

DOI: 10.13382/j.jemi.2017.08.012

改进粒子群算法优化的 SVM 模拟电路故障诊断*

梅恒荣 殷礼胜 刘冬梅 何怡刚 袁莉芬 赵丽欣 陈 鹏 赵蓓蕾 任 帅
(合肥工业大学 电气与自动化工程学院 合肥 230009)

摘 要:针对粒子群(PSO)算法优化支持向量机(SVM)参数存在容易陷入局部最优的问题,通过引入新的动态惯性权重、全局邻域搜索、收缩因子和遗传算法中的变异操作,提出了一种基于改进粒子群(IPSO)算法优化 SVM 参数(IPSO-SVM)的改进型分类器。采用 UCI 机器学习库中的公共数据集 Iris、Wine 和 seeds 来测试其分类效果,结果表明 IPSO-SVM 分类器在分类准确率和分类时间上优于 GS-SVM、AFSA-SVM、GA-SVM 和 PSO-SVM 分类器。最后,将 IPSO-SVM 分类器应用于 Sallen-Key 带通滤波器、四运放双二次高通滤波器及非线性整流电路的故障诊断中,结果表明 IPSO-SVM 分类器具有较强的全局收敛能力和较快的收敛速度。

关键词: 支持向量机;改进粒子群算法;模拟电路;故障诊断

中图分类号: TN707;TP277 **文献标识码:** A **国家标准学科分类代码:** 510.10

Analogue circuit fault diagnosis based on SVM optimized by IPSO

Mei Hengrong Yin Lisheng Liu Dongmei He Yigang Yuan Lifen Zhao Lixin
Chen Peng Zhao Beilei Ren Shuai

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

Abstract:In order to solve the problem that the basic particle swarm (PSO) to optimize the parameter of SVM is easy to fall into local optimum, this paper proposes a modified classifier that uses the improved particle swarm optimization (IPSO) to optimize the parameter of SVM (IPSO-SVM) by introducing the new dynamic inertia weight, global neighborhood search, shrinkage factor and mutation operator of genetic algorithm. The classification result is tested by the common datasets named Iris, Wine and seeds from UCI machine learning repository, the result shows that IPSO-SVM classifier is better than GS-SVM, AFSA-SVM, GA-SVM and PSO-SVM classifier in terms of classification accuracy and classification time. The better convergence ability and speed of the IPSO-SVM classifier are verified by fault diagnosis of Sallen-Key band-pass filter, four-opamp biquad highpass filter and nonlinear rectifier circuit.

Keywords: support vector machine; improved particle swarm optimization; analog circuit; fault diagnosis

0 引 言

随着现代电子设备中模拟电路复杂度和集成度不断增加,其可靠性和可维护性十分关键^[1]。但模拟电路存在建模困难、测试节点少、容差性、非线性以及故障的多样性等问题,使得传统的故障字典法、元件参数辨识法和故障验证法等方法已不适用于模拟电路故障诊断^[2]。基

于此,国内外学者提出了神经网络(NNs)^[3-5]和支持向量机(SVM)^[6-8]等机器学习方法。其中,SVM 相比于 NNs 具有结构简单、自学习能力和泛化能力强等优点,在小样本、非线性、高维度模式识别的情况下,具有很强的分类推广能力,已成功应用于模拟电路故障诊断^[9-10]。

然而 SVM 中惩罚参数 C 和核参数 g 的选取不同严重影响其分类效果^[11],为此,文献[12]应用网格搜索法(GS)寻找训练样本的结构风险最小值所对应的 SVM 最

收稿日期:2016-12 Received Date: 2016-12

* 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)、国际热核聚变实验堆(ITER)计划专项(2015GB102000)、教育部科学技术研究重大项目(313018)资助

优参数,但该方法只适用于样本较小的预测模型;文献[13]利用人工鱼群算法(AFSA)较好的并行性和较强的全局寻优能力得到SVM的最优参数组合,但该方法没有寻得最优解邻域后再进行局部寻优;文献[14]利用遗传算法(GA)的自组织、自适应和自学习性来优化SVM参数,但GA算法仿照基因编码的工作相对较复杂;文献[15]采用基本粒子群(PSO)算法来优化SVM参数,由于其基本参数是固定的,存在容易陷入局部最优的问题,之后Shi等人提出了基于惯性权重的粒子群算法^[16],其采用惯性权重线性递减的方式,但这种算法只有在初始阶段搜索到全局最优附近才有效,否则,随着惯性权重的线性减小,局部搜索能力逐渐增强,就会跳过全局最优,陷入局部最优。

