

基于 AdaBoost 与 GABP 的模拟 电路软故障诊断方法

赵文俊¹, 张强¹, 刘磊², 宋家友²

(1. 空军第一航空学院 航空电子工程系, 河南 信阳 8 464000; 2. 郑州大学 信息工程学院, 郑州 450001)

摘要: 针对容差模拟电路软故障诊断精度较低的问题, 提出了一种基于 AdaBoost 与 GABP 的组合分类器诊断方法; 首先, 在 Pspice 中对故障模式进行 Monte-Carlo 分析, 并利用波形有效点提取法提取故障特征, 在此基础上, 做归一化处理构建神经网络的原始样本; 其次, 利用 GA 算法与 L-M 算法组合优化 BP 网络构建 GABP 分类器; 最后, 利用 AdaBoost 算法对 GABP 单分类器进行迭代提升, 构建 AdaBoost-GABP 组合分类器; 诊断实例的结果表明, 该方法比传统的单分类器诊断方法具有更高的诊断精度、更低的绝对误差, 能够克服单分类器容易陷入局部最优, 诊断结论不可信的缺陷。

关键词: 模拟电路软故障诊断; AdaBoost 算法; GA 算法; Monte-Carlo 分析; 组合分类器

Analog Circuit Soft Fault Diagnosis Method Based on AdaBoost and GABP

Zhao Wenjun¹, Zhang Qiang¹, Liu Lei², Song Jiayou²

(1. First Aeronautical College of Air Force, Xinyang 464000, China;

2. School of Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: The accuracy of soft fault diagnosis for analog circuit with tolerance is relative low, therefore, a new method based on AdaBoost and GABP is proposed. Firstly, fault modes are simulated by Monte-Carlo method, furthermore, the effective point extraction method is used to extract the characteristic of the fault-pattern, on this basis, original samples of neural network is constructed using the normalized fault data. Secondly, GA algorithm and the L-M algorithm are used to optimize BP neural network to construct GABP classifier. Finally, the GABP network was boost by the AdaBoost algorithm to construct the AdaBoost-GABP combination classifier. The example shows that, the method proposed has higher accuracy and lower error than the traditional single classifier, beyond that, the method overcomes the defect that it is easy to fall into local optimum for the single classifier.

Keywords: analog circuit fault diagnosis; AdaBoost algorithm; GA algorithm; Monte-Carlo analysis; combination classifier

0 引言

模拟电路由于元件参数具有容差并且可及节点较少等原因导致故障诊断难度极大^[1]。传统的模拟电路故障诊断通常采用基于解析模型的方法^[2], 但复杂航空装备精确的解析模型往往是不可能建立的, 并且模型与对象之间逼近度难以确定, 这就导致该方法诊断精度较低, 诊断结论不可信^[3]。

为了克服传统方法的缺陷和不足, 各种基于模式识别理论的智能诊断方法被提出, 极大地提高了模拟电路故障诊断精度和效率^[4]。目前, 许多专家学者都对此做了深入研究。宋国明、王厚军^[5]利用提升小波变换法提取电路的故障特征, 然后采用 SVM 分类器进行故障诊断, 该方法改善了故障特征提取的质量, 提高了故障分类的精度。郭阳明、冉从宝^[6]利用遗传算法来确定 BP 神经网络初始权值的局部解空间, 然后利用 L-M 方法再搜索权值的精确解, 最后利用优化后的 BP 网络进行故障诊断, 该方法克服了传统 BP 网络容易陷入局部最小值的缺陷, 提高了 BP 网络的诊断能力。肖迎群、何怡刚^[7]利用小波分析和主元分析方法进行故障特征提取, 并利用脊波网络

