文章编号:1001-5078(2018)05-0659-06

·图像与信号处理 ·

# 电力设备 IR 图像特征提取及故障诊断方法研究

李 鑫1,崔昊杨1,许永鹏2,李高芳1,秦伦明1

(1. 上海电力学院电子与信息工程学院,上海200090;2. 上海交通大学电气工程系,上海200240)

摘 要:针对电力设备红外图像批量诊断中故障特征参量提取及参数配置难题,采用粒子群算法(PSO)与 Niblack 算法相结合的方法,将设备热像从背景中分割出来并提取出设备的最低、最高及平均温度等参量,通过计算设备各温升特征,构建支持向量机(SVM)样本特征空间。
 采用优化的蝙蝠算法(BA)对 SVM 参数进行寻优,并利用最优参数配置下的 SVM 实现设备故障诊断。对 220 组图像样本测试结果表明:该红外图像故障诊断方法在电力设备热故障缺陷检测方面的效率及准确率较高,适用于电力大数据中非结构化红外图像的批量分析与处理。
 关键词:故障诊断;粒子群算法;Niblack 算法;支持向量机;蝙蝠算法
 中图分类号:TP391.41 文献标识码:A DOI:10.3969/j.issn.1001-5078.2018.05.022

# Research on infrared image feature extraction and fault diagnosis of power equipment

LI Xin<sup>1</sup>, CUI Hao-yang<sup>1</sup>, XU Yong-peng<sup>2</sup>, LI Gao-fang<sup>1</sup>, QIN Lun-ming<sup>1</sup>

(1. Department of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 200090, China;2. Department of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Aiming at the problem of defect test and parameter assignment in the batch diagnosis of power equipment infrared image, PSO and Niblack algorithm are used to separate the equipment thermal image from the background and extract the lowest, highest and average temperature. Then, the SVM sample feature space can be constructed by calculating the temperature rise characteristics of the equipment. The support vector machine(SVM) parameters are optimized by using the optimized bat algorithm(BA), and the equipment defects diagnosis is realized by SVM under the optimal parameter configuration. According to the 220 groups of image sample testing results, the proposed method has high efficiency and accuracy in thermal defects detection of power equipment, and is suitable for batch analysis and processing of unstructured infrared images in large power data.

Key words: fault diagnosis; particle swarm optimization; Niblack algorithm; support vector machines; bat algorithm

1 引 言

红外热成像诊断技术通过非接触的方式检测电 力设备的温度场信息,已经成为状态评估领域的一 种重要检测手段<sup>[1]</sup>。迄今为止,对于设备红外图像 的分析,一般还是采用人工的方式。这种诊断方法 效率低下且准确性受人为因素影响<sup>[2]</sup>。在电力大 数据背景下,从海量的红外图像数据中实现设备状 态的准确分析与评估,已经成为该领域中的一个巨

基金项目:国家自然科学基金资助项目(No. 61107081; No. 11647023);上海市科委地方院校能力建设项目资助课题 (No. 15110500900; No. 14110500900);上海市自然科学基金面上项目(No. 17ZR1411500)资助。

作者简介:李 鑫(1990 - ),男,硕士研究生,研究方向为电力设备故障红外诊断。E-mail:lixinshiep@126.com 通讯作者:崔昊杨(1978 - ),男,教授,博士,从事电力设备状态检测研究。E-mail:cuihy@shiep.edu.cn 收稿日期:2017-08-30;修订日期:2017-10-31

大挑战与亟待解决的问题。

目前,设备红外故障图像自动化批量检测的难 点在于:红外热图像中设备与背景的分离以及在此 基础上的设备状态评估与诊断。其中,对于设备与 背景的分离问题,由于红外图像往往存在非均匀背 景及噪声,全局阈值分割会导致图像的过分割或欠 分割。而局部阈值分割法能够对图像局部的信息进 行判断,具有更优异的分割效果。另一方面,需要精 确地提取设备红外特征参数作为分类器输入量,并 为分类器配置最优参数。针对这些问题,林颖等 人<sup>[3]</sup>采用通过超像素分割提取图像灰度作为分类 器输入特征,提出了基于卷积递归网络的电流互感 器红外故障图像诊断方法,初步解决了海量红外故 障图像特征提取与故障自动分类问题。邹辉等 人<sup>[4]</sup>采用图像全局温度作为输入特征,提出了支持 向量机(SVM)的红外故障图像诊断方法,并引入了 混沌序列由粗到细地优化 SVM 分类器参数。尽管 上述工作基本实现了设备故障的分类,但却忽略了 设备的温升与故障之间的关联性,考虑到设备热缺 陷损耗功率越大,温升越高,设备故障的严重程度越 高<sup>[5-6]</sup>,在故障分析诊断中有必要将温升参量考虑 进来,并将其作为分类器的输入特征,由此将产生分 类器参数优化问题。