1 基于改进粒子群算法(IPSO)的SVM参数优化

1.1 SVM原理

设样本集为 $T = \{(x_i, y_i) | i = 1, 2, \dots, N\}$, 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 $(\omega \cdot x) + b = 0$, 要求其不但能正确区分样本, 而且使分类间隔最大^[17]。求解最优分类超平面可以转化为求解下列优化问题:

$$\min \Phi(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N \xi_i$$

$$\text{s. t. } y(\omega \cdot x + b) \geq 1 - \xi_i \quad i = 1, \dots, N \quad (1)$$

式中: ω 为超平面的法向量; b 为偏差; C 为惩罚参数, 用来实现最大化分类间隔和最小化错分样本数之间的折中, 是影响SVM分类性能的重要参数之一; ξ_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, 引入拉格朗日函数, 用对偶原理把原优化问题转化为:

$$\max W(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j K(x_i, x_j)$$

$$\text{s. t. } \sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \quad i = 1, \dots, N \quad (2)$$

式中: α_i 为拉格朗日乘子, $K(x_i, y_j)$ 为核函数, 常用的核函数类型有多项式核函数、高斯径向基核函数、多层感知机核函数等^[18]。本文采用具有普适性的高斯径向基核函数, 文献[10]已证明其优越性, 其函数表达式为:

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

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:

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

1.2 IPSO算法

为了避免惩罚参数 C 和核参数 g 选择困难对SVM分类器的分类效果造成恶劣影响, 本文提出一种IPSO算法来优化SVM参数, 在式(5)~(6)所示PSO算法的基础上, 通过引入新的动态惯性权重、全局邻域搜索、收缩因子和遗传算法中的变异操作来防止算法陷入局部最优。

$$v_{ij}^{k+1} = \omega(k) v_{ij}^k + c_1 r_1 (p_{ij} - x_{ij}^k) + c_2 r_2 (p_{gj} - x_{ij}^k) \quad (5)$$

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} \quad (6)$$

式中: v_{ij}^k 为第 k 次迭代中第 i 个粒子的第 j 个变量的速度, x_{ij}^k 为第 k 次迭代中第 i 个粒子的第 j 个变量的位置, $\omega(k)$ 为惯性权重, c_1 和 c_2 分别为自身学习因子和社会学习因子, p_{ij} 为第 i 个个体最优粒子的第 j 个变量, p_{gj} 为全局最优粒子的第 j 个变量, r_1 和 r_2 为 $[0, 1]$ 内均匀分布的随机数。

对上述基本粒子群算法进行了4个方面的改进后, 构成了本文的IPSO算法。

1) 引入一种新的动态惯性权重, 定义其为一个指数型函数与一个随机数乘积的形式, 如式(7)和(8)所示。

$$\omega(k) = \omega_{\max} \left(\frac{\omega_{\min}}{\omega_{\max}} \right)^m \cdot \text{rand} \quad (7)$$

$$m = \frac{k^2 - 1}{K^2 - 1} \quad (8)$$

式中: rand 是 $[0, 1]$ 内均匀分布的随机数, k 为当前迭代次数, K 为最大迭代次数。设 $\omega_{\max} = 0.9$, $\omega_{\min} = 0.4$, 迭代1000次, 得到动态惯性权重如图1所示。




图1 动态惯性权重 ω

Fig.1 Dynamical inertia weight ω

从图1可以看出, 在搜索初期, ω 取较大值的概率大, 可增强全局搜索能力, 到搜索后期, ω 取较小值的概率大, 局部开采能力得到增强。但在整体上, ω 随迭代次数的增加呈现下降趋势, 这并不表示下一次迭代的惯性权重比上一次小, 这样增加了种群的多样性, 加强了跳出局部最优的能力, 有利于维持算法全局搜索和局部开采的平衡。

2) 考虑到个体最优和全局最优粒子的邻域区间可能

存在较优粒子,其相比于确定的全局最优粒子更有益于 IPSO 算法跳出局部极值。因此,对其进行全局邻域搜索,即对个体最优解和全局最优解进行如式(9)所示的小扰动,这样可以有效地避免算法早熟,提高算法的解空间开发能力。

$$v_{ij}^{k+1} = \omega(k) \times v_{ij}^k + c_1 r_1 [p_{ij}(1 \pm \delta \times U(0,1)) - x_{ij}^k] + c_2 r_2 [p_{g'}(1 \pm \delta \times U(0,1)) - x_{ij}^k] \quad (9)$$

