

基于多核多分类相关向量机的 模拟电路故障诊断方法

高明哲¹ 许爱强² 唐小峰² 张伟²

摘要 针对模拟电路实际存在的多类故障问题, 本文提出一种基于多核多分类相关向量机 (Multi-kernel learning multiclass relevance vector machine, MKL-mRVM) 的模拟电路故障诊断方法. 所提方法能够在故障数据所在的原始特征空间上建立多个非线性核, 在构建分类器的同时实现故障特征的约简; 同时, 基于贝叶斯框架的分类模型还能够给出诊断结果的后验概率. 通过两个电路的诊断实验证明了所提方法的优越性和实用性.

关键词 故障诊断, 模拟电路, 相关向量机, 特征约简, 分类概率

引用格式 高明哲, 许爱强, 唐小峰, 张伟. 基于多核多分类相关向量机的模拟电路故障诊断方法. 自动化学报, 2019, 45(2): 434-444

DOI 10.16383/j.aas.2017.c160779

Analog Circuit Diagnostic Method Based on Multi-kernel Learning Multiclass Relevance Vector Machine

GAO Ming-Zhe¹ XU Ai-Qiang² TANG Xiao-Feng²
ZHANG Wei²

Abstract Aimed at the problem of multi-class fault diagnosis in practical analog circuits, a new diagnostic method based on multi-kernel learning multiclass relevance vector machine (MKL-mRVM) is proposed. The proposed method can build multi-kernels in the feature space where fault data are originally represented, which can realize the reduction of fault features during the modeling of classifier. In addition, the classifier based on Bayesian framework is able to output the posterior probability of diagnostic results. The fault diagnostic results of two circuits demonstrate the advantage and practicability of the proposed method.

Key words Fault diagnosis, analog circuit, relevance vector machine, feature reduction, classification probability

Citation Gao Ming-Zhe, Xu Ai-Qiang, Tang Xiao-Feng, Zhang Wei. Analog circuit diagnostic method based on multi-kernel learning multiclass relevance vector machine. *Acta Automatica Sinica*, 2019, 45(2): 434-444

当前, 模拟电路广泛应用于通信、控制、导航等电子系统中, 随着对电子系统可靠性需求的不断提高, 模拟电路的故障诊断技术也已成为当前电路测试领域的研究热点^[1]. 统计数据表明, 在数模混合的复杂电子系统当中, 超过 80% 的元件故障发生在模拟电路部分^[2], 然而模拟电路的故障诊断

技术却发展缓慢, 难以达到实际应用的需求. 导致这种现象的原因主要有: 1) 模拟电路的故障现象十分复杂, 任何一个元件的参数超出容差就属故障, 各类软、硬故障及多重并发故障导致了模拟电路的故障状态是无限的, 故障特征可以是连续的^[3-4]; 2) 模拟电路的输入-输出关系十分复杂, 电路响应与元件参数往往呈非线性映射关系, 且电路中还存在非线性元件, 使得实际应用中很难建立电路响应的精确数学模型^[1, 4-5]; 3) 由于各类因素的影响, 模拟电路非故障元件的实际参数值会在标称值上下随机波动, 加之元件的非线性表征误差、测试误差等, 使得诊断过程困难重重^[1, 4-6].

为解决上述关键问题, 近年来国内外许多学者对模拟电路的故障诊断方法开展了研究, 研究成果主要集中于模拟电路的故障特征提取和故障模式分类这两个关键环节上. 在现阶段故障特征提取的研究中, 模拟电路常用的故障特征主要有: 1) 在被测电路 (Circuit under test, CUT) 的内部测试节点直接测量节点电压作为故障特征^[2, 6-8]; 2) 通过直流和交流分析从 CUT 的时频响应中提取的故障特征, 包括峰值增益及对应的频率和相位^[9]、直流输出电压和 3 dB 截止频率等^[10]; 3) 通过信号处理得到的小波特征^[1, 11-12]、信号包络特征^[5]及其他高阶统计量特征 (如峰度、偏度、熵值等)^[1, 13-14]. 在故障模式分类的研究中, 基于机器学习的故障分类方法是当前研究最多的方向, 所用到的算法主要有: 反向传播神经网络 (Backward propagation neural network, BPNN)^[4, 9, 14]、径向基网络 (Radial basis function network, RBFN)^[15]、支持向量机 (Support vector machine, SVM)^[4, 16-17]、超限学习机 (Extreme learning machine, ELM)^[18]等. 此外还有基于故障编码^[5]、类间距离^[19]、贝叶斯法^[16]等的故障分类器. 然而, 上述故障诊断方法存在三点不足: 1) SVM、神经网络等分类算法的输出仅仅是故障样本对应的故障类别标签, 无法输出其他诊断信息, 如故障样本属于各故障类别的概率; 2) 在高维特征样本的分类器设计中, 故障特征的维数约简与分类器建模是分离进行的, 这样就存在约简后输入到分类器的特征与该分类器可能不是最佳匹配的问题^[20]; 3) 诊断实验中采用的故障多样性较少, 难以代表实际应用中模拟电路的故障状况^[4].

