

引用格式:熊魁,岳长喜,刘冬梅,等. 基于 IGWO 算法优化的 SVM 模拟电路故障诊断[J]. 微电子学与计算机,2019,36(1): 16-21. [XIONG K, YUE C X, LIU D M, et al. Analogue Circuit Fault Diagnosis Based on SVM Optimized by IGWO[J]. Microelectronics & Computer,2019,36(1):6-21.]

基于 IGWO 算法优化的 SVM 模拟电路故障诊断

熊 魁¹,岳长喜¹,刘冬梅²,梅恒荣²

(1 中国电力科学研究院有限公司,湖北 武汉 430074; 2 合肥工业大学 电气与自动化工程学院,安徽 合肥 230009)

摘 要:为提高基于支持向量机(SVM)模拟电路故障诊断的准确率和优化效率,在灰狼优化(GWO)算法的基础上,通过引入非线性收敛因子、动态权重和边界变异策略,提出了一种改进灰狼优化(IGWO)算法优化 SVM 参数(IGWO-SVM)的改进型分类器.首先,在 Sallen-Key 带通滤波器和四运放双二次高通滤波器电路中采集故障样本,并对故障样本进行小波包特征提取;然后,将特征提取后的样本划分为训练样本和测试样本,利用 IGWO 算法来优化 SVM 中的惩罚参数 C 和核参数 γ ,得到最优的 SVM 分类器模型;最后,与其他算法优化的 SVM 分类器进行对比,结果表明 IGWO-SVM 分类器可以防止种群陷入局部最优,同时收敛速度有了较大提升.

关键词:改进灰狼优化算法;支持向量机;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(2019)01—0016—06

Analogue Circuit Fault Diagnosis Based on SVM Optimized by IGWO

XIONG Kui¹, YUE Chang-xi¹, LIU Dong-mei², MEI Heng-rong²

(1 China Electric Power Research Institute, Wuhan 430074, China; 2 School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

Abstract: In order to improve the accuracy and optimization efficiency of analog circuit fault diagnosis based on support vector machine (SVM), on the basis of gray wolf optimization (GWO) algorithm, this paper proposes a modified classifier that uses the improved gray wolf optimization (IGWO) algorithm to optimize the parameter of SVM (IGSA-SVM) by introducing the nonlinear convergence factor, dynamic weight and boundary variation strategy. Firstly, the fault samples are collected in the Sallen-Key bandpass filter circuit and four opamp biquad highpass filter circuit, and wavelet packet feature extraction is applied to fault samples. Then, feature-extracted samples are divided into training samples and test samples. The IGWO algorithm is used to optimize the penalty parameter C and the kernel parameters γ in SVM to obtain the optimal SVM classifier model. Finally, compared with SVM classifiers optimized by other algorithms, the results show that the IGWO-SVM classifier can prevent the population from falling into a local optimum, and the convergence speed has been greatly improved.

Key words: improved gray wolf optimization algorithm; support vector machine; analog circuit; fault diagnosis

1 引言

近年来,模拟电路设计和生产工艺都取得长足

发展,但模拟电路故障的检测和诊断却进展缓慢,而对模拟电路故障进行快速准确诊断,对于保障电子系统的可靠性和安全性具有重要意义^[1]. 模拟电路

中存在的容差性、可测节点少、非线性等问题,限制了传统故障诊断方法的应用^[2]. 随着神经网络(NNs)^[3]和支持向量机(SVM)^[4]等技术被引入模拟电路故障诊断领域,推动了故障诊断技术进一步发展. 相较于 NNs,基于统计学习理论的 SVM 在小样本、维度高、非线性的模式识别情况下,具有结构简单、泛化能力和自学习能力强等优势,在模拟电路故障诊断中得到广泛应用^[5].

SVM 的分类效果与其惩罚参数 C 和核参数 γ 的选取有关^[6],为了获得更好地分类效果,本文采用群智能算法中的灰狼优化(GWO)算法^[7]来优化 SVM 的这两个参数,GWO 算法是 Seyedali 等人通过观察自然界中灰狼的等级制度和狩猎行为,在 2014 年提出一种新型仿生算法,该算法具有结构简单、需要调节参数少等优点,但一定程度上也存在容易陷入局部最优和收敛较慢等问题^[8].