进行故障诊断, 提高了传统小波网络对高维故障数据的处理能力。

以上方法都是建立在单分类器基础上的, 而单分类器在分类时, 实际上都是在局部空间内从一个起点出发利用各种规则搜索最优解, 有可能会陷入局部最优的缺陷中^[8]。这就导致诊断结果不可信, 并且误差较高, 精度较低^[9]。针对此问题, 本文一方面利用 GA 算法和 L-M 算法组合优化 BP 网络, 改善其拓扑结构、提高其收敛速率; 另一方面, 引入 AdaBoost 算法对单分类器进行提升, 得到具有互补性和多样性的组合分类器。在分类时该组合分类器可以在解空间中从不同点出发搜索最优解, 并融合基分类器的分类结果, 从而提高诊断精度。

1 模拟电路软故障特征提取

模拟电路发生的故障很大一部分是软故障, 即元件参数偏离正常取值范围而产生的故障^[10]。本文利用波形有效点提取法提取电路的故障特征, 并以此构建神经网络的原始样本。

1.1 模拟电路软故障建模

模拟电路元件的容差范围一般是标称值的 $\pm 5\%$, 只要偏离了此范围就会发生软故障。以标称值为 10 k 的电阻 R 为例说明本文对软故障建模的思路。

1) 当 R 在 $[9.5 \text{ k}, 10.5 \text{ k}]$ 范围变化时, R 处于正常

收稿日期: 2017-05-07; 修回日期: 2017-05-24。

作者简介: 赵文俊(1974-), 男, 湖北钟祥人, 研究生, 副教授, 主要从事机载航空电子系统及设备的测试与故障诊断方向的研究。

状态。

2) 当 R 大于 10.5 k 时认为电路发生了偏高软故障, 这种故障一般在大于标称值 50% 时比较明显, 因此可以选取 15 k 为这种故障的模型, 同时对这种故障设置 10% 的波动范围, 即该故障的取值范围为 [13.5 k, 16.5 k], 这种设置可以模拟软故障连续变化的性质。

3) 当 R 小于 9.5 k 时认为电路发生了偏低故障, 同理, 这种故障一般在低于标称值 50% 时对电路的影响比较明显, 因此, 可以选取 5 k 为这种偏低故障的模型, 同样设置 10% 的波动范围来模拟软故障的连续性^[11]。

1.2 故障模式的 Monte-Carlo 分析

Monte-Carlo 分析是一种随机模拟分析法, 可以模拟电路的容差效应^[12]。本文 Monte-Carlo 分析的工具是 OrCAD 中集成的 Pspice, 利用 Pspice 中的模型编辑工具 Model Editor 可以对软故障建模并设置容差范围、概率分布。电阻的模型编辑语句为 model Rbreak RES (R=1DEV/Gauss=10%), 电容的模型编辑语句为 model Cbreak CAP (C=1 DEV/Gauss=5%), 概率分布都设置为高斯分布, 因为这更加符合实际情况。

1.3 故障特征提取

利用 Pspice 可以把分析之后的波形数据导出成 “.txt” 文件, 这些文件可以导入到 Matlab 中进行分析 and 预处理, 从而提取故障特征^[13]。本文采用波形有效点提取法提取故障特征, 即提取每种故障模式 Monte-Carlo 分析后输出节点电压响应波形中各区间分界点的值, 将其作为故障特征数据。

2 AdaBoost 算法

AdaBoost 通过反复抽取训练样本中的部分实例组成新的训练集合, 并在这些训练集合上对单分类器进行训练构成多个分类器的组合。训练集合中的样本有差异, 因此, 分类器具有多样性。同时, AdaBoost 算法在每次迭代的过程中可自适应改变集合中每个样本的权值, 使基分类器能够始终关注那些分类错误的样本, 因此, 基分类器之间具有互补性。这两种性质使得组合分类器比单分类器具有更高的正确率^[15]。算法的具体过程如下:

1) 对原始样本中每个实例均匀分配权重, 公式为:

$$\omega_i^0 = \frac{1}{N} (i = 1, 2, \dots, N) \quad (1)$$

其中: ω_i^0 是第 i 个实例的初始权值, N 是实例总数。初始权重确定后, 对原始样本抽样得到一个训练样本, 并采用一种分类模型在训练样本上训练得到一个弱分类器。