2001 年 Tipping^[21]提出的相关向量机 (Relevance vector machine, RVM) 是一种基于贝叶斯框架的机器学习算法, 相比 SVM 具有参数设置简单、稀疏度更高、概率式输出、基函数不受 Mercer 条件限制等优点. 但最初的 RVM 和 SVM 一样是为二分类问题设计的, 在多分类问题中需要建立多个 RVM 分类器. 2010 年牛津大学的 Psorakis 等^[22]在传统 RVM 的基础上提出了直接多分类相关向量机 (Multiclass relevance vector machine, mRVM), 通过采用 Multinomial probit 函数代替传统 RVM 中的 Logistic sigmoid 函数从而将单个模型的二分类推广到多分类, 并且能够给出分类结果的后验概率. 此外, 鉴于 RVM 具有良好的稀疏性, 文献^[20, 23-24]提出利用 RVM 进行特征约简, 通过将线性核建立在原始特征空间并对特征维进行幂变换扩展, 使之能对特征空间进行稀疏, 从而得到最适合该 RVM 分类器的特征向量. 然而幂变换扩展虽然保证了分类性能, 但增加了模型训练的复杂度.

本文针对模拟电路故障诊断中的关键问题, 提出了一种基于多核多分类相关向量机 (Multi-kernel learning multiclass relevance vector machine, MKL-mRVM) 的模拟电路故障诊断方法. 所提方法沿用了文献^[4]中的故障诊断实施

收稿日期 2016-11-23 录用日期 2017-06-22
Manuscript received November 23, 2016; accepted June 22, 2017
武器装备预研基金 (9140A27020214JB14435) 资助
Supported by Weaponry Pre-research Foundation (9140A27020214JB14435)
本文责任编辑 钟麦英
Recommended by Associate Editor ZHONG Mai-Ying
1. 中国人民解放军 91054 部队 北京 102442 2. 海军航空工程学院科研部烟台 264001
1. The Chinese People's Liberation Army 91054 Unit, Beijing 102442 2. Department of Scientific Research, Naval Aeronautical and Astronautical University, Yantai 264001

框架, 首先, 通过故障注入技术来生成实际应用中可能出现的各类电路故障; 然后, 从频率响应中提取出用于诊断的最小模糊度特征 (Minimum ambiguity features, MAF); 最后, 采用 MKL-mRVM 算法进行故障模式分类, MKL-mRVM 能够对所提取的 MAF 的每一维建立非线性核, 在保持原有分类能力的同时, 通过约束核系数实现原始特征空间的稀疏化, 得到一组更适合该分类器的稀疏特征向量, 同时基于贝叶斯框架的 MKL-mRVM 还能够给出诊断结果的后验概率. Sallen-Key 带通滤波电路和 Biquad 低通滤波电路是国际上最常用的两个验证诊断方法性能的基准电路, 本文以这两个电路作为对象, 验证所提方法的实用性.

本文的主要安排如下: 第 1 节介绍了 MKL-mRVM 算法原理及训练流程, 并分析了算法的计算复杂度; 第 2 节介绍了模拟电路大规模故障诊断的实施框架, 包括故障电路仿真、特征提取和故障分类的实现; 第 3 节将所提方法应用到两个 CUT 的故障诊断实验中, 并与其他方法进行了对比; 第 4 节对文章进行了总结.

