

基于图像分析和野点检测的航空发动机磨损状态识别

谭真臻¹ 陈 果¹ 陈立波² 李 允¹

1. 南京航空航天大学, 南京, 210016 2. 北京航空工程技术研究中心, 北京, 100076

摘要:研究了基于发动机滑油滤磨屑图像的磨损状态自动识别技术。首先采用最大熵法和数学形态学方法,提取滑油滤磨屑图像中反映磨损状态的特征量;然后采集反映正常状态的航空发动机滑油滤图像,通过图像分析与特征提取,构造出仅包含正常样本的训练样本集,最后用野点检测方法对训练样本进行学习,并使用遗传算法对野点检测参数进行优化,得到了滑油滤磨屑图像的正常域,并以此来识别航空发动机磨损状态的严重程度。开发了发动机滑油滤监控系统(engine oil filter monitoring system, EOFMS),实现了基于野点检测的磨屑图像识别功能,并利用实际航空发动机滑油滤磨屑图像进行了实验分析,结果验证了该方法的有效性。

关键词:航空发动机;磨损监测;滑油滤分析;图像分析;野点检测;遗传算法

中图分类号:V163.6;TP277 **文章编号:**1004—132X(2010)07—0827—05

Aero - engine Wear State Recognition Based on Image Analysis and Novelty Detection

Tan Zhenzhen¹ Chen Guo¹ Chen Libo² Li Yun¹

1. Nanjing University of Aeronautics and Astronautics, Nanjing, 210016

2. Beijing Aeronautical Technology Research Center, Beijing, 100076

Abstract: An automatic identification technology based on engine oil filter debris image was investigated. Firstly, characteristic quantities of oil filter images which can reflect wear state were extracted with the maximum entropy method and mathematical morphology method. Then, oil filter images that can reflect normal state were collected, and the normal training sample sets were constructed through image analysis and feature extraction. Finally, the normal domain of oil filter image was obtained through normal training samples using novelty detection, and to identify the severity of the wear state of aero - engine according to the normal domain. Besides, the self - adaptive parameter of novelty detection was obtained by genetic algorithm. Engine oil filter monitoring system (EOFMS) was developed, and the recognition function of wear debris images based on novelty detection was realized. Besides, the experiments using actual aero - engine oil filter debris images were carried out, and the results show the effectiveness of the method.

Key words: aero - engine; wear monitoring; oil filter analysis; image analysis; novelty detection; genetic algorithm

0 引言

滑油滤上磨屑的多少和大小反映了发动机磨损的严重程度,对滑油滤进行图像采集得到的磨屑图像可以反映出磨屑的多少与堆积程度。因此,有效地从滑油滤磨屑图像中提取磨屑目标,并以此计算出反映磨损程度的定量指标,是有效识别发动机磨损状态的关键。研究发动机滑油滤磨屑监控方法,建立量化、标准化且便于操作的工艺方法和监控标准,可有效弥补现有光谱监控等方法难以有效预报因主轴轴承疲劳失效等引发危险性故障的技术局限性,提高发动机滑油系统故障预报成功率,这对于解决发动机安全使用的难题及完成战训飞行任务具有重要意义。

20世纪70年代,航空发动机滑油滤监控研

究已在国外开展,主要采取定期检查滑油滤,并把滑油滤上的碎屑清洗下来作定量分析的方法,但此方法耗时较长,一般仅作为辅助检测方法^[1]。近年来,国外对滑油滤碎屑采用X荧光能谱分析和扫描电镜能谱分析等技术进行研究的报道较多,这些系统一般比较复杂且投资较大^[2-3]。目前常用的铁谱分析方法运用了磨屑图像分析手段,同样也存在着局限性,主要表现在:取样要求苛刻,对铁谱图的观察依赖于人的水平和经验,并且铁谱方法对非铁磁性磨粒的检测存在一定的困难^[4]。

本文构建了航空发动机滑油滤磨损图像监控系统,设计了滑油滤图像采集装置,采集了实际航空发动机滑油滤图像,采用最大熵法^[5-6]、数学形态学方法^[7]提取磨屑图像上磨粒的周长和面积参数,以充分反映发动机磨损程度;针对航空发动机

收稿日期:2009-07-16

滑油滤磨屑图像正常样本获取容易,而异常样本获取困难的问题,引入基于一类分类的野点检测方法^[8-12],通过对正常样本的学习,得到正常磨损油滤图像的正常域边界,通过此边界来实现对油滤图像磨损状态的识别;开发了基于图像分析和野点检测的发动机滑油滤监控系统(engine oil filter monitoring system, EOFMS),并进行了实际的应用分析,验证了本文方法的有效性。