式中: $U(0,1)$ 是没有被预先设定的 $[0,1]$ 内均匀分布的随机数,可使用 MATLAB 中的 `unifrnd` 函数实现;扰动大小为 δ ,仿真发现 $\delta = 0.01$ 能适度且有效增加个体最优和全局最优的邻域搜索范围。

3)引入收缩因子 χ ,如式(10)所示,使用收缩因子改变进化过程中的学习因子,即改变其社会学习能力和自身学习能力,防止算法的发散行为,提高算法稳定性和加快算法收敛。

$$x_{ij}^{k+1} = x_{ij}^k + \chi v_{ij}^{k+1} \quad (10)$$

4)借鉴遗传算法中的变异思想,引入遗传算法中的变异操作,即在每次进行速度和位置更新后以 10% 的概率初始化粒子,变异操作拓宽了迭代过程中不断缩小的种群搜索空间,保持种群的多样性,有效地增加粒子跳出局部最优的概率。

IPSO 算法的具体步骤如下:

- 1)参数初始化。设置种群大小 N ,粒子的位置 x_{ij}^1 和速度 v_{ij}^1 ,进化代数 K ,学习因子 c_1 和 c_2 ,惯性权重的最大值 $\omega_{\max}$ 和最小值 $\omega_{\min}$,扰动大小 δ ,收缩因子 χ ,参数 C 和 g 的取值范围。
- 2)找到初始粒子群的个体最优和全局最优粒子。计算每一个粒子的适应度值,排序确定初始粒子群的全局最优粒子。
- 3)粒子速度和位置更新。引入新的动态惯性权重和全局邻域搜索,按式(7)~(9)进行每一个粒子的速度更新;引入收缩因子,按式(10)进行粒子的位置更新;最后以 10% 的概率进行粒子变异。
- 4)检验终止条件。判断是否达到最大迭代次数(或者达到精度要求),若达到则输出最优解,否则返回

步骤 2)。

1.3 算法验证

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,在 MATLAB R2014a 中对改进型分类器 IPSO-SVM 的分类效果进行验证。其中 Iris 数据集是对 3 种不同的鸢尾花进行比较的结果,是模式识别文献中应用最多的数据集之一;Wine 数据集是对意大利同一地区的 3 个不同品种的葡萄酒化学分析的结果;Seeds 数据集是对 3 种不同小麦进行比较的结果。各个数据集划分情况如表 1 所示。

表 1 各数据集样本划分情况
Table 1 Sample partitioning of each dataset

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

本文采用与文献[15-17]中的 GS-SVM、AFSA-SVM、GA-SVM 和 PSO-SVM 分类器相比较的方法来验证改进型分类器 IPSO-SVM 的分类效果。各分类器算法的参数设置如下,5 种分类器均采用 3 折交叉验证的方式,参数 C 的范围均为 $[0.01,1000]$,参数 g 的范围均为 $[0.001,100]$,除 GS 算法外的 4 种算法的种群大小 N 均为 20,进化代数 K 均为 100 次。GS-SVM 分类器中,参数 C 和 g 的步进大小 $Cstep$ 和 $gstep$ 都为 0.05;AFSA-SVM 分类器中,最大试探次数 Try_num 为 5,人工鱼的感知距离 $Visual$ 为 2.5,移动步长 $Step$ 为 0.5,鱼群的拥挤度因子 s 为 0.3;GA-SVM 分类器中,交叉率 P_c 和变异率 P_m 分别为 0.7 和 0.035;在 PSO-SVM 分类器和 IPSO-SVM 分类器中,学习因子 c_1 和 c_2 分别为 1.5 和 1.7,惯性权重最大值 $\omega_{\max}$ 为 0.9,最小值 $\omega_{\min}$ 为 0.4,收缩因子 χ 的范围为 $[0.7,0.9]$ 。这 5 种分类器对 Iris、Wine 和 Seeds 数据集的分类准确率和分类时间如表 2 所示。

表 2 5 种分类器对 Iris、Wine 和 Seeds 数据集的分类结果
Table 2 Classifying results of five classifiers on Iris, Wine and Seeds datasets

分类器类型	Iris		Wine		Seeds	
	准确率/%	分类时间/%	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
AFSA-SVM	95	15.77	88.732 4	18.22	86.666 7	16.97
GA-SVM	96.666 7	3.71	87.323 9	5.49	86.666 7	3.98
PSO-SVM	96.666 7	4.01	87.323 9	5.84	85.555 6	4.23
IPSO-SVM	98.333 3	3.65	88.7324	5.29	87.777 8	3.88

