

# 改进引力搜索算法优化的 SVM 模拟电路故障诊断

梅恒荣, 刘冬梅, 何怡刚, 殷礼胜, 赵丽欣, 赵蓓蕾  
(合肥工业大学 电气与自动化工程学院, 安徽 合肥 230009)

**摘 要:** 文本在引力搜索算法(GSA)的基础上,通过引入粒子群算法中的惯性权重和全局记忆性、时变引力搜索策略和边界变异策略,提出一种改进引力搜索算法(IGSA)来优化 SVM 参数(IGSA-SVM)的改进型分类器. 首先选取三个 UCI 数据集进行仿真分析,结果表明 IGSA-SVM 分类器在分类准确率和分类时间上优于 GS-SVM、GA-SVM、PSO-SVM 和 GSA-SVM 分类器. 然后分别采用线性和非线性模拟电路来进行故障诊断,结果表明 IGSA-SVM 分类器能有效地防止局部收敛并提高了诊断的优化效率.

**关键词:** 支持向量机;改进引力搜索算法;模拟电路;故障诊断

中图分类号: TP277

文献标识码: A

文章编号: 1000—7180(2018)05—0109—07

## Analogue Circuit Fault Diagnosis Based on SVM Optimized by IGSA

MEI Heng-rong, LIU Dong-mei, HE Yi-gang, YIN Li-sheng,  
ZHAO Li-xin, ZHAO Bei-lei

(School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

**Abstract:** This paper proposes a modified classifier that uses the improved gravity search algorithm (IGSA) to optimize the parameter of SVM (IGSA-SVM) by introducing the inertia weight and global memory in particle swarm algorithm, time-varying gravitational search strategy and boundary mutation strategy. At first, three UCI datasets are selected for simulation analysis, and the results show that IGSA-SVM classifier is better than GS-SVM, GA-SVM, PSO-SVM and GSA-SVM classifiers in classification accuracy and classification time. Then the linear and nonlinear analog circuits are used as fault diagnosis circuits respectively, and the results show that the IGSA-SVM classifier can effectively prevent local convergence and improve the efficiency of diagnosis.

**Key words:** support vector machine; improved gravitational search algorithm; analog circuit; fault diagnosis

### 1 引言

模拟电路是现代电子设备的重要组成部分,模拟电路的可靠性影响整个电子系统的可靠性<sup>[1]</sup>. 模拟电路存在可测节点少、电路信息冗余度高、容差性、非线性以及故障多样性等问题,这使得模拟电路故障诊断发展缓慢<sup>[2]</sup>. 近年来,随着人工智能技术被引入模拟电路故障诊断领域,其中应用最多的是神经网络(NNs)<sup>[3]</sup>和支持向量机(SVM)<sup>[4-5]</sup>.

目前,对 SVM 的惩罚参数 C 和核参数 g 进行

优化时,可能出现陷入局部收敛的问题<sup>[6-8]</sup>. 为此,很有必要去寻找一种新的优化 SVM 参数的方法,引力搜索算法(GSA)是一种基于牛顿万有引力定律和牛顿第二定律的智能优化算法<sup>[9]</sup>.

对此,本文提出了一种改进引力搜索算法(IGSA)来优化 SVM 参数(IGSA-SVM)的改进型分类器.

### 2 基于 IGSA 的支持向量机参数优化

#### 2.1 支持向量机原理

SVM 是建立在统计学习理论——VC 维理论

收稿日期: 2017—07—19; 修回日期: 2017—08—26

基金项目: 国家自然科学基金(51577046, 11105037); 国家自然科学基金重点项目(51637004); 安徽省科技计划重点项目(1301022036)

和结构风险最小化原理基础上的一种机器学习理论<sup>[10]</sup>. 首先通过核函数的非线性变换将输入空间变换到一个高维特征空间, 使之线性可分, 然后在这个特征空间中求如图 1 所示最优分类超平面.

图 1 中,  $H$  为最优分类超平面, 超平面  $H_1$  和  $H_2$  穿过距  $H$  最近的样本点且与  $H$  平行,  $H_1$  和  $H_2$  之间的距离  $\frac{2}{\|\omega\|}$  称为分类间隔, 所谓最优分类超平面就是要求在分类间隔尽可能大的条件下能够准确区分样本, 即使得  $\|\omega\|$  尽可能小.