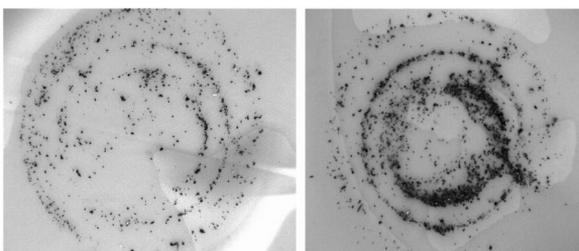
1 发动机滑油滤检测装置

在正常工作情况下,发动机滑油系统摩擦副产生的磨粒的粒径大多小于 50μm,滑油滤上无明显金属屑。当发动机滑油系统存在异常磨损时,滑油系统中会出现大量粒径大于 50μm 的大磨粒,滑油滤上出现超量的金属屑。这些故障中产生的大金属磨粒是发动机存在异常工况的明显征兆。

我们以洁净喷气燃料作为洗剂,以冷气瓶为压力源,使喷气燃料和冷气源在气雾喷射器内相遇形成喷雾,以此喷雾原位清洗滑油滤,将清洗下来的物质经过锥形漏斗收集到过滤组件上,利用过滤组件上的 300 目滤布,过滤出尺寸较大的磨屑。另外,滤布下安装有一定尺寸的环形永久磁铁,使铁磁性磨屑按照磁力线排列成环状,避免磨屑堆积,图 1a 所示即为滑油滤磨屑采集装置。然后选用 DH - HV1302UC 数字摄像机进行图像采集,图像大小为 640pixel × 512pixel,通过 USB 总线将采集的图像传入计算机内存。图 1b 所示为图像采集装置,发动机磨屑正常图像和异常图像如图 2 所示。



(a) 磨屑收集 (b) 图像采集
图 1 滑油滤检测装置

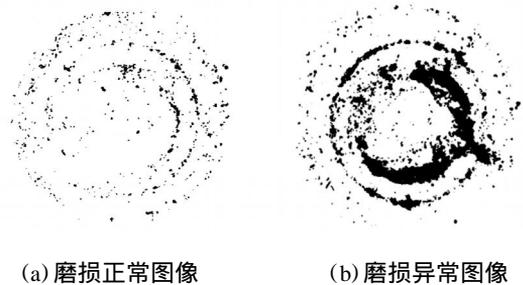


(a) 磨屑正常图像 (b) 磨屑异常图像
图 2 滑油滤磨屑图像

本文方法的优点是:喷气燃料和冷气源在外场均能被方便地提供;用气雾喷射器原位清洗滑油滤,其清洗效果优于采取毛刷刷洗的方式;所需洗剂量很少,清洗一个滑油滤仅需约 50mL 洗剂;滤布较粗,无需抽滤装置,液体即可自行流下。

2 滑油滤图像磨屑特征提取

从图 2 所示的油滤图像可以发现:图像中磨屑(图像中低灰度区域)的多少反映了发动机磨损状态的严重程度,如果能从图像中分割出磨屑区域,计算出该区域的面积和周长,则可以定量地反映出发动机磨损的严重程度。因此,选择从滑油滤磨屑图像上提取磨屑的周长和面积作为图像的特征,具体的提取步骤是:首先采用最大熵阈值分割法来提取图像中的磨屑目标,然后,对二值图像上的磨屑目标提取周长和面积值。关于最大熵阈值分割法基本原理参见文献[5-6]。对图 2 中的图像进行分割后的二值图像如图 3 所示。



(a) 磨屑正常图像 (b) 磨屑异常图像
图 3 最大熵分割后的二值图像

(1) 面积计算。在二值图像中,磨屑表现为灰度值为 0 的区域,面积的计算转换为统计灰度值为 0 的像素数目^[1]。设磨屑图像为 I ,则磨屑图像的分布面积 S 为灰度值为 0 的像素数目的和,即

$$S = N_I = \sum_{i=0}^m \sum_{j=0}^n f(i, j) \quad (i, j) \in I \quad (1)$$

其中, N_I 表示某一区域灰度值为 0 的像素数目; $f(i, j)$ 为与二值图像像素的灰度值相关的函数,当像素灰度为 0 时,其函数值为 1;当像素灰度为 255 时,其函数值为 0。所以,统计出的磨屑区域灰度值为 0 的像素的数目,即为磨屑区域面积。