从表 1 和 2 中可知:对于不同样本总数和不同维度的 3 个数据集,IPSO-SVM 分类器都获得了最高的分类准

确率和最短的分类时间,说明 IPSO-SVM 分类器较其他类型的分类器具有更加突出的分类效果。

2 IPSO-SVM 在模拟电路故障诊断中的应用

基于 IPSO-SVM 的模拟电路故障诊断的方法流程如图 2 所示,主要包括数据采集、特征提取、划分样本、SVM 参数寻优和故障分类 5 个部分。采用如下 3 个 CUT (circuits under test) 进行故障诊断。




图 2 基于 IPSO-SVM 的模拟电路故障诊断流程
Fig.2 Flow chart of analogue circuit fault diagnosis based on IPSO-SVM

2.1 第 1 个 CUT 验证

2.1.1 诊断电路故障设置及数据采集

第一个实验电路为 Sallen-Key 带通滤波器,是进行模拟电路故障诊断的经典电路之一,具体电路图如图 3 所示。考虑该电路元件发生单故障时的情形,所有电阻的容差设为 5%,所有电容的容差设为 10%,当电路元件在容差范围内变化时,处于正常状态,如果电路中任意元件的参数高于或低于其标称值的 50%,电路处于故障状态。 $\uparrow$ 表示元件发生偏大故障, $\downarrow$ 表示元件发生偏小故障。假定电路划分为一种正常状态(NF)和 8 种故障类型,故障类型分别记为 C1 $\uparrow$,C1 $\downarrow$,C2 $\uparrow$,C2 $\downarrow$,R2 $\uparrow$,R2 $\downarrow$,R3 $\uparrow$,R3 $\downarrow$,具体设置如表 3 所示。




图 3 Sallen-Key 带通滤波器电路
Fig.3 Sallen-Key bandpass filter circuit

在 OrCAD16.6 软件中对其进行仿真实验,输入信号 V1 采用电压幅值为 10 V、频率为 1 kHz 的正弦电压源。对表 3 中的各种故障类别分别进行 80 次蒙特卡罗分析,通过 Pspice 中的瞬态分析从“out”节点采集电压信号,在 1.2 ms 内采集 128 个数据点,然后将其进行小波包分解得到 8 维故障特征向量。最后,将每种故障状态下的 80

表 3 Sallen-Key 带通滤波器故障模式				
Table 3 Fault modes of Sallen-Key bandpass filter				
故障代码	故障类别	标称值	容差	故障值
F0	NF	—	—	—
F1	C1 $\downarrow$	5 nF	10%	2.5 nF
F2	C1 $\uparrow$	5 nF	10%	10 nF
F3	C2 $\downarrow$	5 nF	10%	2.5 nF
F4	C2 $\uparrow$	5 nF	10%	10 nF
F5	R2 $\downarrow$	3 k Ω	5%	1.5 k Ω
F6	R2 $\uparrow$	3 k Ω	5%	6 k Ω
F7	R3 $\downarrow$	2 k Ω	5%	1 k Ω
F8	R3 $\uparrow$	2 k Ω	5%	4 k Ω

个样本随机分为两部分,其中 50 个作为训练样本,30 个作为测试样本。

2.1.2 故障诊断结果分析

采用 LibSVM-3.20 在 MATLAB R2014a 中对采集到的样本进行故障诊断,为了验证 IPSO-SVM 分类器的性能优劣,采用与 SVM、AFSA-SVM、GA-SVM 和 PSO-SVM 分类器相对比的方式,各算法的参数设置与本文第 1 节相同。记录仿真结果如表 4 所示,各故障分类结果如图 4 所示。

表 4 Sallen-Key 带通滤波器故障诊断结果				
Table 4 The fault diagnosis results of Sallen-Key bandpass filter				
分类器类型	分类准确率/%	分类时间/s	BestC	BestG
SVM	89.259 3	—	—	—
AFSA-SVM	96.296 3	128.55	817.621 9	69.399 9
GA-SVM	97.037	18.61	834.934	99.173 5
PSO-SVM	96.666 7	19.24	813.316 6	92.594 7
IPSO-SVM	97.407 4	18.32	979.166 4	90.64