针对上述问题,本文将粒子群优化算法 (PSO)<sup>[7]</sup>与Niblack<sup>[8]</sup>局部阈值分割算法相结合,对 批量图像进行二值化处理,提取出设备温度场区域。 将设备温升值作为输入特征量,利用改进蝙蝠算法 (BA\*)优化 SVM 分类器,对电力设备的故障进行 分类和分析。结果表明:选用温升特征量的 BA\*-SVM 模型,能够实现电力设备红外热图像的批量分 析和处理,并且本文方法的分类准确率和效率较 PSO-SVM、GA-SVM 等算法更高。

### 2 红外图像特征提取及 SVM 参数配置

电力设备红外故障图像诊断系统性能很大程度 上取决于图像特征参数的提取以及 SVM 参数的配 置,是红外热成像诊断的关键环节。一般而言,电力 设备故障程度与温升参数密切相关。为准确提取设 备温升特征,如设备的最高温升 x<sub>1</sub>、最低温升 x<sub>2</sub>、平 均温升 x<sub>3</sub>,需要降低非均匀辐射背景及噪声对温度 参数提取的影响。

2.1 基于 PSO-Niblack 的特征参数提取 电力设备红外图像诊断过程中,由于红外热像 图的二维特性,以及设备间的相互交叉与重叠,复杂 背景下设备的分割与识别是较为困难的。另一方 面,非均匀背景对设备的分割也将造成干扰,并严重 影响特征的提取,本文重点解决非均匀背景下批量 设备红外图像的分割问题。为此,本文引入 Niblack 算法,首先采用权重法将设备红外图像进行灰度化 处理,将单幅图像均匀分成 n 个不重叠矩形邻域,以 便每个矩形背景光照都近似均匀的,再按照每个邻 域灰度均值 m 和标准方差 s 以及阈值公式  $X = m + k \times s$  计算该域的灰度分割阈值。为获得较好的图像 分割质量,k 在[-1,1]范围以 0.05 等步长取值,由 此可构建 n 维阈值寻优空间 X,即:

$$X = \begin{bmatrix} X_{1,1} & X_{1,2} & X_{1,3} & \cdots & N \oplus \\ X_{2,1} & X_{2,2} & X_{2,3} & \cdots & X_{2,n} \\ X_{3,1} & X_{3,2} & X_{3,3} & \cdots & X_{3,n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ X_{41,1} & X_{41,2} & X_{41,3} & \cdots & X_{41,n} \end{bmatrix}$$
(1)

以类间方差为适应度函数,采用粒子群算法可 在寻优空间 *X* 上搜寻出各域的最优分割阈值:  $\{X_1^*, X_2^*, \dots, X_n^*\} = \max_{1 \le i \le n} \{\sigma_1^2(X_i); \sigma_2^2(X_i); \dots; \sigma_n^2(X_i)\}$ 

(2)

采用最优分割阈值对相应邻域进行二值化处 理,并计算 ROI 最高灰度值  $g_1$ 、最低灰度值  $g_2$ 、平均 灰度值  $g_3$ ,以及背景区域灰度均值  $g_4$ 。由于红外图 像中存在的大量椒盐噪声和细长的条纹噪声斑点面 积较小,本文采用5×5均值模板计算  $g_1$ 、 $g_2$ ,以消除 噪声干扰的影响。再通过文献[4] 灰度值与实际温 度线性映射公式即可得到 ROI 最高、最低和平均温 度值  $T_1$ 、 $T_2$ 、 $T_3$ ,以及背景温度均值  $T_4$ ,线性映射公 式为:

$$T_{i} = \frac{T_{\text{max}} - T_{\text{min}}}{L} g_{i} + T_{\text{min}}, i = 1 \sim 4$$
 (3)