图 1 SVM 的最优分类超平面

设图 1 中样本集为  $T = \{(x_i, y_i) \mid i = 1, 2, \dots, N\}$ , 其中  $x_i \in R^d, y_i \in \{+1, -1\}$ , 通过非线性映射得到最优分类超平面  $(\omega \cdot x) + b = 0$ , 求解最优分类超平面可以转化为求解下列优化问题:

$$\begin{aligned} \min \Phi(\omega) &= \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N \xi_i \\ \text{s. t. } y \cdot (\omega \cdot x + b) &\geq 1 - \xi_i, i = 1, 2, \dots, N \end{aligned} \quad (1)$$

式中,  $\omega$  为超平面的法向量;  $b$  为偏差;  $C$  为惩罚参数, 实现对错分样本数和分类间隔之间的折中, 是影响 SVM 分类性能的重要参数;  $\xi_i$  为松弛变量, 近似表示被误分类的样本数. 为求解此凸二次规划问题, 引入 Lagrange 函数, 利用对偶原理把原优化问题转化为:

$$\begin{aligned} \max W(\alpha) &= \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j K(x_i, x_j) \\ \text{s. t. } \sum_{i=1}^N \alpha_i y_i &= 0, 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N \end{aligned} \quad (2)$$

式中,  $\alpha_i$  为 Lagrange 乘子;  $K(x_i, x_j)$  为核函数; 本文采用高斯径向基核函数, 其函数表达式为:

$$K(x_i, x_j) = e^{-g \|x_i - x_j\|^2} \quad (3)$$

式中,  $g$  为核参数, 控制着高斯核的作用范围, 是影响 SVM 分类性能的另一个重要参数. 采用高斯径向基核函数可得到决策函数为:

$$f(x) = \text{sgn}\left(\sum_{i=1}^N \alpha_i y_i K(x_i, x) + b\right) \quad (4)$$

## 2.2 基本引力搜索算法

假设在一个  $n$  维的搜索空间中有  $N$  个粒子, 定义第  $i$  个粒子 ( $i = 1, 2, \dots, N$ ) 的位置为:

$$X_i = (x_i^1, x_i^2, \dots, x_i^d, \dots, x_i^n) \quad (5)$$

式中,  $x_i^d$  代表第  $i$  个粒子在第  $d$  维上的位置, 该算法粒子的初始位置是随机产生的. 在某  $t$  时刻, 根据牛顿万有引力定律, 粒子  $i$  和粒子  $j$  之间的万有引力大小为:

$$F_{ij}^d(t) = G(t) \frac{M_{pi}(t) \times M_{aj}(t)}{R_{ij}(t) + \epsilon} (x_j^d(t) - x_i^d(t)) \quad (6)$$

式中,  $M_{pi}(t)$  和  $M_{aj}(t)$  分别为被作用粒子  $i$  的惯性质量和作用粒子  $j$  的惯性质量;  $\epsilon$  是一个非常小的常量;  $G(t)$  是在  $t$  时刻的引力常数;  $R_{ij}(t)$  是粒子  $i$  与粒子  $j$  之间的欧式距离.

$$G(t) = G_0 e^{-\alpha T} \quad (7)$$

$$R_{ij}(t) = \|X_i(t), X_j(t)\|_2 \quad (8)$$

式中,  $G_0$  为 100;  $\alpha$  为 20;  $T$  是最大迭代次数.

惯性质量是按其适应值的大小来计算, 粒子的惯性质量越大, 就表示它越接近最优值. 在 GSA 算法中, 按式 (9) ~ (11) 更新粒子的惯性质量:

$$M_{ai} = M_{pi} = M_{ii} = M_i, i = 1, 2, \dots, N \quad (9)$$

$$m_i(t) = \frac{\text{fit}_i(t) - \text{worst}(t)}{\text{best}(t) - \text{worst}(t)} \quad (10)$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)} \quad (11)$$

