force Engineering University, Xi'an 710077, China)

Abstract: Aimed at the problem of indexes weighting ensuring in comprehensive evaluation, this paper proposed a comprehensive evaluation for network survivability based on support vector data description (SVDD). It analyzed the meaning of SVDD firstly, and constructed the survivability feature index set from the angle of key attributes and characteristics. Then the index set was selected and optimized by using the binary particle swarm optimization (BPSO) algorithm. This method constructed the SVDD classify model by regarding the optimum feature subset as a integrity. And it introduced the relative distance in kernel space between diagnostic samples and distributed spheres as a basis to evaluate the system survivability. It avoided the subjectivity of indexes weighting ensuring in comprehensive evaluation by using this method. Finally, it provided a network example to verify the validity of the evaluation method.

Key words: network survivability; comprehensive evaluation; support vector data description; discrete binary particle swarm optimization; feature selection; relative distance

网络可生存性是在信息技术高速发展, 网络恶意攻击、入侵频繁发生的形势下应运而生的新的网络安全理念, 它强调的是在遭受攻击、故障或意外事故时, 网络能够及时完成关键任务的能力。网络可生存性评估是采用一定的方法对可生存性能力和状态进行有效度量, 通过评估可以优化系统安全配置、调整可生存性策略、为网络管理提供决策依据。

目前, 可生存性评估分析方法可分为三种: 定性、定量和综合评估方法^[1-3]。综合评估方法结合了定性与定量评估方法的优点, 将评估过程转换为系统关键属性的度量, 但是存在着指标权重的确定主观性较强且难以适应时刻变化的网络环境的缺点。为解决这类问题, 统计学习理论中的新型机器学习方法——支持向量机被广泛地应用于各类评估, 并取得了一定的研究成果。文献[4]通过分析影响信息安全的主要因素, 构建多分类支持向量机, 实现对信息安全风险的等级评估。文献[5]分析了标准支持向量机的几何意义, 将网络健康状态评估转换为分类问题, 避免了指标权重确定的主观性。文献[6]采

用支持向量数据描述方法对设备性能退化的每个状态分别建立评估模型, 依据测试分类结果对退化程度进行评估。基于上述思想, 本文通过分析支持向量数据描述的意义及可生存性的关键属性及特点, 将可生存性的评估转换为分类问题。然后采用二进制粒子群算法选择可生存性特征指标, 并根据网络历史样本建立SVDD分类评估模型, 结合隶属度函数对系统的可生存性状态进行等级评估。

1 SVDD与可生存性评估

1.1 SVDD方法

支持向量数据描述^[7,8]是在支持向量机理论基础之上发展起来的, 用于解决单分类问题的方法。不同于支持向量机通过构造最优超平面来进行数据描述, 它将目标类样本通过非线性映射到高维特征空间, 寻找能包含目标样本的最小半径超球, 通过超球面来区分目标类与非目标类, 具有训练数据量小、学习仅需目标类样本等优点。

收稿日期: 2012-07-30; **修回日期:** 2012-09-09 **基金项目:** 国家自然科学基金资助项目(61003252); 全军军事学研究生课题(2011JY002-524)

作者简介: 梁霄(1988-), 女, 辽宁抚顺人, 硕士研究生, 主要研究方向为网络可生存性; 孟相如(1963-), 男, 陕西西安人, 教授, 博导, 主要研究方向为宽带通信网络技术; 陈铎龙(1988-), 男, 陕西西安人, 硕士研究生, 主要研究方向为网络可生存性; 庄绪春(1980-), 男, 山东临沂人, 讲师, 主要研究方向为宽带通信网络技术。

给定训练样本集 $X = \{x_i, i=1, \dots, n\}$, 寻找中心为 a 、半径为 R 的超球体, 能够将所有 (或大多数) 样本包含在内, 球体可表示为

$$F(R, a, \xi_i) = R^2 + C \sum_i \xi_i$$

$$\text{s. t. } (x_i - a)^T (x_i - a) \leq R^2 + \xi_i \quad \xi_i \geq 0 \quad (1)$$