表 4 中,SVM 为采用默认参数的分类器,即参数 $C = 1, g = 1/N, N$ 为训练样本的数量,其分类准确率仅有 89.259 3%。而对比其他经过参数优化的 AFSA-SVM、GA-SVM 和 PSO-SVM 分类器,IPSO-SVM 分类器的分类结果最优,不仅得到最高的分类准确 97.407 4%,而且其分类时间 18.32 s 也最短。

在图 4 中,可以更加直观地看出 AFSA-SVM、GA-SVM、PSO-SVM 及 IPSO-SVM 分类器错分样本的位置。可知,在各分类器的误分样本中,故障 F8 误分为故障 F2 最多,占全部误分样本数的一半以上,通过仿真发现,F2 与 F8 故障的输出波形幅值大小相同,仅相位有较小差别,是造成其较难区分的原因。

2.2 第 2 个 CUT 验证

2.2.1 诊断电路故障设置及数据采集

本文再以四运放双二次高通滤波器电路为例验证




图 4 Sallen-Key 带通滤波器中 4 种分类器的分类结果

Fig. 4 Classifying results of the four classifiers in the Sallen-Key bandpass filter

IPSO-SVM 分类器的收敛能力,具体电路如图 5 所示,此电路更为复杂且故障类别增加到 13 种。假定电路 C1 ~ C2 和 R1 ~ R4 发生故障,具体设置如表 5 所示。给电路




图 5 四运放双二次高通滤波器电路

Fig. 5 Four-opamp biquad highpass filter circuit

表 5 四运放双二次高通滤波器的故障模式

Table 5 Fault modes of four-opamp biquad highpass filter

故障代码	故障类别	标称值	容差/%	故障值
F0	NF	—	—	—
F1	C1 ↑	5 nF	10	10 nF
F2	C1 ↓	5 nF	10	2.5 nF
F3	C2 ↑	5 nF	10	15 nF
F4	C2 ↓	5 nF	10	2.5 nF
F5	R1 ↑	6.2 kΩ	5	15 kΩ
F6	R1 ↓	6.2 kΩ	5	3 kΩ
F7	R2 ↑	6.2 kΩ	5	18 kΩ
F8	R2 ↓	6.2 kΩ	5	2 kΩ
F9	R3 ↑	6.2 kΩ	5	12 kΩ
F10	R3 ↓	6.2 kΩ	5	2.7 kΩ
F11	R4 ↑	1.6 kΩ	5	2.5 kΩ
F12	R4 ↓	1.6 kΩ	5	0.5 kΩ

施加幅值为 5 V、周期为 0.5 ms 脉冲,对每种故障分别进行 80 次 Monte Carlo 分析,在 30 μs 内采集 128 个数据点,通过小波包分解得到 8 维故障特征向量,划分训练样本为 50 个,测试样本为 30 个。

2.2.2 故障诊断结果分析

对四运放双二次高通滤波器电路进行故障诊断,分类器的种群最优适应度曲线如图 6 所示,各分类器的分类结果如表 6 所示。




图 6 四运放双二次高通滤波器中 4 种分类器的种群最优适应度曲线

Fig. 6 Population's best fitness curve of the four classifiers based on the four-opamp biquad highpass filter

从图 6 中可以看出,虽然 AFSA-SVM 在第 1 代已收敛,但其达到的最高适应度只有 98.923 1%; PSO-SVM 在第 12 代达到其最高适应度值 99.076 9%,不仅收敛较慢,而且陷入局部收敛;4 种分类器中只有 IPSO-SVM 和 GA-SVM 达到全局最高的适应度值 99.230 8%,但 IPSO-

表 6 四运放双二次高通滤波器电路故障诊断结果

Table 6 The fault diagnosis results of four-opamp biquad highpass filter circuit

分类器类型	分类准确率/%	分类时间/s	BestC	BestG
SVM	83.076 9	—	—	—
AFSA-SVM	97.435 9	247.77	858.760 4	78.903 1
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
IPSO-SVM	98.205 1	38.31	923.819 6	94.318 0

SVM 具有更快的收敛速度,在第 1 代即收敛,而 GA-SVM 在第 8 代才收敛。说明 IPSO-SVM 分类器不仅能达到全局最高适应度值,而且还具有最快的收敛速度,提高了故障分类的效率。