(2) 周长计算。将集合 A 的边界表示成 (A) ,它可以运用数学形态学方法通过先由 B 对 A 腐蚀,而后用 A 减去腐蚀结果得到^[7]。即

$$(A) = A - (A \ B) \quad (2)$$

式中, B 为一个适当的结构元素(如正方形、三角形等); $A \ B$ 为 B 对 A 的腐蚀结果。

当边界 (A) 用一组数据点 $= \{V_i = (x_i, y_i) / i = 0, 1, \dots, N - 1\}$ 表示时,这些点连成的封闭折线的长度就是磨屑的周长 P ,即

$$P = \sum_{i=0}^{N-1} V_{i+1} - V_i \quad (3)$$

实验证明,使用本方法提取出的面积 S 、周长 P 的值准确反映了图像的真实值,有效地表示了磨屑图像的特征,因此, (S, P) 即成为代表磨屑图像的样本数据,用于检测磨损状况。

3 核方法下基于边界的野点检测原理

基于边界的野点检测方法^[8-12],其本质是寻找包含全体正类样本的最小球体,球体外即为野点区域。对于样本集 $X = \{x_1, x_2, \dots, x_N\}$,其中的样本都为正类。设将全体样本完全包围的最小球体的半径为 R ,球心为 a ,则有优化方程:

$$\min L(R) = R^2 \quad (4)$$

$$\text{s.t. } R^2 - (x_i - a) \cdot (x_i - a)^T = 0 \quad (5)$$

由式(4)和式(5)可定义 Lagrange 函数:

$$L(R, a, \lambda) = R^2 - \sum_{i=1}^N \lambda_i [R^2 - (x_i - a) \cdot (x_i - a)^T] \quad (6)$$

$$\lambda_i = \lambda_i \quad i = 1, 2, \dots, N$$

式中, λ_i 为 Lagrange 系数, $\lambda_i \geq 0$ 。

对式(6)求解,即有优化方程:

$$\max L = \sum_{i=1}^N \lambda_i x_i \cdot x_i - \sum_{i=1}^N \sum_{j=1}^N \lambda_j x_i \cdot x_j \quad (7)$$

约束条件为 $\sum_{i=1}^N \lambda_i = 1$ 及 $\lambda_i \geq 0$ 。根据 Karush - Kuhn - Tucker (KKT) 最优化条件, 中大部分元素为0,只有一小部分 $\lambda_i > 0$ (记为 l 个),与这些 λ_i 对应的样本点决定了边界的构成,即为支持向量。已知 X ,即可求出球心 $a = \sum_{i=1}^N \lambda_i x_i$,任选一支支持向量,求其与球心距离即为半径 R 。对于待定状态数据点 z ,令

$$f(z) = (z - a) \cdot (z - a)^T = (z - \sum_{i=1}^N \lambda_i x_i) \cdot (z - \sum_{i=1}^N \lambda_i x_i)^T = z \cdot z - 2 \sum_{i=1}^N \lambda_i z \cdot x_i + \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j x_i \cdot x_j \quad (8)$$

则判断 z 是否为野点的依据如下:

$$\begin{cases} f(z) > R^2 & z \text{ 为野点} \\ f(z) \leq R^2 & z \text{ 不为野点} \end{cases} \quad (9)$$

引入核函数来代替高维空间中的内积运算,优化方程变为

$$\begin{cases} \max L = \sum_{i=1}^N \lambda_i K(x_i, x_i) - \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j K(x_i, x_j) \\ \text{s.t. } \sum_{i=1}^N \lambda_i = 1 \quad \lambda_i \geq 0 \end{cases} \quad (10)$$

式(8)变为

$$f(z) = K(z, z) - 2 \sum_{i=1}^N \lambda_i K(z, x_i) + \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j K(x_i, x_j) \quad (11)$$

4 应用分析

4.1 滑油滤磨屑状态识别流程

本文采用图像分析和野点检测的方法,开发了航空发动机滑油滤监控系统。磨屑的检测流程如图4所示,其检测流程包括如下步骤:采集磨屑图像,录入正常样本案例图像;对正常的磨屑图像运用最大熵法和数学形态学方法提取周长和面积特征量;用正常样本磨屑的面积和周长特征量进行训练,构造包含所有正常样本的最小超球体,并求出该超球体的球心位置 a 和半径 R ;