其中,L为图像最高灰度值; $T_{min} \sim T_{max}$ 为红外热像 仪设置的测温范围。

利用  $x_1 = T_1 - T_4, x_2 = T_2 - T_4, x_3 = T_3 - T_4$  计 算温升参数,并通过每幅红外图像提取的 $\{x_1, x_2, x_3\} \in \mathbb{R}^3$  特征参量批量构建图像的样本特征空间, 如公式(4) 所示,标签项  $y_i \in \{0,1,2,3\}$  依次代表 正常、一般、严重和危急四种故障类型,其中 i = 1, 2,…,N,N 为样本量。

$$S = \begin{bmatrix} x_{1} & x_{2} & x_{3} & y \\ x_{1,1} & x_{1,2} & x_{1,3} & y_{1} \\ x_{2,1} & x_{2,2} & x_{2,3} & y_{2} \\ \vdots & \vdots & \vdots & \vdots \\ x_{N,1} & x_{N,2} & x_{N,3} & y_{N} \end{bmatrix}$$
(4)

#### 2.2 SVM 多故障分类模型

为解决上述提取的故障样本自动分类问题,引 入映射函数 $\phi(x)$ 将 $R^3$ 映射至高维空间H,在其中 寻找4×(4-1)/2=6个决策超平面,使四类故障 特征数据的分类间隔最大。由于每个超平面可区分 2类故障类型,故对任意2类故障类型,需解决以下 问题:

$$\begin{cases} \max Q(\alpha) = \sum_{i=1}^{n} \alpha_{i} - \frac{1}{2} \sum_{i=1}^{n} \alpha_{i} \alpha_{j} y_{i} y_{j} K(x_{i}, x_{j}) \\ \text{s. t. } \sum_{i=1}^{n} y_{i} \alpha_{i} = 0 , 0 \leq \alpha_{i} \leq C , i = 1, 2, \cdots, N \end{cases}$$

$$(5)$$

其中,超平面表示为 $x_i \cdot \sum_{i=1}^n a_i y_i x_i + d = 0; d$ 为偏置;  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)$ 为拉格朗日乘子; C 为惩罚参 数。选用 RBF 核函数  $K(x_i, x_j) = \exp(-g) ||x_i - x_j||^2)$ 解决有限样本线性分割问题<sup>[9-10]</sup>,式中,g 为 核参数。结合交叉验证法与改进响度因子的蝙蝠算 法获取 C、g 的最优值。

采用投票的方式统计故障样本点的每种故障得 票数,分类决策函数为:

$$f(x) = \operatorname{sgn} \{ \sum_{i=1}^{n} \alpha_{i} y_{i} K(x_{i}, x_{j}) + d \}$$
(6)

当6个决策函数都做出判断,即可得到故障样 本点每类故障总票数,根据票数判断样本点故障 类型。

2.3 基于 BA\* 的 SVM 参数配置

SVM 中  $C_{g}$  参数选取对分类精度影响较大,如 图 1 所示,为达到最高分类精度,本文引入了 K – 折 交叉验证<sup>[11]</sup>与改进响度因子的蝙蝠算法(BA\*)获 取  $C_{g}$  值。

K -折交叉验证中,将矩阵(4)中训练样本集分成大小大致相同的K组子集,每组子集数据做一次验证集,其余的(K - 1)组子集作为训练集,将上述过程重复K次。定义Ac为BA\*算法的适应度函数:

$$\begin{cases} Ac = \frac{1}{K} \sum_{i=1}^{K} |e_i| \times 100\% \\ e = \frac{a_i}{a_i + a_j} \end{cases}$$
(7)