式 (9) 中,  $M_{ii}(t)$  是粒子  $i$  的惯性质量; 式 (10) 中,  $\text{fit}_i(t)$  代表在  $t$  时刻第  $i$  个粒子的适应值大小. 对于求解最小值问题,  $\text{worst}(t)$  和  $\text{best}(t)$  的定义如下:

$$\text{best}(t) = \min_{j \in \{1, 2, \dots, N\}} \text{fit}_j(t) \quad (12)$$

$$\text{worst}(t) = \max_{j \in \{1, 2, \dots, N\}} \text{fit}_j(t) \quad (13)$$

对于求解最大值问题,  $\text{worst}(t)$  和  $\text{best}(t)$  的定义如下:

$$\text{best}(t) = \max_{j \in \{1, 2, \dots, N\}} \text{fit}_j(t) \quad (14)$$

$$\text{worst}(t) = \min_{j \in \{1, 2, \dots, N\}} \text{fit}_j(t) \quad (15)$$

在引力搜索算法中, 为了增加算法的随机特性, 在作用力  $F_{ij}^d(t)$  前面加上随机函数  $\text{rand}_j$ , 假设第  $i$  个粒子  $d$  维上的作用力是其他所有粒子作用力的总

和,根据牛顿第二定律,那么粒子的加速度为:

$$a_i^d(t) = \frac{\sum_{j=1, j \neq i}^N \text{rand}_j F_{ij}^d(t)}{M_{ii}(t)} \quad (16)$$

最后,对于每一次的迭代过程,粒子  $i$  都以式(17)和(18)更新它的速度和位置:

$$v_i^d(t+1) = \text{rand}_i \times v_i^d(t) + a_i^d(t) \quad (17)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (18)$$

式(17)中,  $\text{rand}_i$  是  $[0,1]$  之间的随机数.

### 2.3 改进的引力搜索算法

采用 SVM 进行故障分类时,高斯核函数中的惩罚参数  $C$  和核参数  $g$  的选择不同对分类准确率造成很大影响,为了避免引力搜索算法优化支持向量机参数时陷入局部最优的情况,通过引入粒子群算法中的惯性权重和全局记忆性、时变引力搜索策略和边界变异策略,构成本文的改进引力搜索算法(IGSA),具体如下.

(1)引入粒子群算法中的惯性权重和全局记忆性.由于 GSA 更新粒子时,只考虑到粒子当前位置的影响,而未将粒子的记忆性纳入考虑范围,为此,本文引入粒子群算法中全局记忆功能;为了平衡种群的勘探和开采能力,引入如式(19)所示的线性减小线性的惯性权重,在搜索初期,  $\omega$  取较大值,可以增强全局搜索能力,到了搜索后期,  $\omega$  取较小值,局部开采能力得到增强,有利于找到最优解.

$$\omega(t) = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{T} \times t \quad (19)$$

$$\begin{aligned} v_i^d(t+1) &= \text{rand}_{1i} \times \omega(t) \times v_i^d(t) + \\ &c_1 \times \text{rand}_{2i} \times a_i^d(t) + c_2 \times \text{rand}_{3i} \times \\ &(g_{\text{best}}^d - x_i^d(t)) \end{aligned} \quad (20)$$

式(19)和(20)中,  $\omega_{\max}$  和  $\omega_{\min}$  分别是最大和最小的惯性权重;  $T$  是最大迭代次数;  $t$  是当前迭代次数;  $\text{rand}_{1i}, \text{rand}_{2i}, \text{rand}_{3i}$  是  $[0,1]$  之间的随机数;  $g_{\text{best}}^d$  是经历过全局最优粒子的位置;  $c_1$  和  $c_2$  为学习因子.

(2)引入时变引力搜索策略.为了避免算法陷入局部最优,提高优化效率,随着迭代次数的增加,算法的勘探能力应该逐渐减弱,开采能力应该不断增强,将式(16)调整为式(21).

$$a_i^d(t) = \frac{\sum_{j \in k_{\text{best}}, j \neq i}^N \text{rand}_j F_{ij}^d(t)}{M_{ii}(t)} \quad (21)$$

式中,  $\text{rand}_j$  是  $[0,1]$  之间的随机数;  $k_{\text{best}}(t)$  表示在第  $t$  次迭代时,一组质量较大粒子的数量,是一个随迭代次数增加而减少的线性函数.这里将  $k_{\text{best}}(t)$  的

初始值设置为群体数量  $N$ ,随着迭代次数的增加,  $k_{\text{best}}(t)$  线性减小,最后  $k_{\text{best}}(t)$  的值线性减小为 1,即最终只有一个质量最大的个体作用于其他个体,这样可以减小计算量,缩短分类时间,提高诊断效率.