1 MKL-mRVM 算法原理

1.1 MKL-mRVM 模型

对于训练样本集 $\{\mathbf{x}_i, t_i\}_{i=1}^N$, 其中 $\mathbf{x} \in \mathbf{R}^D$ 为样本观测值、 D 为特征维数、 $t \in \{1, 2, \dots, C\}$ 为观测值对应的类别标签, MKL-mRVM 对该样本集建立多核模型的原理如图 1 所示. 首先, 在样本观测值的每一维特征上建立一个基本核函数; 然后, 通过线性加权得到组合核函数:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \sum_{d=1}^D \beta_d k^d(x_i^d, x_j^d), \beta_d \geq 0, \sum_{d=1}^D \beta_d = 1 \quad (1)$$

其中, k^d 为建立在每一维特征上的基本核函数, β_d 为基本核函数对应的加权系数, β_d 的大小反映了该特征对分类结果的贡献度. β_d 的值在模型训练中求出, 若 β_d 很小 (如 $\beta_d < 10^{-10}$), 则可认为该特征对于分类结果没有贡献, 将其从特征空间中移除.

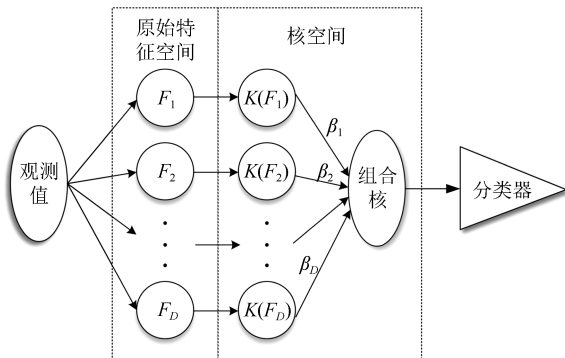


图 1 多核组合原理图

Fig. 1 Combination of multi-kernels

随后建立核矩阵 $\mathbf{K} \in \mathbf{R}^{N \times N}$, \mathbf{K} 的每一列 $\mathbf{k}_n = [k(\mathbf{x}_1, \mathbf{x}_n), k(\mathbf{x}_2, \mathbf{x}_n), \dots, k(\mathbf{x}_n, \mathbf{x}_n)]^T$ 反映了在核函数映射下观测值 \mathbf{x}_n 与其他样本的关联性^[22]. mRVM 引入了辅助变量 $\mathbf{Y} \in \mathbf{R}^{C \times N}$ 来实现直接多分类, \mathbf{Y} 的概率分布与传统 RVM 的回归模型相同, 即 $y_{cn} \sim N(w_c \mathbf{k}_n, 1)$ ^[21], 其中 $\mathbf{W} \in \mathbf{R}^{C \times N}$ 为 MKL-mRVM 模型的权重. \mathbf{Y} 的大小可以看作样本所属类别的排位: 对于观测值 \mathbf{x}_n , y_{cn} 最大值所对应

的类别 c 即为 \mathbf{x}_n 所属的类别, 利用 Multinomial probit 函数^[25] 表示即为

$$t_n = i, \text{ 若 } y_{ni} > y_{nj} \quad \forall j \neq i \quad (2)$$

根据贝叶斯框架, 为保持模型稀疏, 为权重 \mathbf{W} 设置先验分布 $w_{cn} \sim N(0, \alpha_{cn}^{-1})$, 并令先验分布中的超参数 α_{cn} 服从超参数为 γ, ν 的伽马分布. 通过设置 γ, ν 取较小的值, 训练后的权重 \mathbf{W} 被约束在零点附近, 使得模型为由极少数 \mathbf{W} 为非零的相关向量 (Relevance vectors, RV) 组成的稀疏模型. 记超参数 α_{cn} 属于矩阵 $\mathbf{A} \in \mathbf{R}^{C \times N}$, 则采用了多层贝叶斯结构 MKL-mRVM 模型结构由图 2 所示, 其中, β 和 \mathbf{W} 是训练模型所要求解的变量, \mathbf{A}, \mathbf{Y} 是求解过程的中间变量. 由于引入了隐含变量 \mathbf{Y} , 故参数求解采用了期望最大化 (Expectation maximization, EM) 算法.