其中,*a<sub>i</sub>、a<sub>f</sub>*分别为正确和错误分类数目;*e*为验证集 分类准确率。



图 1 SVM 参数对其分类精度的影响

Fig. 1 Effect of SVM parameters on classification accuracy

蝙蝠算法中搜索空间维度根据寻优参数个数可 得为2,*t*时刻,蝙蝠的搜索频率 $f_i$ 、速度 $v_i$ <sup>'</sup>和位置 $p_i$ <sup>'</sup> 表示为:

$$\begin{cases} f_i = f_{\min} + (f_{\max} - f_{\min})\beta \\ v_i^t = v_i^{t-1} + (p_i^{t-1} - p^*)f_i \\ p_i^t = p_i^{t-1} + v_i^t \end{cases}$$
(8)

式中,*f*<sub>min</sub>*f*<sub>max</sub>分别为最小和最大搜索频率;β为[0, 1]范围内随机变量;p<sup>\*</sup>为当前全局最优值。在局部 搜索过程中,如果从最优集集合中选中了一个解,则 该蝙蝠的位置更新为:

$$p_{new} = p_{old} + \varepsilon A^t \tag{9}$$

其中, $\varepsilon$  为[-1,1]范围内随机数;A'为所有蝙蝠 t 时刻的平均响度,通过引入脉冲响度因子  $\xi$  更 新 A',增强本算法的最优解搜寻能力。响度因子 按照 Logistic 函数模型更新。全局搜索和局部寻 优之间的平衡通过改变响度 A 和脉冲发生率  $r_i$ 来 实现:

$$\begin{cases} A_{i}^{t+1} = \xi A_{i}^{t} \\ \xi = 1 - \frac{1}{1 + e^{\lambda(1 - 2t/t_{max})}} \\ r_{i}^{t+1} = r_{i}^{0} [1 - \exp(-\theta t)] \end{cases}$$
(10)

其中, $t_{max}$ 为最大迭代次数; $\lambda$ 为梯度系数,用于控制 响度因子 $\xi$ 的下降速度。图2给出了不同 $\lambda$ 下的响 度因子递减曲线,图中箭头方向为 $\lambda$ 递减方向,— 般取 $\lambda = 6$ 即可满足实验。





采用上述改进脉冲响度因子的蝙蝠算法优化

SVM 参数,使用优化后的分类模型对提取的测试样本进行测试实验。

# 3 实验结果与分析

3.1 PSO-Niblack 算法分割性能分析

本文以如图 3 中电力设备的红外图像为例,对 ROI 区域进行分割,从上至下分别对应刀闸引线接 头、刀闸和阻波器,图像像素尺寸均为 320 × 240。 邻域窗口大小设置为 90 × 80。粒子群算法中,解空 间维度 *n* = 12,加速常数 *c*<sub>1</sub> = *c*<sub>2</sub> = 2,粒子数量设为 10,最大迭代次数为 25。



图 3 红外图像 ROI 及背景提取

Fig. 3 ROI and background extraction of infrared images

图 3 中二值化图像从左至右分别为 Otsu、Niblack、Kapur、PSO-Otsu 和本文方法的分割结果,由 图可知本文算法能够较好地将 ROI 从红外图像中 提取出来,分割效果明显优于前三种分割方法。采 用误分率(Misclassification Rate, ME)为指标,将 PSO-Niblack 算法与四种传统分割算法分割效果进 行对比,如表 1 所示。表中耗时单位为毫秒(ms), 由表可得:相比传统分割法,PSO-Niblack 算法在误 分率和耗时(平均 22 ms)方面均维持在较低水平, 分割效果也优于其他方法,从而验证了 PSO-Niblack 算法的实用性,并为准确提取各区域温升特征奠定 了基础。

# 表1 各分割算法的 ME 值和耗时对比

Tab. 1 Comparison of ME value and time-consuming

of different algorithms

设备图像	Otsu	Niblack	Kapur	PSO + Otsu	本文算法
图 3(a)	0.188/0.8	0.138/17.3	0.206/80.4	0.013/80.1	0.007/23.1
图 3(b)	0.01//0.7	0.136/17.4	0.037/75.2	0.01/83.9	0.008/21.1
图 3(c)	0.038/0.7	0.020/16.8	0.064/74.2	0.019/82.4	0.009/21.8