为此,本文在 GWO 算法中引入非线性收敛因子、动态权重和边界变异策略,构成本文的改进灰狼优化(IGWO)算法,从而提出了一种 IGWO-SVM 分类器,首先采用 UCI 数据集验证其分类效果,然后选用 Sallen-Key 带通滤波器和四运放双二次高通滤波器电路作为诊断电路,通过与 SVM,GA-SVM,PSO-SVM 和 GWO-SVM 相对比的方式,验证 IGWO-SVM 分类器优良的故障诊断分类效果.

2 基于 IGWO 的支持向量机参数优化

2.1 支持向量机原理

SVM 是由 Vapnik 提出的一种基于 VC 维理论和结构风险最小化的机器学习算法^[9]. 其基本原理是通过核函数的非线性变换将样本空间投影到高维的特征空间,并求出最优分类超平面使得各类样本在高维特征空间中线性可分^[10].

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 $(\omega \cdot x) + b = 0$, 使得样本在正确分类的同时保证分类间隔最大,即可转化为求解下列优化问题:

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

式(1)中: ω 为权向量; b 为偏移量; ξ_i 为松弛变量; C 为惩罚参数,表示对错分样本的惩罚程度,主要是影响 SVM 分类性能的参数之一.

通过在公式(1)中引入 Lagrange 函数,再利用对偶原理将上述优化问题转化为:

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

式(2)中, α_i 为拉格朗日乘子; $K(x_i, y_j)$ 为核函数. 不同的核函数形成不同的算法,本文采用普适性较好的高斯径向基核函数,其函数表达式为:

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

式(3)中, γ 为核宽度参数,通过调节参数值的大小改变映射函数,从而影响 SVM 的分类性能. 通过引入上述核函数,其决策函数的表达式为:

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

2.2 基本灰狼优化算法

GWO 算法模拟自然界中灰狼的等级制度和狩猎行为,需要依照适应度值从大到小将狼群个体分为 $\alpha, \beta, \delta, \omega$ 四组,由 α, β, δ 追捕猎物, ω 跟随 α, β, δ 进行跟踪围剿. 猎物位置对应于优化问题的全局最优解,寻优过程可表述为:在一个搜索空间中随机产生 N 个灰狼个体,求出种群中每一个灰狼的适应度值,得出适应度前三的灰狼为 α, β, δ , 由它们的位置作为寻找猎物位置(全局最优解)的基准,迭代更新下一代个体的位置,最终寻找到猎物位置,实现捕获猎物的任务. 在捕食过程中,需由式(5) 确定个体与猎物间的距离,式(6) 则表示灰狼个体的更新方式.

$$D = |C \cdot X_p(t) - X(t)| \quad (5)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (6)$$

$$A = 2a \cdot r_1 - a, C = 2r_1 \quad (7)$$

$$a = 2 - 2(t/\max) \quad (8)$$

式中, t 表示种群当前迭代次数;式(5)、(6) 中 X_p 代表猎物位置; X 代表灰狼个体位置; D 表示个体与猎物间的距离;式(7) 中, A, C 为系数向量; r_1 和 r_2 均为 $[0, 1]$ 的随机数; $|A| > 1$ 对应于全局搜索; $|A| < 1$ 对应于局部搜索;式(8) 中收敛因子 a 随着迭代次数从 2 线性递减到 0, $\max$ 为最大迭代次数.

当灰狼判断出猎物位置时, α, β, δ 是最靠近猎物的, ω 可依据 α, β, δ 的方位推算出猎物的大概位置,从而靠近猎物,其数学表达式如下:

$$D_\alpha = |C_1 \cdot X_\alpha(t) - X(t)| \quad (9)$$

$$D_\beta = |C_2 \cdot X_\beta(t) - X(t)| \quad (10)$$

$$D_\delta = |C_3 \cdot X_\delta(t) - X(t)| \quad (11)$$

式中, $X_\alpha, X_\beta, X_\delta$ 分别表示 α, β, δ 当前位置, $X(t)$ 表

示当前灰狼位置. ω 狼朝向 α, β, δ 的移动的距离及方向可由式(9) ~ (14) 得到.

$$X_1 = X_\alpha - A_1 \cdot D_\alpha \tag{12}$$

$$X_2 = X_\beta - A_2 \cdot D_\beta \tag{13}$$

$$X_3 = X_\delta - A_3 \cdot D_\delta \tag{14}$$

$$X(t+1) = (X_1 + X_2 + X_3)/3 \tag{15}$$

式(15) 为按平均值计算的 ω 狼的最终位置.