其中: ξ_i 为松弛因子, 控制野值对超球面的影响; 常数 C 为惩罚因子, 实现错分样本比例与算法复杂度的折中。 a 和 R 可通过将约束问题转换为 Lagrange 算式来求解:

$$L(R, a, \xi_i, \alpha_i) = \sum_i \alpha_i (x_i \cdot x_j) - \sum_{i,j} \alpha_i \alpha_j (x_i \cdot x_j) \quad (2)$$

其中: α_i 为 Lagrange 系数, $0 \leq \alpha_i \leq C$ 且 $\sum_i \alpha_i = 1$, 对应 α 不为 0 的样本即为支持向量 (support vector, SV), 体现在分类球面上。

通常在原始样本空间无法对目标类进行描述, 根据统计学习理论, 可使用核函数 $K(x_i, x_j)$ 实现样本从低维空间到高维空间的映射, 建立特征空间的超球体。核函数有多种, 本文选用高斯核函数, σ 为核参数:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (3)$$

高维特征空间中超球的半径 R 可由支持向量 x_s 计算得出:

$$R^2 = 1 - 2 \sum_i \alpha_i K(x_i, x_s) + \sum_{i,j} \alpha_i \alpha_j K(x_i, x_j) \quad (4)$$

测试样本 z 与超球体中心 a 的距离为

$$D^2 = 1 - 2 \sum_i \alpha_i K(z, x_i) + \sum_{i,j} \alpha_i \alpha_j K(x_i, x_j) \quad (5)$$

若 $D \leq R$, 说明测试样本 z 位于超球体内, 则接受 z 为目标样本; 否则, z 不属于目标样本。

1.2 SVDD 在可生存性评估中的应用

在网络的实际运行中, 由于时刻面临各种各样的威胁, 系统的可生存性状态也是时变的。而对于 SVDD 而言, 一个超球体仅能描述一种网络状态, 对每种状态进行建模是不实际的, 处于中间状态的网络样本也难以获取。因此, 可以对网络正常状态样本和不能提供关键服务时的损伤状态样本分别建立超球体 S_1 和 S_2 进行数据描述。由分类原理可知, 位于两个超球体 S_1 和 S_2 外的样本可认为是处于网络可生存性中间状态的样本, 其与 S_1 的距离越小 (与 S_2 的距离越远), 与网络的正常状态越相似, 可生存性状态越好。因此, 根据测试样本与超球面的距离可对网络可生存性状态等级进一步划分, 将评估问题转换为分类问题, 并在分类过程中将网络可生存性的评估特征指标作为一个整体, 避免了指标权重确定的主观性。

由于使用不同的核参数对正常状态样本和损伤状态样本分别进行训练, 所得的超球体所在的特征空间没有关联, 因此可采用相对距离 $d = \frac{D}{R}$ 来评估网络的可生存性状态, 如图 1 所示。




图1 测试样本的相对距离

依据测试样本 z 的相对距离及 SVDD 分类原理, 评估结果可分为以下几种情况:

- 当 $d_1 > 1$ 且 $d_2 > 1$, 即 z 位于两个超球体外时, 若 $d_1 \leq d_2$, 网络可生存状态为较好; 若 $d_1 > d_2$, 则网络可生存状态为较差。
- 当 $d_1 \leq 1$ 或 $d_2 \leq 1$, 即 z 位于超球体内时, 可生存状态为正常或损伤。

为能更直观体现网络的可生存性程度, 引入模糊数学中的隶属度概念, 根据相对距离对于评估模型的意义, 选用模糊分布中的正态分布来描述位于超球体外部的网络测试样本的可生存性程度, 如式 (6) 所示, 测试样本 z 对超球体 S_i 的隶属度为

$$u_i = \begin{cases} 1 & d \leq a \\ \exp\left[-\frac{(d-a)^2}{b^2}\right] & d > a \end{cases} \quad (6)$$