(3)边界变异策略.在 GSA 迭代的过程中,粒子在万有引力定律和牛顿第二定律的作用下若其位置超过设定范围  $[x_{\min}, x_{\max}]$  之外,标准的 GSA 会强制粒子回到边界处,若粒子过多地聚集到可行域的边界上,这不利于 GSA 收敛.为提高 GSA 算法的收敛性,引入边界变异策略,具体如下:

若  $x_i < x_{\min}$  或  $x_i > x_{\max}$

$$\text{则 } x_i = \text{rand} \times (x_{\max} - x_{\min}) + x_{\min} \quad (22)$$

经过边界变异后,粒子不在聚集在边界上,增加了种群的多样性,有利于算法更快地找到最优解.

采用经过上述三个方面改进后的 IGSA 来优化 SVM 参数,以确保其获得良好的分类效果. IGSA 的具体流程图如图 2 所示,具体步骤如下.

步骤 1:参数初始化.设置种群大小  $N$ ,  $N$  个粒子的位置  $x_i^d$  和速度  $v_i^d$ ,迭代次数为  $T$ ,学习因子  $c_1$  和  $c_2$ ,惯性权重的最大值  $\omega_{\max}$  和最小值  $\omega_{\min}$ ,参数  $C$  和  $g$  的取值范围.

步骤 2:计算粒子的适应值,找出粒子的最优解  $F_{\text{best}}$  和最优粒子的位置  $g_{\text{best}}^d$ .

步骤 3:按式(7)更新引力常数  $G(t)$ ,按式(8)计算粒子间的欧式距离  $R_{ij}(t)$ ,按式(9)~(13)更新粒子的惯性质量  $M_i(t)$ .

步骤 4:按式(6)计算粒子各个方向上力的总和  $F_{ij}^d(t)$ ,式(21)计算粒子加速度  $a_i^d(t)$ .

步骤 5:按式(18)~(20)更新粒子的速度和位置.

步骤 6:按式(22)判断是否满足边界条件.

步骤 7:返回到步骤 2 循环迭代,直到达到最大迭代次数或精度要求.

步骤 8:结束循环,输出结果.

### 3 IGSA-SVM 在 UCI 数据集上的算法验证

为了验证 IGSA-SVM 分类器的分类效果,从 UCI 公共数据集中选取 3 组数据集 Iris、Wine 和 Seeds 作为仿真样本.其中 Iris 数据集是模式识别文献中应用最多的数据集,分为 3 类,每一类对应鸢尾花的一种,其中一类与另外两类都线性可分,而另外两类并不线性可分;Wine 数据集是对意大利同一地区的三个不同品种的葡萄酒化学分析的结果,三类样本共 178 个;Seeds 数据集是对三种不同小麦

进行比较的结果. 各个数据集样本划分情况见表 1.




图 2 IGSA 算法优化 SVM 参数的流程图

为了凸显 IGSA-SVM 的分类性能,采用与 GS-SVM、GA-SVM、PSO-SVM 及 GSA-SVM 分类器相比较的方法. 各个分类器算法的参数设置见表 2,

表 2 五种分类器的初始参数设置

| 分类器类型    | 种群大小 | 进化代数 | 参数 C 范围      | 参数 g 范围     | $P_c$ | $P_m$ | $c_1$ | $c_2$ | $v$ | C step size | g step size |
|----------|------|------|--------------|-------------|-------|-------|-------|-------|-----|-------------|-------------|
| GS-SVM   | —    | —    | (0.01,1 000) | (0.001,100) | —     | —     | —     | —     | 3   | 0.05        | 0.05        |
| PSO-SVM  | 20   | 100  | (0.01,1 000) | (0.001,100) | —     | —     | 1.5   | 1.7   | 3   | —           | —           |
| GA-SVM   | 20   | 100  | (0.01,1 000) | (0.001,100) | 0.7   | 0.035 | —     | —     | 3   | —           | —           |
| GSA-SVM  | 20   | 100  | (0.01,1 000) | (0.001,100) | —     | —     | —     | —     | 3   | —           | —           |
| IGSA-SVM | 20   | 100  | (0.01,1 000) | (0.001,100) | —     | —     | 0.5   | 1.5   | 3   | —           | —           |