图 2 MKL-mRVM 模型结构示意图

Fig. 2 Schematic diagram of MKL-mRVM

1.2 MKL-mRVM 的训练

MKL-mRVM 的训练是一个二型最大似然过程, 训练过程迭代更新每个待求参数的值. 在每一步迭代得到 \mathbf{A} 的更新值后, 采用 EM 算法估计参数 $\mathbf{W}, \beta, \mathbf{Y}$ 的更新值, 其中 M 步估计 \mathbf{W}, β , E 步估计 \mathbf{Y} .

首先求令边缘似然函数 $p(\mathbf{Y} | \mathbf{A})$ 最大化的超参数 \mathbf{A} 的估计值. 假定样本 n 在各类别中共用一个超参数值 α_n , 则超参数 \mathbf{A} 的对数边缘似然函数 $\ln p(\mathbf{Y} | \mathbf{A})$ 可写为:

$$L(\mathbf{A}) = \ln \int_{-\infty}^{+\infty} p(\mathbf{Y} | \mathbf{W}) p(\mathbf{W} | \mathbf{A}) d\mathbf{W} = -\frac{1}{2} \sum_{c=1}^C [N \ln 2\pi + \ln |\mathbf{C}| + y_c^T \mathbf{C}^{-1} y_c] \quad (3)$$

其中, $\mathbf{C} = \mathbf{I} + \mathbf{K}^T \mathbf{A}^{-1} \mathbf{K}$, $\mathbf{C} \in \mathbf{R}^{N \times N}$. 文献 [26] 分析了 RVM 训练单步迭代的计算复杂度, 指出训练时将包含了所有样本信息的整个核函数矩阵 \mathbf{K} 代入模型会使算法的计算复杂度很高, 因此采用了向模型中逐个添加样本的增量训练方式来训练模型. 将 \mathbf{C} 进行分解, 得到:

$$|\mathbf{C}| = |\mathbf{C}_{-i}| |1 + \alpha_i^{-1} \mathbf{k}_i^T \mathbf{C}_{-i}^{-1} \mathbf{k}_i| \quad (4)$$

其中, \mathbf{C}_{-i} 为隔离样本 i 之后的 \mathbf{C} , α_i 为样本 i 对应的超参数, \mathbf{k}_i 为样本 i 所在的核函数序列. 由此从 $L(\mathbf{A})$ 中分解出样本 i 对 $L(\mathbf{A})$ 的单独贡献值:

$$l(\alpha_i) = \sum_{c=1}^C \frac{1}{2} \left[\ln \alpha_i - \ln(\alpha_i + s_i) + \frac{q_{ci}^2}{\alpha_i + s_i} \right] \quad (5)$$

其中, $s_i = \mathbf{k}_i^T \mathbf{C}_{-i}^{-1} \mathbf{k}_i$, 为稀疏因子, 反映了 \mathbf{k}_i 与包含在模型中其他核函数的交叠程度; $q_{ci}^2 = \mathbf{k}_i^T \mathbf{C}_{-i}^{-1} y_c$, 为质量因子, 反

映了 \mathbf{k}_i 对于类别 c 的描述能力. 此时求解 $L(\mathbf{A})$ 关于 α_i 的最大值简化为求 $\partial l(\alpha_i)/\partial \alpha_i = 0$ 的解, 可得 $L(\mathbf{A})$ 有唯一最大值当

$$\alpha_i = \frac{Cs_i^2}{\sum_{c=1}^C q_{ci}^2 - Cs_i}, \quad \sum_{c=1}^C q_{ci}^2 > Cs_i \quad (6)$$

$$\alpha_i = \infty, \quad \sum_{c=1}^C q_{ci}^2 < Cs_i \quad (7)$$

由此求得当前超参数矩阵 \mathbf{A} 的更新值 \mathbf{A}_* , 符号 $*$ 代表增量学习过程中模型当前包含样本数为 M 时的参数 ($M \ll N$), 因此 $\mathbf{A}_* \in \mathbf{R}^{M \times M}$, 之后采用 EM 算法计算权重 \mathbf{W} 的最大后验估计值:

$$\hat{\mathbf{W}}_* = (\mathbf{K}_* \mathbf{K}_*^T + \mathbf{A}_*)^{-1} \mathbf{K}_* \hat{\mathbf{Y}}^T \quad (8)$$

其中, $\mathbf{K}_* \in \mathbf{R}^{M \times N}$, $\hat{\mathbf{Y}}$ 为 E 步中隐变量 \mathbf{Y} 期望的估计值. β 的初始值为 $1/D$, 更新值通过求解式 (9) 的二次规划来得到.