由分类原理可知 $a=1$, b 可根据网络训练数据来确定。对所得的隶属度值进行归一化:

$$\mu_i = \frac{\mu_i}{\sum_i \mu_i} \quad (7)$$

则归一化后所得的 μ_i 即为网络测试样本 z 所代表的可生存性程度。

2 基于 BPSO 的可生存性特征指标选择

选取全面、合理的可生存性评估特征指标是综合评估的客观依据和前提条件, 但现有的评估指标体系在建立过程中, 多以专家意见为主, 主观因素较强, 难免存在一些冗余的特征指标, 增加了特征维数, 降低了训练速度。支持向量机虽然可以有效处理高维数据, 但研究表明在特征选择之后使用支持向量机作为分类器, 识别效果会得到显著提高^[9]。因此, 在进行 SVDD 分类评估之前, 找到最能反映可生存性的特征指标是十分必要的。鉴于粒子群算法在数据处理方面的优点和广泛应用, 本文选择二进制粒子群算法进行可生存性特征指标的选择。

2.1 二进制粒子群算法

粒子群算法是一种模仿鸟类群体行为的智能优化算法, 可解决连续函数的优化问题。在算法中, 群体中的每个粒子都是一个潜在的解, 通过学习历史中自身的最优位置 p_{best} 和群体最优位置 g_{best} 来更新位置和速度, 并根据粒子的位置计算适应度函数来判断解的优劣, 不断迭代找到最优解。

若粒子群的搜索空间为 M 维, 粒子的位置和速度分别为 $P_i = (p_{i1}, p_{i2}, \dots, p_{iM})$ 和 $V_i = (v_{i1}, v_{i2}, \dots, v_{iM})$, 则其迭代式为

$$\begin{cases} v_{it}^{t+1} = v_{it}^t + c_1 r_1 (p_{best_i} - p_{it}^t) + c_2 r_2 (g_{best_i} - p_{it}^t) \\ p_{it}^{t+1} = p_{it}^t + v_{it}^{t+1} \end{cases} \quad (8)$$

其中: t 为迭代次数, c_1 和 c_2 为学习因子, r_1 和 r_2 为 $[0, 1]$ 之间的随机数。

为解决粒子群在离散问题中的应用, Kennedy 和 Eberhart 在标准粒子群的基础之上提出了二进制粒子群优化算法^[10]。其原理和速度的更新方式不变, 只是将粒子位置的每一维分量限制为 0 或 1, 并根据速度的 Sigmoid 函数变换来控制粒子的位置更新:

$$\begin{aligned} & \text{if } \text{rand} < s(v_{im}^t) \\ & \text{then } p_{im}^{t+1} = 1; \text{ else } p_{im}^{t+1} = 0 \end{aligned} \quad (9)$$

2.2 可生存性特征指标的选取

根据可生存性的定义, 为保证关键服务的正常运行, 网络系统必须具有抵抗、识别、恢复和自适应四个关键属性。结合系统的服务可生存性、拓扑可生存性和环境因素, 选取可生存性的初始特征指标集 S_{in} 。其中抵抗性包括: 攻击度 s_1 , 即攻击固有的威胁程度; 攻击结果 s_2 , 即系统遭受攻击后关键服务等级的变化; 粘聚度 s_3 和连接度 s_4 , 分别用来衡量链路或节点对

网络连通度的影响。识别性包括:识别时间 s_5 和识别率 s_6 , 分别指系统识别攻击及其影响范围需要的时间和程度;漏报率 s_7 , 即攻击没有被识别出的概率。恢复性包括:恢复时间 s_8 和恢复程度 s_9 , 分别指恢复受损的信息及服务所需的时间及程度;服务关键性 s_{10} , 即系统所提供服务的权重;路由重构时间 s_{11} , 是指故障发生后路由重构的时间间隔。自适应性包括:自适应周期 s_{12} 和程度 s_{13} , 是系统对遭受过的攻击, 积累经验调整可生存性策略的周期和程度。对于定性指标如 s_1 、 s_{10} 和 s_{13} , 可根据系统类型、统计信息及专家经验等途径获得。而对于定量指标如 s_3 、 s_5 和 s_8 , 则可根据系统的运行状况实际测量而得。

对于拟定的特征指标集 S_m , 采用 BPSO 进行特征选择时, 每个粒子的位置即为一组二进制编码。第 i 个粒子的位置为 $P_i = (p_{i1}, p_{i2}, \dots, p_{iM})$, $M = 13$; 位置的每一维分量 p_{in} 对应着指标 s_n ; p_{in} 的取值决定是否选取相应的特征, 取 1 则选择, 取 0 则丢弃。粒子按照式(8)(9)不断迭代, 判断适应度函数, 找到的最优位置即为最优的特征组合。这样, 在 SVDD 分类效果不变或优化的前提下, 既提高了训练速度, 又减少了网络可生存性评估测试样本的特征数据采集。