表 3 五种分类器对 Iris、Wine 和 Seeds 数据集的分类结果

| 分类器类型    | Iris     |        | Wine     |        | Seeds    |        |
|----------|----------|--------|----------|--------|----------|--------|
|          | 准确率/%    | 分类时间/s | 准确率/%    | 分类时间/s | 准确率/%    | 分类时间/s |
| GS-SVM   | 96.666 7 | 143.75 | 87.323 9 | 206.62 | 85.555 6 | 210.64 |
| PSO-SVM  | 96.666 7 | 4.01   | 87.323 9 | 5.84   | 85.555 6 | 4.23   |
| GA-SVM   | 96.666 7 | 3.71   | 87.323 9 | 5.49   | 86.666 7 | 3.98   |
| GSA-SVM  | 98.333 3 | 3.17   | 91.549 3 | 3.65   | 90       | 2.63   |
| IGSA-SVM | 98.333 3 | 2.25   | 92.957 7 | 3.19   | 90       | 2.31   |

4 IGSA-SVM 在模拟电路故障诊断中的应用

基于 IGSA-SVM 模拟电路故障诊断的主要流程步骤如图 3 所示. 采用四运放双二次高通滤波器

其中,“—”表示该分类器不存在的该参数, $P_c$  和  $P_m$  分别代表 GA-SVM 分类器中的交叉率和变异率; $c_1$  和  $c_2$  为 PSO-SVM 和 IGSA-SVM 分类器中的学习因子; $v$  表示交叉验证的次数, $C_{step}$  和  $g_{step}$  为 GS-SVM 分类器中参数 C 和 g 的步进大小.

表 1 各数据集样本划分情况

| 数据集   | 样本维度 | 总样本数     | 训练样本划分   | 测试样本划分   | 选取方式 |
|-------|------|----------|----------|----------|------|
| Iris  | 4    | 50/50/50 | 30/30/30 | 20/20/20 | 均匀随机 |
| Wine  | 13   | 59/71/48 | 35/43/29 | 24/28/19 | 随机   |
| Seeds | 7    | 70/70/70 | 40/40/40 | 30/30/30 | 均匀随机 |

从表 1 和表 3 中可知:对于不同样本总数和样本维度的三个数据集,IGSA-SVM 分类器在分类准确率和分类时间都优于 GS-SVM、PSO-SVM 和 GA-SVM 分类器. GSA-SVM 分类器在 Wine 数据集上陷入了局部收敛,虽然 IGSA-SVM 和 GSA-SVM 分类器在 Iris 和 seeds 数据集上分类准确率相同,都找到了全局最优解,但 IGSA-SVM 分类器引入时变引力搜索策略,减小了计算量,缩短分类时间,提高了分类的优化效率. IGSA-SVM 分类器跳出了其他分类器所陷入的局部收敛,且大大缩短了分类时间,可进一步应用于模拟电路故障诊断.

和非线性整流电路来验证 IGSA-SVM 的分类性能.

4.1 诊断电路故障设置

第一个 CUT 为四运放双二次高通滤波器的线性电路,在 OrCAD Capture CIS16.6 中对其进行仿




图 3 基于 IGSA-SVM 的模拟电路故障诊断流程图

真验证,具体电路如图 4 所示. 电路通过 Pspice 中的瞬态分析从“out”节点采集响应电压信号. 考虑电路中元件的容差范围,所有电阻的容差设为 5%,所有电容的容差设为 10%,当电路元件的参数高于或低于其标称值的 50%时,则电路发生故障.




图 4 四运放双二次高通滤波器电路

假定电路中电阻  $R_1 \sim R_4$  和电容  $C_1 \sim C_2$  发生故障,具体参数设置如表 4 所示,↑表示元件发生偏大故障,↓表示元件发生偏小故障. 给电路施加一个幅值为 5 V,周期为 0.5 ms 的脉冲作为激励信号,从“out”节点在 30  $\mu$ s 内采集 128 个数据点,每种故障类别都进行 80 次 Monte Carlo 分析,其中 50 个作为训练样本,30 个作为测试样本. 最后采用小波包分解将原始数据提取为 8 维特征向量.