2.3 改进的灰狼优化算法

采用灰狼优化算法在优化支持向量机的惩罚参数 C 和核参数 γ 时, 为避免陷入局部最优和收敛较慢的情况, 通过引入非线性收敛因子、动态权重和边界变异策略, 构成本文的改进灰狼优化(IGWO)算法, 具体改进如下:

(1) 引入非线性收敛因子. GWO 算法的收敛因子 a 在迭代过程是线性递减的, 但算法的收敛过程并非线性, 为实现算法迭代过程中全局搜索和局部搜索之间的平衡, 本文引入一种非线性收敛因子如公式(16)所示.

$$a = 2 - 2 \frac{e^{\frac{t}{\max}} - 1}{e - 1} \tag{16}$$

式中, t 为当前迭代次数; $\max$ 为最大迭代次数; e 为自然对数函数的底数. 收敛因子迭代 100 次后对比图如图 1 所示, 非线性收敛因子相比于线性收敛因子, 在搜索初期, a 的衰减程度降低, 有利于种群的全局寻优; 到了搜索后期, a 的衰减程度提高, 局部寻优能力增强, 从而实现全局和局部搜索能力的平衡.




图 1 收敛因子对比图

(2) 在公式(15) 所示的位置更新中引入动态权重. 在进行位置更新时, GWO 算法是依据体现 α, β, δ 同等重要性的平均值来进行计算的, 这样忽略了 α 的领导地位, 没有体现不同的最优解在进行位置更新时所占的比例, 为此, 本文引入一种动态权重如公式(17)~(20)所示, 通过引入动态权重有利于加快

算法收敛.

$$\omega_1 = \frac{|X_1|}{|X_1| + |X_2| + |X_3|} \tag{17}$$

$$\omega_2 = \frac{|X_2|}{|X_1| + |X_2| + |X_3|} \tag{18}$$

$$\omega_3 = \frac{|X_3|}{|X_1| + |X_2| + |X_3|} \tag{19}$$

$$X(t+1) = \frac{(\omega_1 X_1 + \omega_2 X_2 + \omega_3 X_3)}{3} \tag{20}$$

(3) 引入边界变异策略. 在 GWO 算法进行迭代的过程中, 若种群中的个体参数值超出其设定的范围之外, GWO 算法会自动设置个体回到边界处, 若较多的个体聚集到边界上, 不利于 GWO 算法的收敛, 为此, 引入边界变异策略如公式(21)所示, 这样有利于增加种群的多样性, 加快算法收敛.

当 $X < X_{\min}$ 或 $X > X_{\max}$
则 $X = \text{rand} \times (X_{\max} - X_{\min}) + X_{\min}$ (21)

3 IGWO-SVM 在 UCI 数据集上的算法验证

选择 UCI 公共数据集中的 Iris、Wine 和 Seeds 数据来验证 IGWO-SVM 分类器的分类效果, Iris 数据集是三种不同的鸢尾花进行比较的结果, Wine 数据集是对三种不同的葡萄酒成分进行比较的结果, Seeds 数据集是对三种不同品种的小麦进行比较的结果, 三个样本集的划分情况如表 1 所示.

表 1 各数据集样本划分情况

数据集	各类样本总数	数据集维度	训练样本划分情况	测试样本划分情况	选取方式
Iris	50/50/50	4	30/30/30	20/20/20	均匀随机
Wine	59/71/48	13	35/43/29	24/28/19	随机
Seeds	70/70/70	7	40/40/40	30/30/30	均匀随机

采用与 GS-SVM、GA-SVM、PSO-SVM 及 GWO-SVM 相比较的方式来验证 IGWO-SVM 分类器的分类性能. 五种分类器的初始参数设置见表 2, “-”表示不存在的参数, P_c 和 P_m 分别代表 GA 中的交叉率和变异率; c_1 和 c_2 为 PSO 算法中的学习因子; v 为交叉验证的次数, Cstep 和 gstep 为 GS 算法中参数 C 和 γ 的步进大小, 从表 2 中可以看出 GWO-SVM 和 IGWO-SVM 需要调节初始参数最少.