$$\begin{aligned} \hat{\beta} = \operatorname{argmin} & \left(\frac{1}{2} \beta^T \Omega \beta - \beta^T \mathbf{f} \right) \\ \text{s. t. } & \beta_d \geq 0, \quad \sum_{d=1}^D \beta_d = 1 \end{aligned} \quad (9)$$

其中, Ω 、 \mathbf{f} 为过程变量, $\Omega_{ij} = \sum_{n,c}^{N,C} \mathbf{w}_c \mathbf{k}_n^i \mathbf{k}_n^j \mathbf{w}_c^T$, $f_i = \sum_{n,c}^{N,C} \mathbf{w}_c \mathbf{k}_n^i \hat{y}_{cn}$.

最后根据 M 步 \mathbf{W} 和 β 的估计值, 给出 E 步中隐变量 \mathbf{Y} 的期望的更新值. 隐变量 \mathbf{Y} 为 $C \times N$ 维锥形截断高斯分布, 对于类别标签为 i 的样本, y_{in} 期望的估计值 \hat{y}_{in} 由式 (10) 更新; 对于其他类别为 c 的样本 ($\forall c \neq i$), y_{cn} 期望的估计值 \hat{y}_{cn} 由式 (11) 更新^[22].

$$\hat{y}_{in} = \hat{\mathbf{w}}_i^T \mathbf{k}_n^{\hat{\beta}} - \left(\sum_{j \neq i} \hat{y}_{jn} - \hat{\mathbf{w}}_j^T \mathbf{k}_n^{\hat{\beta}} \right) \quad (10)$$

$$\hat{y}_{cn} = \hat{\mathbf{w}}_c^T \mathbf{k}_n^{\hat{\beta}} - \frac{E_{\mu} [N_{\mu} (\hat{\mathbf{w}}_c^T \mathbf{k}_n^{\hat{\beta}} - \hat{\mathbf{w}}_i^T \mathbf{k}_n^{\hat{\beta}}, 1) \Phi_{\mu}^{n,i,c}]}{E_{\mu} [\Phi(\mu + \hat{\mathbf{w}}_i^T \mathbf{k}_n^{\hat{\beta}} - \hat{\mathbf{w}}_c^T \mathbf{k}_n^{\hat{\beta}}, 1) \Phi_{\mu}^{n,i,c}]} \quad (11)$$

其中, μ 服从标准高斯分布, $\mu \sim N(0, 1)$, $E_{\mu}[\cdot]$ 代表 μ 服从标准高斯分布时的期望, Φ 代表高斯累积分布, $\Phi_{\mu}^{n,i,c}$ 定义为 $\prod_{j \neq i,c} \Phi(\mu + \hat{\mathbf{w}}_i^T \mathbf{k}_n^{\hat{\beta}} - \hat{\mathbf{w}}_j^T \mathbf{k}_n^{\hat{\beta}})$ [22].

记 \mathbf{X}_* 为包含在模型中的样本集合, 训练开始令所有 $\alpha = \infty$, 此时 \mathbf{X}_* 为空集, 随后随机选择一个样本作为初始样本, 为其超参数 α_i 设置初始值

$$\alpha_i^{\text{initial}} = \frac{C \|\mathbf{k}_n\|^2}{\sum_{c=1}^C \|\mathbf{k}_i^T \mathbf{y}_c\| \|\mathbf{k}_i\|^2 - C} \quad (12)$$

在随后的迭代中, 根据选择的样本计算

$$\theta_i = \sum_{c=1}^C q_{ci}^2 - Cs_i \quad (13)$$

θ_i 大小反映了该样本对模型分类提供的额外信息量^[19]. $\theta_i > 0$ 说明该样本对模型分类有益, 需要将其加入 \mathbf{X}_* 并更新 α_i 的值; $\theta_i < 0$ 说明该样本为冗余样本, 需要将其超参数设置为 $\alpha_i = \infty$ 使其从 \mathbf{X}_* 中剔除.

当所有 $\theta_i > 0$ 的样本均包含在 \mathbf{X}_* 中且相邻两步迭代中超参数的改变值 $|\ln \mathbf{A}^k - \ln \mathbf{A}^{k-1}| < \varepsilon$ (ε 通常取 10^{-12}), 则判定模型收敛.