表 6 中各分类器的分类性能和表 4 中类似,IPSO-SVM 分类器的分类效果都最优,综合表 4 和表 6 各分类器的表现,可以得出如下结论。

- 1)SVM 的 (C,g) 参数组合影响其分类准确率,采用默认 (C,g) 参数组合的 SVM 分类准确率都在 90% 以下,而其他经过参数优化的 SVM 分类准确率均在 96% 以上,说明优化 SVM 参数在模拟电路故障诊断中的重要性。
- 2)AFSA-SVM 分类器分类时间最长且陷入局部最优。GA-SVM 分类器虽然相比于 AFSA-SVM 和 PSO-SVM 分类器的分类效果较好,但仍不能达到最高的分类准确率。而 IPSO-SVM 相比于 PSO-SVM 的分类准确率有了较大提升,不仅没有陷入局部收敛,而且收敛速度更快。
- 3)无论是经典的 Sallen-Key 带通滤波器电路,还是具有弱非线性的四运放双二次高通滤波器电路,IPSO-SVM 分类器均能获得最高的分类准确率和最短的分类时间。

2.3 第 3 个 CUT 验证

2.3.1 非线性电路故障设置及数据采集

最后,本文以非线性整流电路为例来验证 IPSO-SVM 分类器的普适性,具体电路如图 7 所示,该电路的功能是将交流电压整流为直流电压。选择 L_1 、 C_2 和 C_3 作为故




图 7 非线性整流电路

Fig. 7 Nonlinear rectifier circuit

障诊断元件,电路中电阻、电容和电感的容差均设置为 5%,故障模式设置如表 7 所示。采用交流分析对该电路进行故障诊断,扫描频率的起止范围是 1 ~ 100 Hz。同样,对每种故障分别进行 80 次 Monte Carlo 分析,采集到的数据进行小波包分解,得到 8 维故障特征向量,其中 50 个作为训练样本,30 个作为测试样本。

表 7 非线性整流电路故障模式

Table 7 Fault modes of the nonlinear rectifier circuit

故障代码	故障类别	标称值	容差/%	故障值
F0	NF	—	—	—
F1	L1 ↓	0.1H	5	0.05 H
F2	L1 ↑	0.1H	5	0.15 H
F3	C2 ↓	1 000 μF	5	500 μF
F4	C2 ↑	1 000 μF	5	1 500 μF
F5	C3 ↓	1 000 μF	5	500 μF
F6	C3 ↑	1 000 μF	5	1 500 μF

2.3.2 故障诊断结果分析

各种算法的分类准确率如表 8 所示,虽然各算法分类准确率相比线性电路的有所降低,但各算法的寻优差距进一步体现出来。IPSO-SVM 分类器取得最高的准确率 94.761 9%,而 PSO-SVM 分类器的准确率仅为 91.428 6%,说明 IPSO 算法通过引入新的动态惯性权重和全局邻域搜索等手段,有效确保了 IPSO 算法在粒子进化过程中跳出局部最优,找到了最优的惩罚参数 C 和核参数 g ,使得分类准确率明显提升,由此,说明 IPSO-SVM 分类器在非线性电路故障诊断中具有较大优势。

表 8 4 种分类器的故障诊断结果

Table 8 The fault diagnosis results of four classifiers

(%)				
分类器类型	AFSA-SVM	GA-SVM	PSO-SVM	IPSO-SVM
分类准确率	90.952 4	93.809 5	91.428 6	94.761 9

3 实际电路故障诊断

为验证本文方法在实际电路故障诊断中的效果,搭建如图 8 所示的 Sallen-Key 带通滤波器电路板,选用容差为 5% 的电阻,容差 10% 的电容,运放 OP-07 的 ± 12 V 供电电源通过电路板右侧的并联电容滤波,以减小噪声对实验的干扰。Tektronix AFG2021-SC 函数信号发生器为电路提供与仿真相同的输入信号,按照表 3 为 C_1 、 C_2 、 R_2 和 R_3 设置不同的故障参数,每种故障状态采集 40 个样本,其中,训练样本和测试样本各 20 个,采用 Tektronix DPO2024B 数字储存示波器将各种故障状态

的输入输出波形储存为 CSV 格式,以便进行小波包特征提取。




图 8 实际 Sallen-Key 带通滤波器电路板
Fig. 8 The actual Sallen-Key bandpass filter circuit board

各种算法的分类准确率如表 9 所示,其分类准确率普遍低于仿真测试的分类准确率,但 IPSO-SVM 分类器准确率仍高于其他分类器,由此验证了其在实际故障诊断中的有效性。在实际电路故障诊断中,由于电源噪声、信号互扰、元件精度和系统误差的影响,导致幅值相同但相位差较小的故障在实际电路中更难以区分,是分类准确率降低的主要原因。