表 4 四运放双二次高通滤波器的故障模式

| 故障代码 | 故障类别             | 标称值            | 容差/% | 故障值            |
|------|------------------|----------------|------|----------------|
| F0   | NF               | —              | —    | —              |
| F1   | $C_1 \uparrow$   | 5 nF           | 10   | 10 nF          |
| F2   | $C_1 \downarrow$ | 5 nF           | 10   | 2.5 nF         |
| F3   | $C_2 \uparrow$   | 5 nF           | 10   | 15 nF          |
| F4   | $C_2 \downarrow$ | 5 nF           | 10   | 2.5 nF         |
| F5   | $R_1 \uparrow$   | 6.2 k $\Omega$ | 5    | 15 k $\Omega$  |
| F6   | $R_1 \downarrow$ | 6.2 k $\Omega$ | 5    | 3 k $\Omega$   |
| F7   | $R_2 \uparrow$   | 6.2 k $\Omega$ | 5    | 18 k $\Omega$  |
| F8   | $R_2 \downarrow$ | 6.2 k $\Omega$ | 5    | 2 k $\Omega$   |
| F9   | $R_3 \uparrow$   | 6.2 k $\Omega$ | 5    | 12 k $\Omega$  |
| F10  | $R_3 \downarrow$ | 6.2 k $\Omega$ | 5    | 2.7 k $\Omega$ |
| F11  | $R_4 \uparrow$   | 1.6 k $\Omega$ | 5    | 2.5 k $\Omega$ |
| F12  | $R_4 \downarrow$ | 1.6 k $\Omega$ | 5    | 0.5 k $\Omega$ |

第二个 CUT 为非线性整流电路,用来验证 IG-

SA-SVM 分类器在非线性模拟电路中的优越性,具体电路如图 5 所示. 采用交流分析对电路进行故障诊断,扫描频率的起止范围是 1~100 Hz. 通过灵敏度分析,电路故障类别包括  $L_1 \downarrow, L_1 \uparrow, C_2 \downarrow, C_2 \uparrow, C_3 \downarrow, C_3 \uparrow$ ,具体参数设置见表 5,同样进行 80 次 Monte Carlo 分析和 8 维小波包特征提取,50 个作为训练样本,30 个作为测试样本.




图 5 非线性整流电路

表 5 非线性整流电路故障模式

| 故障代码 | 故障类别             | 标称值           | 容差/% | 故障值           |
|------|------------------|---------------|------|---------------|
| F0   | NF               | —             | —    | —             |
| F1   | $L_1 \downarrow$ | 0.1 H         | 5%   | 0.05 H        |
| F2   | $L_1 \uparrow$   | 0.1 H         | 5    | 0.15 H        |
| F3   | $C_2 \downarrow$ | 1000 $\mu$ F  | 5    | 500 $\mu$ F   |
| F4   | $C_2 \uparrow$   | 1 000 $\mu$ F | 5    | 1 500 $\mu$ F |
| F5   | $C_3 \downarrow$ | 1 000 $\mu$ F | 5    | 500 $\mu$ F   |
| F6   | $C_3 \uparrow$   | 1 000 $\mu$ F | 5    | 1 500 $\mu$ F |

4.2 故障诊断结果分析

采用 LibSVM-3.20 在 MATLAB 2014a 中对小波包特征提取后的样本进行故障诊断,采用与 GA-SVM、PSO-SVM、GSA-SVM 相对比的方式,来验证 IGSA-SVM 在两个 CUTs 中的诊断性能优劣,各算法的参数设置与第三部分相同.

四运放双二次高通滤波器电路的故障诊断中各分类器的诊断结果如表 6 所示. 其中,  $C_{Best}$  和  $g_{Best}$  是各分类器找到的最优参数 ( $C, g$ ) 的组合, SVM 为采用默认参数的分类器,即  $C=1, g=1/N, N$  为训练样本的数量,其分类器准确率仅为 83.076 9%,而其他经过算法优化的分类器的准确率都在 97% 以上,说明优化 SVM 参数在模拟电路故障诊断中的重要性.