#### 3.2 样本特征提取

按照上述方法对 220 张红外图像的 ROI 区域 进行分割,提取 ROI 温度场信息,实验中设置红外 热像仪温度探测范围为 10~150 °C。采用 5×5 模 板并计算 ROI 的最高和最低温度值  $T_1$  和  $T_2$  以及 ROI 与背景区域温度均值  $T_3$ 和  $T_4$ ,由此计算每张设 备图像对应的温升数据  $x_1$ 、 $x_2$ 、 $x_3$ ,以此作为样本特 征,表 2 给出了部分红外图像特征提取结果。

表2 部分特征提取结果

Tab. 2 Partial results of feature extraction

设备图像	$T_1$	$T_2$	<i>T</i> <sub>3</sub>	$T_4$	<i>x</i> <sub>1</sub>	<i>x</i> <sub>2</sub>	<i>x</i> <sub>3</sub>
1	125.2	78.2	91.9	29.4	95.8	48.8	62.5
2	94.3	45.6	74.4	26.0	68.3	19.6	48.4
3	93.5	42.3	73.1	23.1	70.4	19.2	50.0
4	93.5	42.3	73.1	23.1	70.4	19.2	50.0
:	:	:	:	:	:	:	:
219	53.7	34.2	41.3	26.0	27.7	8.2	15.3
220	51.3	31.5	40.5	26.0	25.3	5.5	14.5

将表 2 中前 140 组特征数据作为训练样本,包括 32 组正常状态样本、36 组一般故障状态样本、31 组严重故障状态样本、41 组危急故障状态样本。将剩余的 80 组数据作为测试样本,包括 17 组正常状态样本、19 组一般故障状态样本、24 组严重故障状态样本、20 组危急故障状态样本。

3.3 SVM 参数优化

为评价 BA\*-SVM 算法的参数优化的性能,分 别与 BA-SVM<sup>[12]</sup>、GA-SVM<sup>[13]</sup>、PSO-SVM<sup>[14]</sup>三种常 见的算法进行对比。由于这四种算法皆为概率搜索 算法,参数均设置为:种群数量 20,最大迭代次数 50,SVM 参数 *C* 范围[10<sup>-2</sup>,10<sup>3</sup>],参数 *g* 范围 [10<sup>-2</sup>,10<sup>3</sup>],交叉验证中 *K* = 10。尽管四种算法参 数设置相同,但是由于每种算法种群的寻优策略不 同,达到最优解的迭代过程也都不相同。

为便于观察,对四种算法的种群平均适应度进行了统计比较,如图 4 所示。在相同参数和温升样本下,BA\*-SVM 算法在搜寻最优解时,平均适应度 波动较小,且收敛的适应度值为 99.0991%,为四种 算法中最高,最优解搜索能力更强。这是由于本文 方法引入 Logistic 函数更新脉冲响度因子,使算法后 期搜索中局部最优值的搜索更为精细,因此提高了 收敛精度。

在收敛速度方面,BA\*-SVM 算法在15次迭代 后即收敛,而传统 BA-SVM 算法则需要25次迭代 才能开始收敛,这说明本文方法比传统 BA-SVM 算法收敛速度更快。这可归因为引入的 Logistic 响度因子更新函数在算法搜索前期降幅较小,使 得群体能很快进入局部搜寻。因此,BA\*-SVM 算 法在最优解搜寻能力和收敛速度方面表现均为 最优。



Fig. 4 Four algorithms with the change of fitness

3.4 诊断结果与分析

利用提取的 220 组温升样本测试 BA\*-SVM 分类性能,将该算法的分类结果与 BA-SVM、GS-SVM<sup>[15]</sup>、PSO-SVM 和 GA-SVM 等四种传统算法分 类结果进行对比。选择前 140 组样本作为训练样 本,剩下的样本作为测试样本,实验结果如表 3 所 示。由表可得,本文提出的 BA\*-SVM 算法的分类 精度远高于 GA-SVM 与 GS-SVM 算法,略高于传统 BA-SVM 算法。测试分类准确率方面达到了 97.5%,高于未经优化的 BA-SVM 算法,且明显优 于其他三种故障诊断算法。因此,本文提出的 BA\*算法能较好地优化分类器参数,提升分类器 性能,在电力设备故障诊断领域具有良好的应用 前景。 表3 算法优化参数选取及分类准确率