2) 利用训练得到的单分类器对整个原始样本进行分类, 并计算该分类器的分类错误率, 错误率的计算公式为:

$$\epsilon = \frac{1}{N} [\sum_j \omega_j I(C(x_j) \neq y_j)] \quad (2)$$

其中: ϵ 是该分类器分类错误率, ω_j 是第 j 个实例的权重, x_j 是第 j 个实例, y_j 是第 j 个实例的类标签, $C(x_j)$ 是该分类器对实例 x_j 的分类结果, $I(A)$ 是指示函数, 具体的取值情况如式 (3) 所示。

$$I(A) = \begin{cases} 0 & A = false \\ 1 & A = true \end{cases} \quad (3)$$

分类器错误率计算之后, 可以得出该基分类器的重要性:

$$\alpha = \frac{1}{2} \ln \frac{1-\epsilon}{\epsilon} \quad (4)$$

其中: α 是该分类器的重要性, 当错误率趋近 1 时, 分类器的重要性为负无穷, 错误率趋近 0 是, 分类器的重要性趋近正无穷。

3) 利用基分类器对原始样本中所有实例的分类结果更新样本权重, AdaBoost 中权重更新算法可以用式 (5) 表示。

$$\omega_i^{(j+1)} = \frac{\omega_i^{(j)}}{Z_j} \times \begin{cases} e^{-\alpha_j} C^j(x_i) = y_i \\ e^{\alpha_j} C^j(x_i) \neq y_i \end{cases} \quad (5)$$

其中: $\omega_i^{(j+1)}$ 是第 i 个实例在第 $j+1$ 次迭代之后的权重, $\omega_i^{(j)}$ 是第 i 个实例在第 j 次迭代后的权重, Z_j 是规范化因子, 用于保证 $\sum_i \omega_i^{(j+1)} = 1$ 。从式 (5) 可以看出, 当第 j 次得到的基分类器对实例 x_i 分类正确时, 该实例的权重在更新后就会下降, 错误时, 权重则会增加。

4) 反复执行 2) 和 3) 直到满足迭代次数。

5) 对基分类器加权, 构建组合分类器。AdaBoost 算法利用分类器的重要性进行加权投票^[16], 公式为:

$$C^*(x) = \underset{y}{\operatorname{argmax}} \sum_{i=1}^n \alpha_j I(C_j(x) = y) \quad (6)$$

其中: $C^*(x)$ 是样本 x 的最终分类结果。式 (6) 表示对每个基分类器分类结果进行加权, 并把加权总值最大的类标签作为最终类别。

3 GABP 分类器

传统 BP 网络容易陷入局部极小值, 并且收敛速度很慢^[17]。针对此问题, 本文对 BP 网络做两方面的优化以构建 GABP 分类器, 一方面利用 GA 的全局搜索能力优化 BP 网络的拓扑结构和参数; 另一方面, 利用 L-M 算法 (Levenberg-Marquardt) 训练网络, 以减少网络迭代次数, 提高收敛速度。

3.1 利用 GA 优化 BP 网络

利用 GA 优化 BP 网络的具体步骤如下:

1) 按照 1.3 节中的方法提取故障特征, 在 Matlab 中预处理之后组成原始样本。

2) 编码构成染色体。在优化网络的拓扑结构时采用二进制编码, 在优化网络的权值、阈值等参数时采用实数编码。具体编码形式如图 1、图 2 所示。

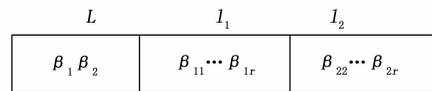


图 1 隐层数、隐层节点数的二进制编码

图 1 中, L 是隐层个数, 当 $\beta_1 \beta_2$ 都为 0 时隐层只有一层。 l_1 表示第一层隐层的节点数, l_2 是第二层隐层的节点数。