通过对表 1 中三个不同样本总数和不同样本维度的三个数据集进行分类识别, 五种分类器的分类结果如表 3 所示, IGWO-SVM 分类器不仅分类准

确率是最高的,而且其分类时间也是最短的,尤其对于 Iris 数据集,IGWO-SVM 分类器跳出了 GWO-SVM 分类器所陷入的局部收敛,获得 100% 的分类准确率,说明引入非线性收敛因子、动态权重和边界变异策略可以有效避免算法局部收敛,提高样本的分类准确率.

表 2 五种分类器的初始参数设置

分类器	种群大小	进化代数	参数 C 范围	参数 γ 范围	P_c	P_m	c_1	c_2	v	C step size	γ 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	—	—
GWO-SVM	20	100	(0.01,1 000)	(0.001,100)	—	—	—	—	3	—	—
IGWO-SVM	20	100	(0.01,1 000)	(0.001,100)	—	—	—	—	3	—	—

表 3 五种分类器对 Iris、Wine 和 Seeds 数据集的分类结果

分类器	Iris 数据集		Wine 数据集		Seeds 数据集	
	分类准确率/%	分类时间/s	分类准确率/%	分类时间/s	分类准确率/%	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
GWO-SVM	98.333 3	2.57	94.366 2	3.30	90	2.35
IGWO-SVM	100	2.51	94.366 2	3.28	90	2.14

4 基于 IGWO-SVM 的模拟电路故障诊断

基于 IGWO-SVM 的模拟电路故障诊断流程图见图 2,首先选择电路的激励信号、测试节点及定义故障集,后续的诊断流程包括故障数据采集、小波包特征提取、划分训练和测试样本、IGWO-SVM 参数寻优及测试样本故障分类.首先通过对 Sallen-Key 带通滤波器和四运放双二次高通滤波器电路的故障诊断进行仿真分析,然后搭建实际 Sallen-Key 带通滤波器电路板来检验 IGWO-SVM 的分类效果.




图 2 基于 IGWO-SVM 的模拟电路故障诊断流程图

4.1 Sallen-Key 带通滤波器故障诊断

第一个诊断电路为 Sallen-Key 带通滤波器,具体电路如图 3 所示,通过 PSPICE 的时域分析从电路的“out”节点采集数据,当电路元件在设定的容差值范围内时,电路无故障,当电路元件超出其标称值的 $\pm 50\%$ 时,则表示电路出现故障.

电路中的元件的故障模式设置如表 4 所示, $\uparrow$ 和 $\downarrow$ 分别表示元件的参数值高于和低于其标称值.




图 3 Sallen-Key 带通滤波器电路

电压幅值为 10 V 且频率为 1 kHz 的正弦电压源作为电路的激励,在 1.2 ms 内从“out”节点采集 128 个数据点,每一个故障类型进行 80 次蒙特卡罗分析,然后对采集到的数据进行小波包特征提取,最后随机选取其中的 50 个样本作为训练样本,30 个样本作为测试样本.

表 4 Sallen-Key 带通滤波器的故障模式

故障代码	故障类型	标称值	容差值	故障值
E0	NE	—	—	—
E1	C1 $\downarrow$	5 nF	10%	2.5 nF
E2	C1 $\uparrow$	5 nF	10%	10 nF
E3	C2 $\downarrow$	5 nF	10%	2.5 nF
E4	C2 $\uparrow$	5 nF	10%	10 nF
E5	R2 $\downarrow$	3 k Ω	5%	1.5 k Ω
E6	R2 $\uparrow$	3 k Ω	5%	6 k Ω
E7	R3 $\downarrow$	2 k Ω	5%	1 k Ω
E8	R3 $\uparrow$	2 k Ω	5%	4 k Ω

在 MTALB2014a 中安装 LibSVM-3.20 工具包,在该工具包中利用训练样本找到最优的 SVM 参数,并将其输入 SVM 分类模型中,从而得出测试样本的分类准确率.为验证 IGWO-SVM 分类器的分类效果,采用与 SVM,GA-SVM,PSO-SVM,GWO-SVM 分类器相对比的方式,各分类器的参数设置与第三部分一致.