综上所述, MKL-mRVM 的迭代流程如下:

步骤 1. 初始化各模型参数: 根据目标值 t 初始化 \mathbf{Y} , 随机选择一个样本 i 并根据式 (12) 为其超参数 α_i 赋值, 令其他 $\alpha = \infty$;

步骤 2. 更新超参数 \mathbf{A}_* :

a) 根据式 (13) 计算样本的 θ_i ,

b) 若 $\theta_i > 0$, 则根据式 (6) 更新 α_i ,

c) 若 $\theta_i < 0$ 且 $\alpha_i < \infty$, 则令 $\alpha_i = \infty$;

步骤 3. M 步: 根据式 (8) 更新 $\hat{\mathbf{W}}_*$;

步骤 4. 求解式 (9) 的二次规划更新 $\hat{\beta}$;

步骤 5. E 步: 根据式 (10)、(11) 更新 $\hat{\mathbf{Y}}$;

步骤 6. 再次随机选择一个样本, 重复步骤 2~步骤 5, 直至满足收敛条件, 训练结束.

1.3 MKL-mRVM 的分类结果及计算复杂度

模型训练完成后, 模型参数 \mathbf{W} 和 β 中的大部分值为零, 因此模型在样本空间和特征空间上均是稀疏的. 对于新的输入样本 \mathbf{x}_{new} , MKL-mRVM 的输出为一系列后验概率

$$P(t_{\text{new}} = c | \mathbf{x}_{\text{new}}, \mathbf{W}, \beta) = E_{\mu} \left\{ \prod_{c \neq j} \Phi[\mu + (\mathbf{w}_c - \mathbf{w}_j)^T \mathbf{k}(\mathbf{x}_{\text{new}})] \right\} \quad (14)$$

式 (14) 即新样本属于类别 c 的概率, 而最大概率对应的类别即为新样本所属的类别

$$\hat{t}_{\text{new}} = \operatorname{argmax}_i P(t_{\text{new}} = i | \mathbf{x}_{\text{new}}, \mathbf{W}, \beta) \quad (15)$$

MKL-mRVM 每步迭代的计算复杂度取决于三点: 式 (8) 计算 $\hat{\mathbf{W}}_*$ 时的求逆运算、式 (9) 特征权值 β 的优化以及式 (10)、式 (11) 中 $\hat{\mathbf{Y}}$ 更新值的估算. 其中 $\hat{\mathbf{W}}_*$ 求逆运算的复杂度为 $O(M^3)$, 特征权值 β 优化过程的计算复杂度取决于原始特征维数 D , 隐含变量 $\hat{\mathbf{Y}}$ 更新值的计算复杂度主要取决于样本类别数 C . 此外, 模型训练的迭代步数很大程度上由训练样本的数量决定, 因此模型的总体训练时间取决于样本类别数、训练样本个数以及输入的原始特征维数.

2 模拟电路故障诊断的实施框架

本文所采用的模拟电路大规模故障诊断的实施框架源自文献 [4], 如图 3 所示. 该框架分为故障电路生成、故障数据仿真、故障特征提取和故障模式分类 4 个阶段.

2.1 故障电路生成

模拟电路的故障通常可分为硬故障和软故障. 硬故障 (如开路或短路) 会造成电路拓扑结构的改变, 使电路功能发生很大变化; 软故障指元件参数的实际值超出了容差范围, 从而导致电路工作性能下降.

在故障电路生成阶段中, 我们通过变异操作将多种故障注入到 CUT 中, 得到一系列不同故障模式下的 CUT 变异体, 故障生成所采用的变异操作见表 1. 其中, PCH 为软故障变异操作, 我们设置故障的最小可检测尺度 (Minimum detectable fault size, MD FS) 为 $2t$ (t 为元件的容差值), 采用均匀分布 $U(0.1X_n, X_n - 2t)$ 和 $U(X_n + 2t, 2X_n)$ (X_n 为元件标称值) 来分别表示元件的参数负向偏差 (PCH ↓) 和参

数正向偏差 (PCH ↑); ROP、LRB、GRB 和 NSP 为硬故障变异操作, 采用均匀分布 $U(100\text{ k}\Omega, 1\text{ M}\Omega)$ 和 $U(10\ \Omega, 1\text{ k}\Omega)$ 来分别表示开路状态和桥接状态所用的阻值。