Tab. 3 Classification accuracies and optimal

parameters of the classifiers

算法名称	С	g	训练分类 精度/%	测试分类 准确率/%
GA-SVM	31.2695	4.6930	92.8571	91.25(73/80)
GS-SVM	32.0000	2.8000	94.2857	93.75(75/80)
PSO-SVM	44.9122	2.3141	95.7143	88.75(71/80)
BA-SVM	67.8867	6.8950	87.1429	95.00(76/80)
BA*-SVM	63.9462	1.6273	99.0991	97.50(78/80)

鉴于样本特征参数的选取对分类器分类准确率 影响较大,本文分别选取 { $T_1$ , $T_2$ , $T_3$ , $T_4$ }、{ $x_1$ , $x_2$ ,  $x_3$ }和{ $T_1$ , $T_2$ , $T_3$ , $T_4$ , $x_1$ , $x_2$ , $x_3$ }和{ $T_1$ , $T_2$ , $T_3$ , $T_4$ , $x_1$ , $x_2$ , $x_3$ }作为样本特征参数, 测试了 BA\*-SVM 算法在三种样本集下的分类准确 率,结果如表 4 所示。

表4 不同特征对算法诊断结果的影响

Tab. 4 The influence of different characteristics on the diagnosis results of the proposed algorithm

特征选取	温度特征	温升特征	温升 + 温度特征
则试准确率/%	92.50% (74/80)	97.50% (78/80)	87.50% (70/80)

由表4可得,当选取温升作为 BA \*-SVM 分类 器输入特征时,算法的故障诊断准确率更高。

### 4 结 论

本文通过 PSO-Niblack 算法精确地提取出了电 力设备红外图像特征,结合交叉验证和改进蝙蝠算 法(BA\*)对 SVM 进行参数优化。利用基于 PSO-Niblack 及 BA\*-SVM 电力设备故障红外图像自动诊 断系统对 220 组红外图像进行仿真对比实验,得出 以下结论:

(1) 对特征提取性能,本文对电力设备红外图 像进行仿真实验,提出的 PSO-Niblack 算法平均误 分率达 8.2×10<sup>-3</sup>,平均耗时为 22 ms,为特征的精 确提取奠定良好基础。

(2)对 SVM 参数优化,经 BA\*算法参数优化后的分类器的故障分类精度更高,收敛速度比传统 BA 算法更快。

(3)对样本分类精度,本文提出的 BA\*-SVM 算法分类精度达 99.0991%。分别高于 GA-SVM 的 92.8571%、GS-SVM 的 94.2857%、PSO-SVM 的 95.7143% 和传统 BA-SVM 的 97.1429%。

(4) 对样本测试准确率, 本文提出的 BA\*-SVM

综合考虑,本文提出的 PSO-Niblack 及 BA\*-SVM 电力设备故障红外图像自动诊断方法,在特征 提取和故障诊断方面均具有较高精度。这一优势使 其适用于电力大数据中非结构化红外图像的批量化 分析与自动处理,因此具有较好的实际应用价值。

## 参考文献:

- [1] YU Ping, CUI Shaofei, GE Yongxin, et al. A new method for electrical equipment visual and infrared image registration based on alignment metric [J]. Laser & Infrared, 2008,38(7):737-740. (in Chinese) 余萍,崔少飞,葛永新,等. 基于对齐度的电力设备红 外与可见光的图像配准[J]. 激光与红外,2008,38 (7):737-740.
- [2] LI Mengxing. Research and implementation of power equipment fault infrared diagnosis system [J]. Electric Power IT,2013,11(2):36-39. (in Chinese)
  李孟兴. 电力设备故障红外诊断系统的研究与实现 [J]. 电力信息化,2013,11(2):36-39.
- [3] LIN Ying, GUO Zhihong, CHEN Yufeng. Convolutional-recursive network based current transformer infrared fault image diagnosis [J]. Power System Protection and Control, 2015, 43(16):87 94. (in Chinese)
  林颖,郭志红,陈玉峰. 基于卷积递归网络的电流互感器红外故障图像诊断[J]. 电力系统保护与控制, 2015, 43(16):87 94.
- [4] ZOU Hui, HUANG Fuzhen. A novel intelligent fault diagnosis method for electrical equipment using infrared thermography[J]. Infrared Physics & Technology, 2015, 73, 29-35.
- [5] LANG Cheng, JIN Guangxi, XU Dan, et al. Analysis of influence factors on relative temperature difference judgement method of electrical equipments [J]. Infrared and Laser Engineering, 2011, 40 (1): 28 - 31, 40. (in Chinese)

郎成,金光熙,徐丹,等. 电气设备相对温差判断法的 影响因素分析[J]. 红外与激光工程,2011,40(1): 28-31,40.