Sallen-Key 带通滤波器电路测试样本的分类结果如表 5 所示,未经过参数优化的 SVM 仅取得 89.259 3% 的分类准确率,远远落后于其他经过算法优化的分类.GWO-SVM 和 PSO-SVM 分类器取得相同的分类准确率 96.666 7%,GA-SVM 分类器的分类准确率为 97.303 7%,都不同程度的陷入局部收敛,由于 IGWO-SVM 分类器引入非线性收敛因子等操作,有效避免的算法陷入局部最优的情况,取得了最高的分类准确率 97.407 4%.

表 5 Sallen-Key 带通滤波器测试样本的分类结果

分类器	分类准确率/%	最优 C 值	最优 γ 值
SVM	89.259 3	—	—
GA-SVM	97.037	834.934	99.173 5
PSO-SVM	96.666 7	813.316 6	92.594 7
GWO-SVM	96.666 7	800.473 1	93.265 5
IGWO-SVM	97.404 7	927.984 4	94.686 9

4.2 四运放双二次高通滤波器故障诊断

第二个诊断电路为四运放双二次高通滤波器电路,用来验证 IGWO-SVM 分类器的收敛效果,具体电路如图 4 所示,电路更为复杂.电路故障模式设置如表 6 所示,电路故障模式增加到 13 种.选取幅值为 5 V、周期为 0.5 ms 的脉冲作为电路的激励,通过电路的“out”节点在 30 μ s 内采集 128 个数据点,同样对每个故障类型进行 80 次蒙特卡罗分析,然后对进行小波包特征提取,选取 50 个作为训练样本,30 个作为测试样本.




图 4 四运放双二次高通滤波器电路

四运放双二次高通滤波器电路测试样本的分类

表 6 四运放双二次高通滤波器的故障模式

故障代码	故障类型	标称值	容差值	故障值
E0	NE	—	—	—
E1	C1 $\uparrow$	5 nF	10%	10 nF
E2	C1 $\downarrow$	5 nF	10%	2.5 nF
E3	C2 $\uparrow$	5 nF	10%	15 nF
E4	C2 $\downarrow$	5 nF	10%	2.5 nF
E5	R1 $\uparrow$	6.2 k Ω	5%	15 k Ω
E6	R1 $\downarrow$	6.2 k Ω	5%	3 k Ω
E7	R2 $\uparrow$	6.2 k Ω	5%	18 k Ω
E8	R2 $\downarrow$	6.2 k Ω	5%	2 k Ω
E9	R3 $\uparrow$	6.2 k Ω	5%	12 k Ω
E10	R3 $\downarrow$	6.2 k Ω	5%	2.7 k Ω
E11	R4 $\uparrow$	1.6 k Ω	5%	2.5 k Ω
E12	R4 $\downarrow$	1.6 k Ω	5%	0.5 k Ω

结果如表 7 所示,各种分类器的分类结果与 Sallen-Key 带通滤波器电路的类似,IGWO-SVM 分类器取得了最高的分类准确率 98.205 1%,GA-SVM 分类器取得了第二的分类准确率 97.692 3%,GWO-SVM 和 PSO-SVM 分类器的分类准确率相同为 97.435 9%,位列第三.

表 7 四运放双二次高通滤波器电路测试样本的分类结果

分类器	分类准确率/%	最优 C 值	最优 γ 值
SVM	83.076 9	—	—
GA-SVM	97.692 3	803.768 2	94.019 5
PSO-SVM	97.435 9	760.648 8	97.598 3
GWO-SVM	97.435 9	929.525 0	60.512 5
IGWO-SVM	98.205 1	862.184 6	99.702 5

GWO-SVM 和 IGWO-SVM 的优化曲线对比如图 5 所示,IGWO-SVM 分类器在第 1 代找到局部最优值 1.282 1%,由于在算法中引入动态权重和边界变异策略,将不同的最优解所占比例引入个体的位置更新中,确保了 α 狼的领导地位,同时,边界变异策略增加了种群的多样性,从而使得 IGWO-SVM 分类器在第二收敛于全局最优解 0.512 8%;而 GWO-SVM 分类器由于按照最优解的平均值进行位置更新,这种无领导的寻优方式使得种群在第 1 代到第 43 代之间出现一个平缓段,尽管在第 44 代时找到了一个局部最优值 1.282 1%,但种群还是陷入局部收敛.