表 9 4 种分类器的故障诊断结果

Table 9 The fault diagnosis results of four classifiers				
(%)				
分类器类型	AFSA-SVM	GA-SVM	PSO-SVM	IPSO-SVM
分类准确率	86.6667	88.8889	86.6667	90

4 结 论

SVM 的参数优化在模拟电路故障诊断中十分重要,本文提出了一种基于 IPSO 算法优化 SVM 参数的改进型分类器。对 3 个 UCI 数据集、Sallen-Key 带通滤波器、四运放双二次高通滤波器及非线性整流电路进行仿真分析,通过与 GS-SVM、AFSA-SVM、GA-SVM 和 PSO-SVM 分类器相对比的方式,验证了 IPSO-SVM 分类器能有效地提高模拟故障诊断的分类准确率和收敛速度,缩短分类时间。但本文在对 Sallen-Key 带通滤波器的仿真和实验中均发现,幅值相同且相位差较小的故障样本较难区分,因此,可选用其他更为合适的故障特征提取方法来提高这类样本的分类准确率,是有待进一步研究的内容。

参考文献

[1] 何星,王宏力,陆敬辉,等. 基于优选小波包和 ELM 的模拟电路故障诊断[J]. 仪器仪表学报, 2013, 34(11):2614-2619.
HE X, WANG H L, LU J H, et al. Analog circuit fault diagnosis method based on preferred wavelet packet and ELM[J]. Chinese Journal of Scientific Instrument,

2013, 34(11):2614-2619.
[2] 孙健,王成华. 基于 mRMR 原则和优化 SVM 的模拟电路故障诊断[J]. 仪器仪表学报, 2013, 34(1): 221-226.
SUN J, WANG CH H. Analog circuit fault diagnosis based on mRMR and optimized SVM [J]. Chinese Journal of Scientific Instrument, 2013, 34(1):221-226.
[3] 肖迎群,冯良贵,何怡刚. 基于小波分形和核判别分析的模拟电路故障诊断[J]. 电工技术学报, 2012, 27(8):230-238.
XIAO Y Q, FENG L G, HE Y G. A fault diagnosis approach of analog circuit using wavelet-based fractal analysis and Kernel LDA [J]. Transactions of China Electrotechnical Society, 2012, 27(8):230-238.
[4] 丁硕,巫庆辉,常晓恒,等. 基于灰色 BP 神经网络的实验材料供应预测[J]. 国外电子测量技术, 2016, 35(12):78-82.
DING SH, WU Q H, CHANG X H, et al. Prediction of laboratory equipment support based on grey relation analysis and BP neural network[J]. Foreign Electronic Measurement Technology, 2016, 35(12):78-82.
[5] YUAN L F, HE Y G, HUANG J Y, 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.
[6] 王道明,鲁昌华,蒋薇薇,等. 基于粒子群算法的决策树 SVM 多分类方法研究[J]. 电子测量与仪器学报, 2015, 29(4):611-615.
WANG D M, LU CH H, JIANG W W, et al. Study on PSO-based decision-tree SVM multi-class classification method [J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(4):611-615.
[7] 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.
[8] 廖剑,史贤俊,周绍磊,等. 基于局部图嵌入加权罚 SVM 的模拟电路故障诊断方法[J]. 电工技术学报, 2016, 31(4):28-35.
LIAO J, SHI X J, ZHOU SH L, et al. Analog circuit fault diagnosis based on local graph embedding weighted-penalty SVM[J]. Transactions of China Electrotechnical Society, 2016, 31(4):28-35.
[9] 张朝龙,何怡刚,袁莉芬,等. 基于核熵成分分析的模拟电路早期故障诊断方法[J]. 仪器仪表学报, 2015, 36(3):675-684.
ZHANG CH L, HE Y G, YUAN L F, et al. Approach for analog circuit incipient fault diagnosis based on KECA [J]. Chinese Journal of Scientific Instrument, 2015, 36(3):675-684.