3 可生存性评估过程

根据以上的分析, 网络可生存性的评估过程可由图 2 表示, 具体步骤如下:

a) 根据拟定的可生存性初始评估指标集 S_m , 选择出网络运行的正常状态和崩溃状态两类历史样本数据。

b) 对样本数据进行预处理, 量化定性指标, 归一化定量指标, 对于效益型指标和成本性指标分别采用式(10)(11)进行处理, y_i 为指标 i 的原始数值, $y_{\min}$ 为指标 i 对应的最小值, $y_{\max}$ 为指标 i 对应的最大值:

$$y'_i = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}} \quad (10)$$

$$y'_i = \frac{y_{\max} - y_i}{y_{\max} - y_{\min}} \quad (11)$$

c) 应用 BPSO 算法对可生存性的特征指标进行选择, 生成新的特征指标集 S_u , 筛选样本数据。

d) 通过交叉验证方法寻找最优的核参数 σ 和惩罚因子 C , 分别输入正常样本和崩溃样本数据单独进行训练, 建立正常状态超球 S_1 和损伤状态超球 S_2 。

e) 根据 S_u 对网络可生存性测试样本进行采集并预处理, 输入特征空间, 计算相对距离并根据判断规则对样本分类。对位于超球外的测试样本, 利用隶属度函数将相对距离转换为测试样本的可生存性程度。

f) 输出可生存性的等级评估结果, 对结果进行分析, 并采取相应的可生存性策略保障系统正常运行。

4 实例验证

现以某网络为例, 根据系统统计日志、报警日志等分析收集到的网络历史样本数据, 挑选出正常类和损伤类各 20 组样本进行特征选择, 以类内类间距离准则为 BPSO 算法的适应度函数, 得到的最优特征指标集为 $S_u = \{s_2, s_4, s_6, s_7, s_9, s_{11}, s_{13}\}$ 。从 S_u 可以看出, 选出的特征指标仍然符合可生存性的四个关键属性, 可全面反映影响系统可生存性评估的关键因素, 达到了降维的目的。根据 S_u 筛选原有样本, 得到的样本数据如表 1

所示。




图2 可生存性评估流程

表1 网络可生存性历史样本数据

样本类别	评估指标						
	s_2	s_4	s_6	s_7	s_9	s_{11}	s_{13}
正常样本	0.85	0.89	0.92	0.07	0.95	0.18	0.94
	0.76	0.81	0.87	0.15	0.78	0.28	0.82
	0.82	0.90	0.94	0.11	0.88	0.23	0.89
损伤样本	0.26	0.24	0.40	0.56	0.31	0.73	0.33
	0.19	0.30	0.35	0.62	0.16	0.66	0.25
	0.34	0.41	0.28	0.70	0.29	0.58	0.27

对筛选后的两类历史样本分别建立正常超球 S_1 和损伤超球 S_2 , 选用高斯核函数为分类器核函数, 训练得到半径分别为 0.2516 和 0.3183 的超球 S_1 和 S_2 。按照 S_u 重新收集网络数据建立网络可生存性待测样本集, 将其输入到 SVDD 评估模型进行测试, 评估结果如表 2 所示。以测试样本 4 和 7 为例说明评估结果。样本 4 与正常超球 S_1 和损伤超球 S_2 的相对距离分别为 1.6627 和 4.8221, 样本 7 与 S_1 和 S_2 的相对距离分别为 3.4056 和 4.7832, 依据判断规则样本 4 和样本 7 都与网络正常状态比较类似, 计算隶属度函数得到样本 4 和 7 的可生存性程度分别为 70.8% 和 63.1%, 可生存性状态均为较好, 而对比其网络数据发现, 样本 7 的各指标值相对较差, 符合网络的实际情况。根据评估结果可知在这两种状态下, 网络均存在着一些薄弱环节, 需要管理员提高警惕, 加强维护。