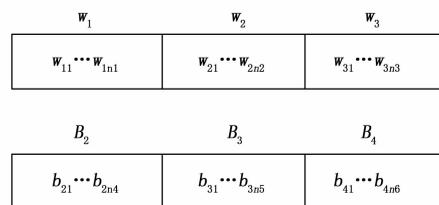


图 2 权值、阈值的实数编码图

实数编码即参数用十进制表示, 这样可缩短编码长度。图

2 中各个参数代表的意义如表 1 所示。

表 1 BP 网络参数表

网络参数	参数代表的意义
$\omega_1 \ \omega_2 \ \omega_3$	网络第一层与第二层、第二层与第三层、第三层与第四间的链接权值
$B_2 \ B_3 \ B_4$	网络第二层、网络第三层、第四层的阈值
n_1	第一层节点数与第二层节点数的乘积
n_2	第二层节点数与第三层节点数的乘积
n_3	第三层节点数与第四层节点数的乘积
$n_4 \ n_5 \ n_6$	第二、第三、第四层节点数

3) 设置遗传操作参数: 种群规模、遗传代数、选择方法、交叉概率 p_c 、变异概率 p_m 等。产生规模为 N 的按照上游编码规则的染色体, 构成 N 个网络个体。

4) 利用训练样本训练 N 个网络得到输出, 根据适应度函数计算每个网络的适应度。适应度的计算公式为:

$$objv = \frac{1}{2} \sum_{k=1}^m \sum_{i=1}^n (y_i(k) - y_i(k))^2 \quad (7)$$

$$fit = (objv + \delta_m)^{-1} \quad (8)$$

式 (7) 中, $objv$ 是目标函数, m 是训练样本中数据对的个数, n 是输出层节点数, $y_i(k)$ 是第 k 个样本的期望输出, $y_i(k)$ 是第 k 个样本的网络实际输出。式 (8) 中, fit 是适应度, δ_m 是为了避免分母为零而添加的一个极小量。

5) 根据适应度大小对所有个体进行选择操作, 选择概率为:

$$p_i = \frac{fit_i}{\sum_{i=1}^N fit_i} \quad (9)$$

其中: p_i 是第 i 个个体被选择的概率, fit_i 是第 i 个个体的适应度大小, N 是种群规模。

6) 利用交叉概率 p_c 对个体进行交叉操作, 利用变异概率 p_m 进行突变操作以产生下一代新个体, 并把新个体插入到旧种群中去, 产生进化后的新种群。

7) 判断是否达到停止条件, 否则转入 4) 继续迭代, 直到找到满意个体。

3.2 L-M 训练算法

传统的梯度下降法在寻找最优值时, 梯度越大下降越快, 当搜索到达最优值附近时, 由于梯度接近零, 此时下降速度变的非常缓慢。而 L-M 算法在梯度下降法的基础上加入牛顿搜索法, 使得当搜索到达最优值附近时依然可以得到一个理想的搜索方向, 提高了网络的收敛速度^[18]。L-M 算法之所以能够具有上述优点, 关键在于改进了权值计算公式:

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (10)$$

其中: e 是训练过程中的误差向量, J 是误差对权值微分的雅克比矩阵, μ 是平滑因子, 使算法在梯度下降和高斯-牛顿法之间达到平衡。

4 构建 AdaBoost-GABP 组合分类器

目前, 单分类器分类性能已经到了技术瓶颈^[19], 因此, 本文从组合分类器的角度出发, 把 GABP 网络与 AdaBoost 算法相结合构建组合分类器, 即 AdaBoost-GABP 分类器, 构建该分类器的过程可用图 3 表示。