- [6] JIN Lijun, AI Jianyong, DUAN Wei. Health condition assessment of catenary insulation based on multisource images[J]. High Voltage Engineering, 2016, 42(11):3515 3523. (in Chinese)
  金立军,艾建勇,段伟. 基于多光源图像的接触网外绝缘健康状态评估[J]. 高电压技术, 2016, 42(11): 3515 3523.
- [7] WANG Ju, WANG Zhaohui, LIU Yin. Fast algorithm of sparse signal decomposition based on PSO and LM[J].

Laser & Infrared, 2012, 42(2):227-230. (in Chinese) 王菊,王朝晖,刘银. 基于 PSO 和 LM 的信号稀疏分解 快速算法[J]. 激光与红外, 2012, 42(2):227-230.

- [8] Niblack W. An introduction to digital image processing [M]. Denmark: Strand berg Publishing Company Birkeroed, 1986, 115 – 116.
- [9] YUAN Zhiwei, HUANG Shucai, XIONG Zhigang, et al. Infrared small target detection based on SVM posterior probability[J]. Laser & Infrared, 2016, 46(6): 766 – 771. (in Chinese)
  苑智玮,黄树彩,熊志刚,等. 基于 SVM 后验概率的红 外弱小目标检测[J]. 激光与红外, 2016, 46(6): 766 – 771.
- [10] HU Yanyan, LI Dongsheng, ZHANG Shigui. Classification of hyperspectral image by convex combination kernels function SVM[J]. Laser & Infrared, 2016, 46(5):627 633. (in Chinese) 胡燕燕,李东生,张诗桂. 凸组合核函数的支持向量机 高光谱图像分类[J]. 激光与红外, 2016, 46(5): 627 633.
- [11] ZHANG Yan, WU Ling. Transformer fault diagnosis based on C - SVC and cross-validation algorithm [J]. Electric Power, 2012, 45(11):52 - 55. (in Chinese) 张艳, 吴玲. 基于支持向量机和交叉验证的变压器故 障诊断[J]. 中国电力, 2012, 45(11):52 - 55.
- [12] CHEN Yuanyuan, WANG Zhibin, WANG Zhaoba. Feature selection ofInfrared spectrum based on improved bat algorithm[J]. Infrared and Laser Engineering, 2014, 43(8): 2715 2721. (in Chinese)
  陈媛媛, 王志斌, 王召巴. 基于改进蝙蝠算法的红外光 谱特征选择[J]. 红外与激光工程, 2014, 43(8): 2715 2721.
- [13] CHEN Shijie, LIAN Ke, WANG Houjun. Method for analog circuit fault diagnosis based on GA optimized SVM [J]. Journal of University of Electronic Science and Technology of China, 2009, 38(4):553 - 558. (in Chinese) 陈世杰,连可,王厚军. 遗传算法优化的 SVM 模拟电路 故障诊断方法[J]. 电子科技大学学报, 2009, 38(4): 553 - 558.
- [14] GUO Tiantai, HONG Bo, PAN Zengrong, et al. Application of improved SVM in quantitative analysis of mine gas concentration[J]. Infrared and Laser Engineering, 2016, 45 (6):211-218. (in Chinese)
  郭天太,洪博,潘增荣,等.改进的 SVM 在矿井气体定量分析中的应用[J]. 红外与激光工程,2016,45(6):211-218.
- [15] UAN Chongwen, CHENG Lizhi. Sample set shrinking strategy efficiently improving parameters seeking of support vector machines[J]. Computer Applications, 2007, 27 (2):363-365. (in Chinese) 段崇雯,成礼智.有效提高 SVM 参数搜索效率的样本 集缩减策略[J]. 计算机应用, 2007, 27(2):363-365.