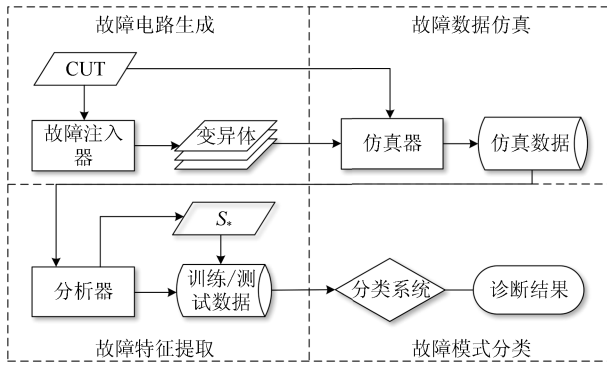


图 3 诊断实施框架示意图

Fig. 3 Implementation framework of the diagnosis

2.2 故障数据仿真

将上一阶段生成的故障 CUT 变异体和初始的无故障 CUT 输入到基于 Pspice 内核的仿真器中, 以扫频信号作为激励, 得到各 CUT 的频率响应曲线的仿真数据。鉴于元件参数存在一定的容差, 我们假设各元件参数服从均值为标称值 X_n , 标准差为 $\sigma = tX_n/3$ 的高斯分布, 随后进行 n 次 Monte Carlo 仿真得到各类 CUT 的仿真数据 n 组。

2.3 故障特征提取

故障的特征值要满足: 1) 在同一故障中相近; 2) 在不同故障间不同^[1]。本文从 CUT 的频率响应曲线中提取了最小模糊度特征 (Minimum ambiguity features, MAF) 作为故障特征。

2.3.1 模糊度模型

设 s 为一故障特征值, 由于 s 的大小会随着元件存在的容差而在一定范围内变动, 故采用 $\varphi(s)$ 来表示某一状态下 s 的概率分布。CUT 所处的状态不同, 对应的分布 $\varphi(s)$ 也不同。对于指定的两类 CUT 故障 f_i 和 f_j , 定义二者在该特征下的模糊度为:

$$a_{i,j} = \int_{s^-}^{s^+} \min[\varphi_i(s), \varphi_j(s)] ds \quad (16)$$

其中, $s^- = \max[s_i^-, s_j^-]$, $s^+ = \min[s_i^+, s_j^+]$ 。如图 4 所示, $a_{i,j}$ 的大小为两条概率密度分布曲线与坐标横轴所围成面积的大小, $a_{i,j} \in [0, 1]$ 取值范围为, 反映了在该特征下两类故障相似程度, $a_{i,j}$ 越小, 越容易将两类故障区分。

在实际计算中, 我们采用核密度估计 (Kernel density estimation, KDE) 方法来求得故障特征值的概率分布函数。

假设 $\{S_i\}_{i=1}^N$ 一组观测到的特征值, 则采用 KDE 得到的概率分布函数为

$$\hat{\varphi}(s) = \frac{1}{Nh} \sum_{i=1}^N K\left(\frac{s - S_i}{h}\right) \quad (17)$$

其中, K 为核函数, h 为平滑参数。




图 4 模糊度示意图

Fig. 4 Schematic diagram of ambiguity

2.3.2 最小模糊度特征

从 CUT 的工作频率中采样得到 m 个离散的频率点作为特征集 $\mathbf{S} = \{s_1, s_2, \dots, s_m\}$, 每类故障都可得到一个基于该特征集的 $m \times n$ 维数据集 $G_{m \times n} = \{G(s_1), G(s_2), \dots, G(s_m)\}$, n 为故障数据仿真时的 Monte Carlo 仿真次数。

对于两类故障 f_i, f_j 及其对应的故障数据集 G_i, G_j , 首先计算二者的各特征下的模糊度, 然后二者的最小模糊度特征可由式 (18) 得到^[4]:

$$M_{i,j} = \operatorname{argmin}_{s_k} a_{i,j}^{s_k} \quad (18)$$

$M_{i,j} \in \mathbf{S}$, 其对应的最小模糊度记作 $a_{i,j}^*$ 。通过各种故障两两之间的组合, 可得到诊断任务所需的最小模糊度故障特征集 \mathbf{S}^* 。