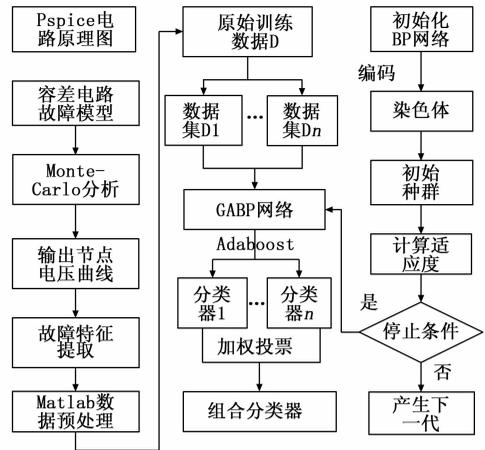


图 3 构建 AdaBoost-GABP 组合分类器流程图

5 诊断实例

下面以一个差分放大电路为例说明本文方法诊断模拟电路软故障的具体过程, 并验证本文方法的可行性和有效性。

5.1 诊断步骤及结果

电路在 OrCAD 中的 Pspice 中建模, 原理图如图 4 所示。

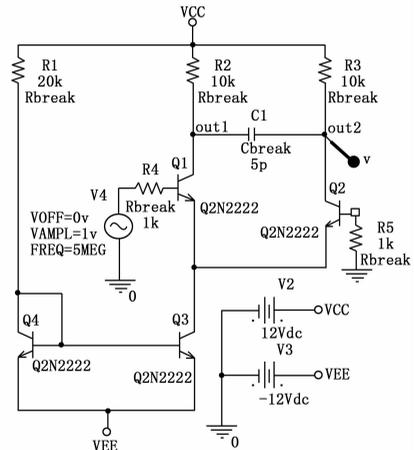


图 4 差分放大电路原理图

5.1.1 故障特征提取

采用 1.3 节中的方法, 提取波形在 $0.2 \mu s$ 、 $0.22 \mu s$ 、 $0.24 \mu s$ 、 $0.26 \mu s$ 、 $0.32 \mu s$ 、 $0.36 \mu s$ 、 $0.38 \mu s$ 处的电压值作为故障特征数据。

5.1.2 构建故障样本

通过灵敏度分析可知, 电路中的 $R1$ 、 $R2$ 、 $R3$ 、 C 发生故障后对电路影响较大, 并且在 10 次 Monte-Carlo 分析后可知 $R3$ 偏高故障对输出几乎无影响。综上所述, 本文待诊断的故障模式及其编码可用表 2 表示。

从表 2 可知, 本文故障模式共 8 种, 因此, 10 次 Monte-Carlo 分析后故障样本总共有 80 组, 其中, 56 组作为训练样本, 24 组作为测试样本。

样本在输入神经网络之前必须进行归一化处理, 归一化公式为:

$$x_{mid} = \frac{x_{max} + x_{min}}{2} \quad (10)$$

$$x_i^* = \frac{x_i - x_{mid}}{(x_{max} - x_{min})/2} \quad (11)$$

其中： x_{mid} 表示每组数据的中间值， x_i^* 是归一化后的数据。

表 2 待诊断故障及其编码表

故障号	故障类别	故障编码
F0	正常	000
F1	R1 偏高	001
F2	R1 偏低	010
F3	R2 偏高	011
F4	R2 偏低	100
F5	R3 偏低	101
F6	C 偏高	110
F7	C 偏低	111

5.1.4 利用 AdaBoost—GABP 组合分类器进行诊断

本文首先在数据挖掘软件 Weka 中实现 AdaBoost 算法，之后利用 AdaBoost—GABP 组合分类器对测试样本进行分类^[20]，结果如表 3 所示。

表 3 AdaBoost—GABP 分类器性能指标

Class	TP	FP	Precision	ROC
000	0.667	0.000	1.000	0.960
001	1.000	0.000	1.000	1.000
010	1.000	0.000	1.000	1.000
011	1.000	0.000	1.000	1.000
100	1.000	0.048	0.750	1.000
101	1.000	0.000	1.000	1.000
110	1.000	0.000	1.000	1.000
111	0.958	0.006	0.969	1.000