采集一幅新的磨屑图像,对其进行上述步骤的处理,依据步骤中的最小超球体的球心位置求取函数 $f(z)$,将 $f(z)$ 求得的结果与最小超球体的半径 R 相比较,如果小于半径 R ,即新的磨屑图像处在最小超球体之内,则被认为是发动机磨损正常,反之,则被认为是发动机磨损异常,需要对发动机进行进一步的检查。

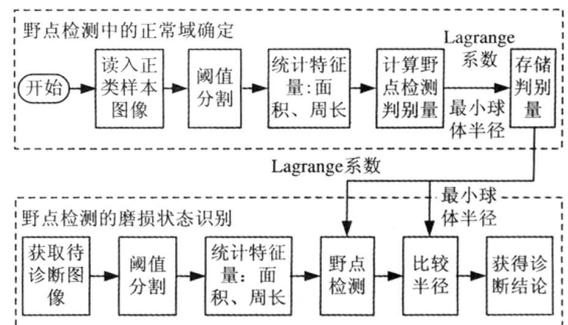


图4 基于图像分析和野点检测的滑油滤磨屑的检测流程图

4.2 滑油滤磨屑实验结果分析

为了验证基于图像分析和野点检测的滑油滤磨屑图像诊断方法的有效性,本文利用所建立的图像监控系统 EOFMS,对若干磨损正常和异常的发动机采集图像,从中随机选取110幅正常图像和40幅异常图像,共150幅样本图像,组成实验样本。从110幅正常图像中,随机选取55幅图像作为野点检测的训练样本;剩余55幅正常图像和40幅异常图像作为测试样本。提取图像的面积 S 和周长 P 特征,并将数据归一化到区间 $[0, 1]$ 中,得到归一化后的面积 s 和周长 p ,运用野点检测方法寻求决策面。

在野点检测的优化方程式(10)中,本文选择 $K(x, y) = \exp(-\|x - y\|^2 / \sigma^2)$,其中, σ 为核函数中的参数。实验证明,高斯径向基核函数效果要

好于其他核函数。优化方程中松弛变量的存在将允许一些点处在超球体外,处于超球体外的样本点个数由惩罚因子 C 决定,即: C 可决定对边缘样本的惩罚程度。由于 $\sum_{i=1}^N \xi_i = 1$ 且 $0 \leq \xi_i \leq C$, 所以当 $C < 1/l$ 时,优化方程无解;当 $C > 1$ 时,优化方程总有解,且其解一定满足条件 $\xi_i < C$, 此时所有样本都处在超球体内部;当 $1/l < C < 1$ 时,参数 C 起着控制超球体外的样本个数的作用,参数 C 的值越小,超球体外面的样本个数越多(l 为支持向量个数)。图 5 所示为参数 C 在不同取值下的正常域边界曲线(为了显示完整曲线,横纵坐标扩展到 -0.2 到 1.2)。图 5 中所有的高斯径向基核函数中的参数 σ 均选 0.7 。

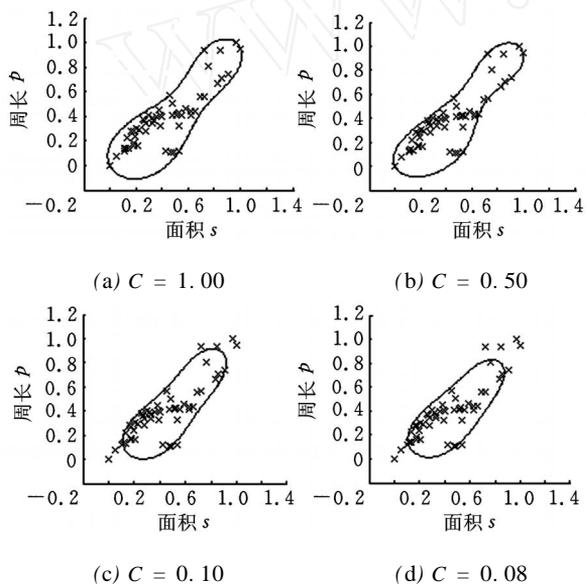


图 5 不同参数 C 时的封闭曲线

另外,高斯径向基核函数中的参数 σ 对优化边界起着非常重要的作用:参数 σ 越小,优化区域越紧致,如图 6 所示。图 6 中所有情况均选取 $C = 0.5$ 。