表2 网络可生存性评估结果

网络测试样本	评估指标							可生存性	
	s_2	s_4	s_6	s_7	s_9	s_{11}	s_{13}	状态	可生存性程度/%
1	0.89	0.76	0.94	0.08	0.89	0.18	0.90	正常	100
2	0.45	0.60	0.42	0.53	0.52	0.64	0.33	较差	20.2
3	0.82	0.86	0.90	0.15	0.97	0.13	0.85	正常	100
4	0.66	0.71	0.81	0.20	0.91	0.40	0.81	较好	70.8
5	0.27	0.38	0.50	0.77	0.47	0.55	0.65	较差	11.8
6	0.20	0.29	0.34	0.79	0.36	0.85	0.34	损伤	0
7	0.56	0.59	0.71	0.34	0.45	0.50	0.38	较好	63.1

5 结束语

网络可生存性是由多种特征构成的综合概念, 评估时应建立全面、合理的指标集并减少评估过程中的主观因素, 为此本文将 BPSO 算法和 SVDD 方法结合起来对可生存性进行综合评估。在最初建立的特征指标集基础之上, 利用 BPSO 算法解决最优化问题的特性, 对原有特征指标集进行约简。并以此为依据训练 SVDD 的分类模型, 将可生存性的评 (下转第 860 页)

图1~3显示了三种模型预测准确率最接近平均值的一次实验的实验效果。通过这三幅图也可以对比出 GAFSA-SVR 模型的优势性。

如上所述,实验结果充分表明,GAFSA-SVR 网络流量预测模型预测精准度高,稳定度好,可靠性强,与 GA-SVR 及 CPSO-SVR 网络流量预测模型相比,具有很强的优势性。

5 结束语

本文研究使用 GAFSA 算法优化 SVR 流量预测模型参数选择过程,建立 GAFSA-SVR 网络流量预测模型。并通过仿真实验,表明了该模型不仅预测准确率高,而且稳定性好,可靠性强,预测效果非常好。未来可以将智能优化参数的算法与 SVR 算法自身的改进过程进行结合,建立更精准可靠的网络流量预测模型。

参考文献:

- [1] 党小超,阎林.基于多元线性自回归模型的流量预测[J].计算机工程,2012,38(1):84-89.
- [2] 邹柏贤,刘强.基于 ARMA 模型的网络流量预测[J].计算机研究与发展,2002,39(12):1645-1652.
- [3] 段智彬,孙恩昌,张延华,等.基于 ARMA 模型的网络流量预测[J].中国电子科学研究院学报,2009,4(4):325-356.
- [4] 薛可,李增智,刘浏,等.基于 ARIMA 模型的网络流量预测[J].微电子学与计算机,2004,21(7):84-87.
- [5] 张冉,赵成龙. ARIMA 模型在网络流量预测中的应用研究[J].计算机仿真,2011,28(1):171-174.
- [6] 李士宁,闫焱,覃征.基于 FARIMA 模型的网络流量预测[J].计算机工程与应用,2006,42(29):148-150.
- [7] 胡玉清,谭献海,宋正阳.基于 FARIMA 的网络建模与性能分析[J].计算机工程与设计,2008,29(18):4666-4714.
- [8] 曹建华,刘渊,戴悦.一种基于灰色神经网络的网络流量预测模型[J].计算机工程与应用,2008,44(5):155-157.
- [9] 马华林,李翠凤,张立燕.基于灰色模型和自适应过滤的网络流量预测[J].计算机工程,2009,35(1):130-152.
- [10] 洪飞,吴志美.基于小波的多尺度网络流量预测模型[J].计算机学报,2006,29(1):166-171.
- [11] 刘杰,黄亚楼.基于 BP 神经网络的非线性网络流量预测[J].计算机应用,2007,27(7):1770-1772.
- [12] 王俊松,高志伟.基于 RBF 神经网络的网络流量建模与预测[J].计算机工程与应用,2008,44(13):7-11.
- [13] 林雪纲,郑成兴,实旻,等.基于 FIR 神经网络的以太网网络流量预测[J].计算机工程,2006,32(8):124-130.
- [14] 侯家利. Elman 神经网络的网络流量预测[J].计算机仿真,2011,28(7):154-157.
- [15] 李丽.基于支持向量机的网络流量预测研究[D].南京:南京理工大学,2007.
- [16] 王定成.支持向量机建模预测与控制[M].北京:气象出版社,2009.
- [17] 谢国强.基于支持向量回归机的股票价格预测[J].计算机仿真,2012,29(4):379-382.
- [18] 陈强,吴慕春,薛月菊,等.支持向量回归机的碳通量预测[J].计算机工程与应用,2009,45(21):235-238.
- [19] 刘显德,高泓.基于 SVR 的组合预测模型及其应用[J].计算机工程与设计,2009,30(19):4506-4523.
- [20] HUANG Ji. Electromechanical equipment state forecasting based on genetic algorithm-support vector regression[J]. Expert Systems with Applications,2011,38(7):8399-8402.
- [21] CHEN Kuan-yu. Forecasting systems reliability based on support vector regression with genetic algorithms[J]. Reliability Engineering and System Safety,2007,92(4):423-432.
- [22] LIN Shih-wei, YING Kuo-ching, CHEN Shih, et al. Particle swarm optimization for parameter determination and feature selection of support vector machines[J]. Expert Systems with Applications,2008,35(4):1817-1824.
- [23] 王治.基于混沌粒子群优化 SVR 的网络流量预测[J].计算机仿真,2011,28(5):151-154.
- [24] 李晓磊,钱积新.人工鱼群算法:自下而上的寻优模式[J].系统工程理论与实践,2002,22(3):76-82.
- [25] 江铭炎,袁东风.人工鱼群算法及其应用[M].北京:科学出版社,2012.
- [26] LELAND W E, TAQQU M S, WILLINGER W. On the self-similar nature of Ethernet traffic(extended version)[J]. IEEE/ACM Trans on Networking,1994,2(1):1-15.
- [27] PAXSON V, FLOYD S. Wide-area traffic: the failure of poisson modeling[J]. IEEE/ACM Trans on Networking,1996,3(3):226-244.
- [28] CLEGG R G. A practical guide to measuring the Hurst parameter[J]. International Journal of Simulation: Systems, Science & Technology,2006,7(2):3-4.
- [29] 郝清民. R/S 系列分析的非线性估计及应用[J].系统工程理论与实践,2005,25(3):80-85.