4.3 实际 Sallen-Key 带通滤波器电路板故障诊断

搭建实际 Sallen-Key 带通滤波器电路板,用来验证本文方法对实际电路故障诊断的效果,选用容差值为 5% 的电阻,容差值为 10% 的电容,OP-07 作为运放,通过 Tektronix AFG2021-SC 函数信号发生器给出与仿真同样的正弦电压源,电路元件的故




图 5 GWO-SVM 和 IGWO-SVM 的优化曲线对比
障模式设置见表 4,选用 Tektronix DPO2024B 数字
储存示波器读取输出节点的响应信号,每一种故障
模式采集 40 个样本,并进行小波包特征提取,将特
征提取后的样本随机选取 20 个作为训练样本,剩下
的 20 个作为测试样本。

Sallen-Key 带通滤波器电路板测试样本的分类
结果如表 8 所示,IGWO-SVM 分类器取得了最高
的分类准确率 90%。与表 5 所示的仿真结果相对
比,各分类器的分类准确率都有所降低,其中,PSO-
SVM 的分类准确率相比仿真时下降了 10%;GA-
SVM 的分类准确率下降了 8.148 1%;GWO-SVM
的分类准确率下降了 7.777 8%;而 IGWO-SVM 的
分类准确率下降最少,为 7.407 4%;由此,验证了
IGWO-SVM 分类器在仿真和实验中的有效性。

表 8 Sallen-Key 带通滤波器电路板测试样本的分类结果

分类器	分类准确率/%	最优 C 值	最优 γ 值
SVM	76.666 7	—	—
GA-SVM	88.888 9	942.231 8	89.3414
PSO-SVM	86.666 7	494.749 9	86.057 8
GWO-SVM	88.888 9	981.550 2	72.973 2
IGWO-SVM	90	908.047 2	98.980 4

5 结束语

采用 SVM 对模拟电路进行故障分类时,需要
优化惩罚参数 C 和核参数 γ 以达到最高的分类准
确率,为此,本文对 GWO 算法进行改进,提出了一
种 IGWO-SVM 改进型分类器,通过对 UCI 数据集
和两个模拟电路的仿真分析,以及实际的 Sallen-
Key 带通滤波器电路板的实验验证,并与 SVM,
GA-SVM,PSO-SVM 和 GWO-SVM 分类器的分类
结果相比较,结果表明 IGWO-SVM 分类器都取得

最高的分类准确率,有效防止了种群陷入局部最优,
并且其收敛速度也得以加快。

参考文献:

[1] 毛先柏. 基于支持向量机的模拟电路故障诊断研究
[D]. 武汉:华中科技大学,2009.

[2] 刘美容,张立玮. 基于小波分解和模糊聚类的模拟电
路软故障诊断[J]. 微电子学与计算机,2014,31(12):
140-143.

[3] Yuan L, He Y, Huang J, et al. A new neural-net-
work-based fault diagnosis approach for analog circuits
by using kurtosis and entropy as a preprocessor[J].
IEEE Transactions on Instrumentation & Measure-
ment, 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 algo-
rithm and its application in analogue circuit diagnosis
[J]. Neurocomputing, 2016(211):202-211.

[6] 梅恒荣,殷礼胜,刘冬梅,等. 改进粒子群算法优化的
SVM 模拟电路故障诊断[J]. 电子测量与仪器学报,
2017, 31(8):1239-1246.

[7] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimi-
zer[J]. Advances in Engineering Software, 2014, 69
(3):46-61.

[8] 郭振洲,刘然,拱长青,等. 基于灰狼算法的改进研究
[J]. 计算机应用研究,2017,33(12):3603-3606.

[9] 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.

[10] 姜媛媛,韩振云,崔江. 基于 DAGSVC 的模拟电路故
障字典法[J]. 传感器与微系统,2011, 30(4):12-16.

作者简介:

熊 魁 男,(1988-),硕士,工程师. 研究方向为电气测量
技术.

岳长喜 男,(1982-),硕士,高级工程师. 研究方向为高电
压大电流以及电能计量技术.

刘冬梅(通讯作者) 女,(1982-),博士,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

梅恒荣 男,(1993-),硕士研究生. 研究方向为机器学习和
故障诊断.