采用上述样本图像,对不同惩罚因子 C 和不同高斯径向基核函数参数 σ 下得到的样本识别率进行比较,结果如表 1 所示。

从表 1 可以看出:在惩罚因子 C 不变的情况下,正常测试样本的识别率随参数 σ 的增大而逐渐升高,而异常测试样本的识别率随参数 σ 的增大逐渐降低;在一定范围内,惩罚因子 C 增大,测试样本识别率升高,当超出一定的范围时, C 的作用将不明显。只有当 C 和 σ 取到某合适值时,对正常样本和异常样本才均能达到较高的识别率,此时,对应的支持向量个数通常较少。可见,这些参数在一定程度上对模型的分类精度具有很大影响。在实际应用中,选择适当的惩罚因子 C 和高斯核函数参数 σ 尤为重要。

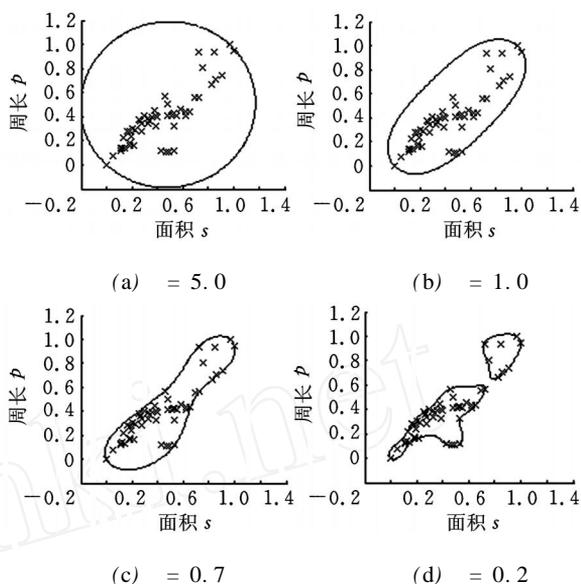


图 6 不同参数 σ 对正类域边界的影响

表 1 不同惩罚因子 C 及参数 σ 下样本识别率

惩罚因子 C	参数 σ	支持向量个数	正常样本识别率 (%)	异常样本识别率 (%)
0.08	0.2	21	67.3	100.0
	0.7	14	78.2	100.0
	1.0	13	81.8	100.0
	5.0	14	83.6	100.0
0.10	0.2	17	67.3	100.0
	0.7	11	70.9	100.0
	1.0	11	83.6	100.0
	5.0	11	83.6	100.0
0.50	0.2	16	70.9	100.0
	0.7	5	94.6	100.0
	1.0	3	98.2	97.5
	5.0	2	98.2	92.5
1.00	0.2	16	70.9	100.0
	0.7	5	94.6	100.0
	1.0	2	98.2	97.5
	5.0	2	98.2	92.5

目前对于支持向量机的参数选择尚无统一标准,本文借鉴文献[13]的思想,在进行参数影响分析的基础上,结合本文野点检测分类器模型,构造了基于遗传算法的模型参数自适应优化算法:首先,对惩罚因子 C 和高斯核函数 σ 值进行二进制编码,并随机产生初始化种群,其中, $0 < C < 1$, $\sigma > 0$;其次,对种群中的各染色体解码获取 C 值及 σ 值,在每组 C 值及 σ 值下,运用训练样本数据训练野点检测分类器,并用训练好的分类器分别计算磨损正常和异常测试样本集数据的识别率,根据交叉验证原理,识别率在一定程度上反映了野点检测模型的推广能力和分类能力,因此本文选择正常样本识别率 R_1 和异常样本识别率 R_2 的和作为遗传算法的目标函数值,即 $V_{obj} = R_1 + R_2$,以保证在同一组参数下,正常样本和异常样本识别率同时达到满意效果,所以基因适应度 $R = R_1 + R_2$;然后判断遗传算

法的停止条件是否满足,如果满足则停止计算,输出最优参数,否则,则执行选择、交叉和变异等操作,产生新一代种群,进行新一代的遗传,直到满足停止条件或者达到最大遗传代数。

利用上述样本,在遗传算法中设最大迭代次数为 100,种群规模为 20,个体串长度为 10,交叉率和变异率分别为 0.8 和 0.05,得到最优的分类器模型参数:惩罚因子 $C = 0.5$,高斯核函数参数 $\gamma = 0.7$ 。在此参数下,由上述 55 个训练样本计算得到:半径 $R = 0.5309$ 。用测试样本进行测试,将训练样本到正类域中心的距离与半径的比值,及测试样本到正类域中心的距离与半径的比值用散点图表示,如图 7 所示。其中,横坐标为样本编号,纵坐标为样本到正类域中心的相对距离。从图 7 可以看出:正常测试样本到正类域中心的相对距离基本都小于 1 或接近于 1,异常测试样本到正类域中心的相对距离都大于 1(图中直线为相对距离是 1 的直线)。以 1 作为分类阈值,得到识别结果:正常测试样本识别率为 94.6%,异常测试样本识别率为 100%,对比表 1 中的识别率,在此参数下,磨损正常和异常识别率均达到理想效果,说明了遗传算法自动获取最优分类器参数方法的有效性和本文方法对发动机磨损状态能够有效地识别。