(上接第855页)估问题转换为分类问题,避免了指标权重确定的主观性,具有泛化能力强、建模简单且便于计算机实现等优点。在下一步的研究工作中,将该模型中的隶属度函数进行改进,使得分类过程中相对距离的不确定性转换更为科学合理,评估结果更为可靠。

参考文献:

- [1] ELLISON R J, LINGER R C, LONGSTAFF T, et al. Survivable network system analysis: a case study[J]. IEEE Software, 1999, 16(4):70-77.
- [2] WANG H A, YAN Su, LIU Peng. A semi-Markov survivability evaluation model for intrusion tolerant database systems[C]//Proc of International Conference on Availability, Reliability and Security. 2010: 104-111.
- [3] 蔡均平,肖治庭,李雪冬.基于云模型的军事信息网络可生存性评估[J].武汉理工大学学报,2010,32(20):11-15.
- [4] 党德朋,孟真.基于支持向量机的信息安全风险评估[J].华中科技大学学报,2010,38(3):46-49.
- [5] 温祥西,孟相如.基于支持向量机和云模型的网络健康状态评估[J].北京邮电大学学报,2012,35(1):10-14.
- [6] 刘雨,陈进,潘玉娜,等.基于 SVDD 与信息融合技术的设备性能退化评估[J].振动与冲击,2009,28(9):21-24.
- [7] TAX D M J, DUIN R P W. Support vector domain description[J]. Pattern Recognition Letters,1999,20(11-13):1191-1199.
- [8] TAX D M J. Support vector data description[J]. Machine Learning, 2004,54(1):45-66.
- [9] 张庆,徐光华,王晶,等.基于支持向量域描述的多故障诊断动态模型[J].西安交通大学学报,2007,41(5):593-597.
- [10] BARZILAY O, BRAILOVSKY V L. On domain knowledge and feature selection using a support vector machines[J]. Pattern Recognition Letters,1999,20(5):475-484.
- [11] KENNEDY J, EBERHART R. Particle swarm optimization[C]//Proc of IEEE Conference on Neural Networks. Piscataway: IEEE Press, 1995:1942-1948.