5.1.3 利用 GA 优化 BP 构建单分类器

根据第 3 节中的方法利用 GA 分别优化 BP 神经网络的拓扑结构和权值、阈值。在优化网络拓扑结构时编码采用 12 位二进制编码，在优化参数时采用 157 位十进制编码，设定种群规模为 40，运行代数 100 代，代沟设定为 0.9，选择操作采用“轮盘赌”方法，变异概率选择为 0.7。优化之后得到的最佳个体的编码为 000111000100，因此，BP 网络的最佳拓扑结构为 7—14—3。按照此结构构建 BP 网络，训练之后对测试样本进行测试，分类结果如图 5、图 6、所示。

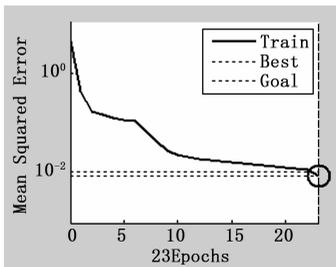


图 5 GABP 网络的训练误差下降曲线

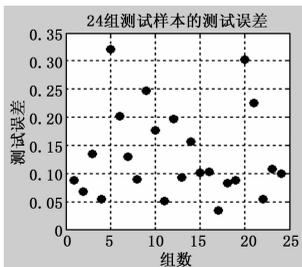


图 6 GABP 网络对 24 组测试样本的分类结果的误差

从图 5 可以看出 GABP 网络在训练 23 次后误差下降到 0.01，网络的收敛速度很快，说明本文利用 GA 算法和 L—M 算法对于提高网络收敛速度，减小网络误差是有效的。

从图 6 可以看出最大的误差不超过 0.35。本文设定 0.2 为阈值，即分类误差大于 0.2 就认为分类失败，低于 0.2 认为分类成功，因此，诊断正确的个数为 19，正确率为 79.16%。从分类结果可知单分类器的软故障诊断正确率不高，因此，利用 AdaBoost 算法对这个单分类器进行提升，来提高诊断正确率。

表 3 中，class 是故障模式，TP 是真阳性率，FP 是假阳性率，precision 是查准率，ROC (Recieve Operating Characteristic) Area 代表的是模型的平均性能，越大这证明该模型越好。从表 3 可以看出，AdaBoost—GABP 组合分类器对 001 010 011 101 110 故障的诊断能力较高，对 000 故障和 100 111 故障的诊断能力稍弱，但 ROC 指标都达到了 0.96 以上，证明该组合分类器的平均性能依然很高。

5.2 四种方法诊断性能对比分析

除了本文提出的方法现还利用几种常见的方法：SVM（支持向量机）、决策树、GABP 网络对 24 组测试样本进行故障分类，并比较这几种方法的分类性能，进一步验证本文方法的有效性和改进程度。四种方法的分类结果如表 4 所示。

表 4 四种分类方法对 24 组故障样本的分类结果

分类器	分类性能		
	Kappa	Mean absolute error	分类精度/%
SVM	0.8571	0.192	87.5
决策树	0.8163	0.0602	83.9286
GABP	0.7619	0.1425	79.1667
AdaBoost—GABP	0.9524	0.0421	95.8333

表 4 中，kappa 系数是指分类器的分类结果和随机分类之间的差异度，Kappa 系数越接近 1，分类器性能越好；Mean absolute error 是平均绝对误差，误差越小，诊断可信用度越高。从表 4 中可知，AdaBoost—GABP 组合分类器的 Kappa 系数分别比 SVM、决策树、GABP 这三种方法高 11.12%、16.67%、25%，误差分别比其他三种方法低 78.07%、30.07%、70.46%，分类精度分别比其他三种方法高 9.52%、14.81%、21.05%，说明 AdaBoost—GABP 网络诊断性能更好、可信用度更高、诊断结果更精确。