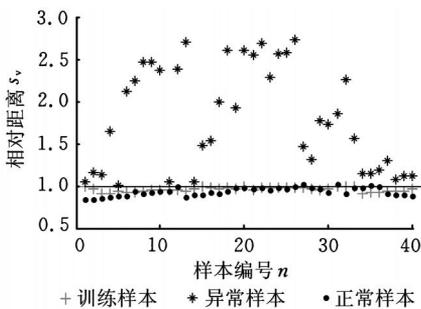


图 7 样本相对距离分布散点图

5 结束语

本文提出了一种基于图像分析和野点检测的发动机滑油滤磨损状态识别方法。首先构建了图像采集装置获取了滑油滤图像,然后使用最大熵法和数学形态学方法实现了对磨屑图像有效特征的提取,得到了描述滑油滤图像特征的周长和面积值,最后基于野点检测的方法,通过对正常案例图像样本集进行学习,得到正常域边界,并利用遗传算法获取最优参数,从而建立了野点检测诊断模型。该方法仅需要对一类样本进行训练,有效地解决了滑油滤磨屑图像正常样本获取容易、异常样本获取困难的问题。另外,作为离线检测,该

方法深入有效,而且不需要检测磨粒成分,能自动确定分类阈值,简单易行,减少了对专家经验的依赖性。最后的算例验证了该方法的正确有效性。

参考文献:

- [1] 陈果. 航空器检测与诊断技术导论[M]. 北京:中国民航出版社,2007.
- [2] Nelson I. Compact High Performance XFS Instrument for On-line Real-time Wear Metal Analysis of Lubricating Oils[C]//JOAP International Condition Monitoring Conference. Mobile, 2000: 99-108.
- [3] Podsiadlo P, Stachowiak G W. Characterization of Surface Topography of Wear Particles by SEM Stereoscopy[J]. Wear, 1997, 206(1):39-52.
- [4] 水友花,胡军华. 影响铁谱分析准确性的因素及对策[C]//2006 全国油液监测技术会议. 广州,2006: 119-121.
- [5] Sahoo P K, Arora G. A Thresholding Method Based on Two-dimensional Renyi's Entropy[J]. Pattern Recognition, 2004, 37(6):1149-1161.
- [6] 张九龙,潘泉,戴冠中. 模式识别的最大熵方法[J]. 信息与控制, 2004, 29(2):152-156.
- [7] Gonzalez R C, Woods R E. Digital Image Processing[M]. Beijing: Publishing House of Electronics Industry, 2007.
- [8] Haggett S J, Chu D F. Evolving Novelty Detectors for Specific Applications [J]. Neurocomputing, 2009, 72(10/12):2392-2405.
- [9] Tax D J, Duin R W. Support Vector Data Description[J]. Machine Learning, 2004, 54(1):45-66.
- [10] Larry M M, Malik M. One-class SVMs for Document Classification[J]. Journal of Machine Learning Research, 2002, 2:139-154.
- [11] Camci F, Chinnam R B. General Support Vector Representation Machine for One-class Classification of Non-stationary Classes[J]. Pattern Recognition 2008, 41(10):3021-3034.
- [12] 郭璇,杨晓元,刘佳,等. 基于遗传算法和一类 SVM 的隐秘图像检测方案[J]. 计算机工程与应用, 2007, 43(20):37-39.
- [13] 陈果. 基于遗传算法的支持向量机分类器模型参数优化[J]. 机械科学与技术, 2007, 26(3):347-350. (编辑 王艳丽)

作者简介:谭真臻,女,1986 年生。南京航空航天大学民航学院硕士研究生。主要研究方向为图像处理与模式识别。陈 果,男,1972 年生。南京航空航天大学民航学院教授、博士研究生导师。陈立波,男,1972 年生。北京航空工程技术研究中心高级工程师、博士。李 允,女,1983 年生。南京航空航天大学民航学院硕士研究生。