- [10] 宋国明,王厚军,刘红,等. 基于提升小波变换和 SVM 的模拟电路故障诊断[J]. 电子测量与仪器学报, 2010, 24(1):17-22.
SONG G M, WANG H J, LIU H, et al. Analog circuit fault diagnosis using lifting wavelet transform and SVM[J]. Journal of Electronic Measurement and Instrument, 2010, 24(1):17-22.
- [11] 周绍磊,廖剑,史贤俊. RBF-SVM 的核参数选择方法及其在故障诊断中的应用[J]. 电子测量与仪器学报, 2014, 28(3):240-246.
ZHOU SH L, LIAO J, SHI X J. Kernel parameter selection of RBM-SVM and its application in fault diagnosis[J]. Journal of Electronic Measurement and Instrumentation, 2014, 28(3):240-246.
- [12] 张向东,冯胜洋,王长江,等. 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.
ZHANG X D, FENG SH Y, WANG CH J, et al. Support vector machine model for predicting sand liquefaction based on grid-search method[J]. Chinese Journal of Applied Mechanics, 2011, 28(1):24-28.
- [13] 高雷阜,赵世杰,高晶. 人工鱼群算法在 SVM 参数优化选择中的应用[J]. 计算机工程与应用, 2013, 49(23):86-90.
GAO L F, ZHAO SH J, GAO J. Application of artificial fish-swarm algorithm in SVM parameter optimization selection[J]. Computer Engineering and Applications, Computer Engineering and Applications, 2013, 49(23):86-90.
- [14] LI J Z, ZHANG Q G, 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 and Electrical Insulation, 2016, 23(2):1198-1206.
- [15] XUE Z H, DU P J, SU H J. Harmonic analysis for hyperspectral image classification integrated with PSO optimized SVM[J]. IEEE Journal of Stars, 2014, 7(6):2131-2146.
- [16] 高立群,李若平,邹德旋. 全局粒子群优化算法[J]. 东北大学学报:自然科学版, 2011, 32(11):1538-1541.
GAO L Q, LI R P, ZOU D X. A global particle swarm optimization algorithm[J]. Journal of Northeastern University: Natural Science, 2011, 32(11):1538-1541.
- [17] 郭明玮,赵宇宙,项俊平,等. 基于支持向量机的目标检测算法综述[J]. 控制与决策, 2014, 29(2):193-200.
GUO M W, ZHAO Y ZH, XIANG J P, et al. Review of object detection methods based on SVM[J]. Control and Decision, 2014(2):193-200.
- [18] 翟旭平,杨兵兵,孟田. 基于 PCA 和混合核函数

QPSO_SVM 频谱感知算法[J]. 电子测量技术, 2016, 39(9):87-90.

ZAI X P, YANG B B, MENG T. Spectrum sensing based on PCA and QPSO_SVM with mixed kernel[J]. Electronic Measurement Technology, 2016, 39(9):87-90.

作者简介



梅恒荣, 2015 年于青岛大学获得学士学位, 现为合肥工业大学硕士研究生, 主要研究方向为模拟电路故障诊断。

E-mail: mhr1107@mail.hfut.edu.cn

Mei Hengrong received B. Sc. from Qingdao University in 2015. Now, he is a M. Sc. candidate in Hefei University of Technology. His main research interest includes analogue circuit fault diagnosis.



殷礼胜, 1994 年于安徽大学获得学士学位, 2004 年于广西大学获得硕士学位, 2007 年于重庆大学获得博士学位, 现为合肥工业大学副教授, 主要研究方向为现代智能算法理论及其应用。

E-mail: yls20000@163.com

Yin Lisheng received B. Sc. from Anhui University in 1994, M. Sc. from Guangxi University in 2004, and Ph. D. from Chongqing University in 2007, respectively. Now he is an associate professor in Hefei University of Technology. His main research interest includes modern intelligent algorithm theory and its application.



刘冬梅 (通讯作者), 2004 年于西安电子科技大学获得学士学位, 2009 年于中科院合肥物质科学研究院获得博士学位, 现为合肥工业大学副教授, 主要研究方向为电路设计、电路故障诊断和信号处理。

E-mail: dmliu@live.cn

Liu Dongmei (Corresponding author) received B. Sc. from Xidian University in 2004, and Ph. D. from Hefei Institute of Physical Science, CAS, in 2009, respectively. Now she is an associate professor in Hefei University of Technology. Her main research interests include circuit design, circuit fault diagnosis and signal processing.



何怡刚, 1992 年于湖南大学获得硕士学位, 1996 年于西安交通大学获得博士学位, 现为合肥工业大学教授, 合肥工业大学电气与自动化工程学院院长, 主要研究方向为智能测试与诊断装备, 智能电网等。

E-mail: 18655136887@163.com

He Yigang received M. Sc. from Hunan University in 1992, and Ph. D. from Xi'an Jiaotong University in 1996, respectively. Now he is a professor and the dean of School of Electrical Engineering and Automation, Hefei University of Technology. His main research interests include intelligent test and diagnosis equipment, smart grid and so on.