6 结束语

本文提出了一种利用 AdaBoost—GABP 组合分类器进行模拟电路软故障诊断的新方法。该方法利用 GA 算法、L—M 算法解决了传统 BP 网络容易陷入局部最小值的问题，克服了其收敛缓慢的缺陷，并利用 AdaBoost 算法提升 GABP 分类器，提高了容差模拟电路软故障诊断精度。实例结果表明，本文方法在分类精度、分类器 Kappa 系数上都有较大提高，并且

(下转第 42 页)

测为划痕, 则判定为误检, 若未能检测到贴上的划痕标签, 则同样判定为误检。设定精度为正确检测的机器数量与总量的比值。窗口大小和检测精度的关系如图 9 所示。

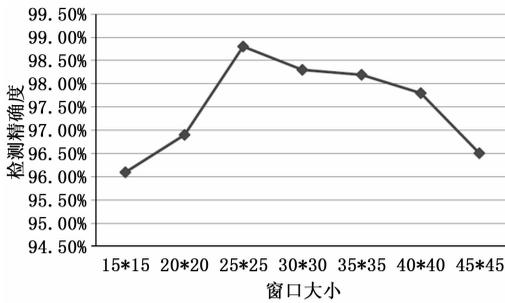


图 9 窗口大小和精确度的关系

表 1 不同大小窗口时间与精度

窗口大小	15 * 15	20 * 20	25 * 25	30 * 30	35 * 35	40 * 40	45 * 45
时间/s	9.0	6.2	4.8	4.0	3.5	3.2	3.0
精度	96.1%	96.9%	98.8%	98.3%	98.2%	97.8%	96.5%

表 1 为不同大小的窗口的检测时间与检测精度对应的具体数值。分析图表, 在窗口大小为 25 * 25 时, 精确度会达到一个峰值, 之后缓慢下降, 结合时间, 选取大小为 25 * 25 大小的滑动窗口用于检测产品的正面以及侧面; 35 * 35 大小的窗口相比起 30 * 30 大小的窗口, 精确度几乎持平, 而时间却明显减少, 所以选取大小为 35 * 35 的滑动窗口用于检测产品的顶面; 背面对于精确度的要求较低, 可选取大小为 40 * 40 的滑动窗口用于检测背面。

5 结论

提出了一种基于 HOG 特征和 Lab 颜色特征融合的多尺度

分类的绝对误差得到了降低, 证明本文提出的方法是容差模拟电路软故障诊断的一种可信的、有效的方法。

参考文献:

[1] 龚茜茜, 李巧君. 遗传神经网络在模拟电路故障诊断中的应用 [J]. 计算机测量与控制, 2012, 20 (11): 2926-2928, 2931.

[2] 黄亮. 模拟电路故障诊断研究 [D]. 北京: 交通大学, 2012.

[3] 方葛丰. 模拟电路故障诊断优化理论与方法的研究 [D]. 长沙: 湖南大学, 2013.

[4] 龚伏廷, 涂爱萍, 王建勇. 小波神经网络在模拟电路故障诊断中的应用 [J]. 计算机仿真, 2011, 28 (2): 228-231, 359.

[5] 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.

[6] 郭阳明, 冉从宝, 姬昕禹, 等. 基于组合优化 BP 神经网络的模拟电路故障诊断 [J]. 西北工业大学学报, 2013, 31 (1): 44-48.

[7] 肖迎群, 何怡刚. 基于小波分形分析和脊波网络的模拟电路故障诊断方法 [J]. 电工技术学报, 2011, 26 (11): 105-114.

[8] 付彬. 多分类器组合中的基分类器选取方法 [D]. 北京: 交通大学, 2009.