GSA-SVM 和 IGSA-SVM 的分类时间小于 GA-SVM 和 PSO-SVM,可以有效节约时间成本,尤其是对于数据量较大的样本. 标准 GSA-SVM 的分

类准确率和 PSO-SVM 的保持一致,并未在模拟电路故障诊断中表现出优势,而 IGSA-SVM 分类器取得了最高的分类准确率 98.205 1%,表示其跳出了其他分类器所陷入的局部收敛,具有较好的故障诊断效果.

表 6 四运放双二次高通滤波器电路故障诊断结果

| 分类器类型    | 分类准确率/%  | 分类时间/s | $C_{Best}$ | $g_{Best}$ |
|----------|----------|--------|------------|------------|
| SVM      | 83.076 9 | —      | —          | —          |
| GA-SVM   | 97.692 3 | 38.99  | 803.768 2  | 94.019 5   |
| PSO-SVM  | 97.435 9 | 44.36  | 760.648 8  | 97.598 3   |
| GSA-SVM  | 97.435 9 | 24.73  | 838.189 5  | 65.205 8   |
| IGSA-SVM | 98.205 1 | 23.71  | 943.411 4  | 98.275 3   |

在非线性整流电路的故障诊断中,各分类器的诊断结果见表 7,由于非线性元件二极管 D1 的影响,各算法的分类准确率相比于四运放双二次高通滤波器电路的准确率有所降低,但各个算法的寻优差距进一步体现出来. IGSA-SVM 取得最高的分类准确率94.285 7%和最短的分类时间 39.22 s,无论在分类准确率和分类时间上都优于 GSA-SVM 分类器.

表 7 非线性整流电路故障诊断结果

| 分类器类型    | 分类准确率/%  | 分类时间/s | $C_{Best}$ | $g_{Best}$ |
|----------|----------|--------|------------|------------|
| SVM      | 29.523 8 | —      | —          | —          |
| GA-SVM   | 93.809 5 | 56.03  | 847.247 7  | 71.164 9   |
| PSO-SVM  | 91.428 6 | 49.43  | 940.287 0  | 37.396 7   |
| GSA-SVM  | 93.333 3 | 41.49  | 783.948 0  | 59.535 0   |
| IGSA-SVM | 94.285 7 | 39.22  | 563.401 7  | 99.261 6   |

IGSA-SVM 和 GSA-SVM 进化过程中的优化曲线如图 6 所示. IGSA-SVM 通过第一代粒子群寻优后找到了局部极值 0.052 4,IGSA-SVM 引入全局记忆性等操作,以此为导向 IGSA-SVM 在第二代即找到全局最优值 0.042 9,大大加快了收敛速度;而 GSA-SVM 的整体优化过程与 IGSA-SVM 类似,都在第一代找到了局部极值 0.052 4,但在搜索初期由于没有全局记忆性的盲目寻优,在第 1 代和第 8 代出现一个平缓段,收敛速度大大减慢,虽然在第九代找到一个较优的局部极值 0.047 6,但整体还是陷入局部收敛. 从以上两个 CUTs 可知,IGSA-SVM 分类器均跳出局部收敛,以最短的时间找到了最优的惩罚参数  $C$  和核参数  $g$ ,说明 IGSA-SVM 在线性和非线性模拟电路故障中都有较大优势.




图 6 GSA-SVM 和 IGSA-SVM 的优化曲线对比

5 结束语

SVM 中惩罚参数  $C$  和核参数  $g$  的优化选择方法非常重要,决定模拟电路故障诊断的精度和效率. 本文提出了一种基于改进引力搜索算法优化 SVM 参数的改进型分类器. 对三个 UCI 数据集、四运放双二次高通滤波器电路及非线性整流电路中进行仿真分析,并与 GS-SVM、GA-SVM、PSO-SVM 和 GSA-SVM 分类器相对比,验证了 IGSA-SVM 分类器在粒子进化过程中可以有效地跳出局部最优,提高了模拟电路故障诊断的精度,同时缩短了分类时间,提高了故障诊断的效率.

参考文献:

[1] 孙永奎. 基于支持向量机的模拟电路故障诊断方法研究[D]. 成都:电子科技大学, 2009.