[9] Dong B Y, Ren G. Analog circuit fault diagnosis using AdaBoost with SVM-Based component Classifiers [J]. Advanced Materials

滑动窗口检测方法, 可以对产品外观质量完成快速准确的检测, 且具有实时性, 多特征融合可以保证检测结果的准确性, 多尺度滑动窗口既能保证较高的检测精度又能降低检测时间。实验过程中对比了其他几种特征提取方法, 结果表明本文采取 HOG 特征和 Lab 颜色特征具有最高的检测精度; 通过分别选取不同大小的窗口, 结合精度和时间, 在不同的检测面生成大小合适的窗口。在实际的生产流水线进行实验, 结果表明该研究具有很高的工业应用价值。但是经过实验, 发现还是存在误检漏检的情况, 在生产密集的时候, 检测速度还是略微有些跟不上生产速度, 在未来的研究中, 还需要继续改进, 逐步完善性能。

参考文献:

[1] 孙浩, 王程, 王润生. 局部不变特征综述 [J]. 中国图象图形学报, 2011, 16 (2): 141-151.

[2] 蒋年德, 王耀南. 一种新的基于主分量变换与小波变换的图像融合方法 [J]. 中国图象图形学报, 2005, 10 (7): 910-915.

[3] 陈培俊, 伍铁军. 去除阴影后利用霍夫直线变换检测茶叶中的杂质 [J]. 机械工程与自动化, 2014 (5): 63-65.

[4] 龙建武, 申铨京, 陈海鹏. 自适应最小误差阈值分割算法 [J]. 自动化学报, 2012, 38 (7): 1134-1144.

[5] Dragan V, Morozan T, Stoica A M. Robust Stabilization of Linear Stochastic Systems [J]. Mathematical Methods in Robust Control of Linear Stochastic Systems, 2013, 52: 381-436.

[6] Guo Q, Chen G X, Luo J. A Blind Watermarking Algorithm Using DWT and DCT Techniques for Color Image [J]. 2015, 731 (1): 179-182.

[7] 刘金梅, 王国宇. 基于特征接近度的多特征融合方法 [J]. 中国海洋大学学报, 2015, 45 (11): 109-113.

[8] 唐银凤, 黄志明, 黄荣娟. 基于多特征提取和 SVM 分类器的纹理图像分类 [J]. 计算机应用与软件, 2011, 28 (6): 22-26.

[9] Research, 2012 (5), 591-593: 1414-1417.

[10] 敖永才. 容差条件下模拟电路软故障诊断方法研究 [D]. 成都: 电子科技大学, 2014.

[11] 祝文姬, 何怡刚. 容差模拟电路软故障诊断的神经网络方法 [J]. 电工技术学报, 2009, 24 (11): 184-191.

[12] 李云红. 基于 BP 神经网络的模拟电路故障诊断 [J]. 计算机与数字工程, 2009, 37 (6): 192-194+200.

[13] 蒋周娜. 基于小波神经网络的模拟电路故障诊断方法研究及系统实现 [D]. 西安: 西安电子科技大学, 2010.

[14] Wang H Z, Yang J P, Zhang A Y. Design of an Intelligent Fault Diagnosis System for Modern Radar Equipment [J]. Modern Radar, 2008, 42 (2): 80-84

[15] 曹莹, 苗启广, 刘家辰, 等. AdaBoost 算法研究进展与展望 [J]. 自动化学报, 2013, 39 (6): 745-758.

[16] Kantardzic M. 数据挖掘: 概念、模型、方法和算法 [M]. 第 2 版. 王晓海, 吴志刚, 译. 北京: 清华大学出版社, 2013.

[17] 傅荟璇, 赵红. MATLAB 神经网络应用设计 [M]. 第 1 版. 北京: 机械工业出版社, 2010.

[18] Webb A R, Copsey K D. 统计模式识别 [M]. 第 3 版. 王萍译. 北京: 电子工业出版社, 2015.

[19] 刘红, 陈光, 宋国明, 等. 基于 AdaBoost 集成网络的模拟电路单软故障诊断 [J]. 仪器仪表学报, 2010, 31 (4): 851-856.

[20] 袁梅宇. 数据挖掘与机器学习—WEAK 应用技术与实践 (第 1 版) [M]. 北京: 清华大学出版社.