[2] 许军, 张耀辉, 陈圣俭, 等. 基于结点电压增量的模拟电路多故障诊断方法研究[J]. 微电子学与计算机, 2015,32(2):138-141.

[3] Yuan L, He Y, Huang J, et al. A new neural-network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor[J]. IEEE Transactions on Instrumentation & Measurement, 2010, 59(3):586-595.

[4] Long B, Xian W, Li M, et al. Improved diagnostics for the incipient faults in analog circuits using LSSVM based on PSO algorithm with Mahalanobis distance [J]. Neurocomputing, 2014, 133(10):237-248.

[5] Chen P, Yuan L, He Y, et al. An improved SVM classifier based on double chains quantum genetic algorithm and its application in analogue circuit diagnosis [J]. Neurocomputing, 2016, 211:202-211.

[6] 张向东, 冯胜洋, 王长江. 基于网格搜索的支持向量机砂土液化预测模型[J]. 应用力学学报, 2011, 28

- (1):24-28.
- [7] Li J, Zhang Q, Wang K, et al. Optimal dissolved gas ratios selected by genetic algorithm for power transformer fault diagnosis based on support vector machine [J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2016, 23(2):1198-1206.
- [8] Liu N, Zhao J. Intrusion detection research based on improved PSO and SVM[C]// International Conference on Automatic Control and Artificial Intelligence. IET, 2012:1263-1266.
- [9] Rashedi E, Nezamabadi-pour H, Saryazdi S. GSA: a gravitational search algorithm [J]. Information Sciences, 2009, 179(13):2232-2248.
- [10] 邓乃扬, 田英杰. 支持向量机:理论、算法与拓展[M]. 北京:科学出版社, 2009.
- 作者简介:**  
**梅恒荣** 男, (1993-), 硕士研究生. 研究方向为机器学习和故障诊断.  
**刘冬梅(通讯作者)** 女, (1982-)副教授, 硕士生导师. 研究方向为电路设计、电路故障诊断和信号处理.  
E-mail: dmliu100@hfut.edu.cn.
- 
- (上接第 108 页)
- [3] 孙强. 信息安全风险评估模型的定性定量对比研究 [J]. 微电子学与计算机, 2010, 27(6):92-96.
- [4] Rosa M Rodríguez, Luis Martínez, Francisco Herrera. Hesitant fuzzy linguistic term sets for decision making[J]. IEEE TRANSACTIONS ON FUZZY SYSTEMS, 2012, 20(1):109-118.
- [5] Cuiping Wei, Na Zhao, Xijin Tang. Operators and comparisons of hesitant fuzzy linguistic term sets [J]. IEEE TRANSACTIONS ON FUZZY SYSTEMS, 2014, 22(3): 575-585.
- [6] Decui Liang, Dun Liu. A novel risk decision making based on decision-theoretic rough sets under hesitant fuzzy information [J]. IEEE TRANSACTIONS ON FUZZY SYSTEMS, 2015, 23, (2):237-247.
- [7] Sanjay Kumar Tyagi. Multiple attribute decision making using hesitant triangular fuzzy sets[C]// International Conference on Electrical, Electronics, and Optimization Techniques. IEEE, 2016:1502-1509.
- [8] Ren Peijia, Xu Zeshui, Hao Zhinan. Hesitant fuzzy thermodynamic method for emergency decision making based on prospect theory[J]. IEEE TRANSACTIONS ON CYBERNETICS, 2016(3): 2168-2267.
- [9] Tversky A, Kahneman D. Advances in prospect theory cumulative representation of uncertainty [J]. Journal Risk Uncertainty, 1992, 5(4):297-323.
- [10] 潘雪霖, 孙伟. 基于 GB/T 20984-2007 风险评估计算模型的研究[J]. 信息安全研究, 2015, 1(1):54-59.
- [11] 陈鑫, 王晓晗, 黄河. 基于威胁分析的多属性信息安全风险评估方法研究[J]. 计算机工程与设计, 2009, 30(1):38-40.
- 作者简介:**  
**黄国庆** 男, (1963-), 教授, 硕士生导师. 研究方向为信息安全和效能评估.  
**肖爽(通讯作者)** 男, (1991-), 硕士研究生. 研究方向为信息安全效能评估. E-mail: 13523828918@163.com.