此外, 若 $a_{i,j}^*$ 足够大, 说明 f_i 和 f_j 的频率特性过于相似, 难以被区分开。设置模糊组门限 $\lambda \in [0, 1]$, 若 $a_{i,j}^* > \lambda$, 则故障 f_i 和 f_j 处于同一个模糊组中, 此时两类故障被认定为一类。

2.4 故障模式分类

根据最小模糊度特征集 \mathbf{S}^* 生成训练数据集来训练 MKL-mRVM 分类器, 对于新的样本, MKL-mRVM 分类器能够输出该样本的故障类别、诊断置信度以及最优特征。诊断性能采用了文献 [1] 提出的以下 5 个指标来从多方面进行评价:

表 1 变异操作

Table 1 Mutation operators

操作	名称	描述
PCH	参数改变 (Parameter change)	将元件的指定参数偏离其容差范围
ROP	电阻开路 (Resistive open)	在元件的端口间接入一个阻值极大的电阻以表示开路
LRB	局部电阻桥接 (Local resistive bridging)	在同一元件的两个端口间接入一个阻值极小的电阻
GRB	全局电阻桥接 (Global resistive bridging)	在不同元件的两个节点间接入一个阻值极小的电阻
NSP	节点分裂 (Node splitting)	将一个节点分为两个, 并在分出的节点上接入一个阻值极大的电阻

- 1) 故障漏判率 = $\frac{\text{有故障被诊断为无故障的样本数}}{\text{测试集中有故障的样本总数}}$
- 2) 故障误判率 = $\frac{\text{无故障被诊断为有故障的样本数}}{\text{测试集中无故障的样本总数}}$
- 3) 故障检测率 = $\frac{\text{被诊断为有故障的故障样本数}}{\text{被诊断为有故障的所有样本数}}$
- 4) 故障隔离率 = $\frac{\text{无故障被诊断为有故障的样本数}}{\text{测试集中有故障的样本总数}}$
- 5) 分类准确率 = $\frac{\text{被正确分类的样本数}}{\text{测试集中的样本总数}}$

3 诊断实验

本文的诊断实验包含两个案例: 案例 1 为 Sallen-Key 带通滤波电路的诊断, 注入故障数较少, 主要用于详细分析 MKL-mRVM 算法的诊断性能; 案例 2 为 Biquad 低通滤波电路的诊断, 注入故障数较多, 主要用于验证 MKL-mRVM 算法对大规模故障诊断的可行性。

为比较诊断结果, 将同样采用核函数建模的 SVM 和核超限学习机 (Kernel extreme learning machine, kELM) 应用于故障模式分类中, 三种方法均使用高斯核函数, 并采用 5 折交叉验证法来选取平均验证误差最小的模型参数。其中, SVM 采用一对一 (One-against-one, OAO) 法进行多分类, 一共需要构建 $c(c-1)/2$ 个 SVM 分类器。

仿真实验以 Matlab 2015a 作为实验平台, 所有实验均在 CPU 为 3.3 GHz、内存为 16 GB 的 PC 上运行。

3.1 Sallen-Key 带通滤波电路诊断

3.1.1 实验设计

Sallen-Key 带通滤波电路的电路结构如图 5 所示, 其中中心频率为 25 kHz。仿真实验注入 14 个软故障, 故障描述见表 2, 其中, 无故障状态下各元件参数的变动范围控制在容差的 10% 之内。




图 5 Sallen-Key 带通滤波电路结构图

Fig. 5 Sallen-Key band-pass filter circuit diagram

将从 [0 Hz, 100 kHz] 频率区间中等间隔离散化得到的 1001 个激励信号输入到仿真器中, 设置 Monte Carlo 仿真次数 $n = 200$, 得到每类 200 个故障样本 (共 3000 个)。将故障样本按类别平均分为 2 组, 第一组作为训练样本集, 第二组作为测试样本集。

表 2 Sallen-Key 带通滤波电路故障描述
Table 2 Faults in Sallen-Key band-pass filter

编号	故障描述	标称值	故障值
f0	无故障	-	-
f1	C1 ↑	5 nF	[6 ~ 10] nF
f2	C1 ↓	5 nF	[0.5 ~ 4] nF
f3	C2 ↑	5 nF	[6 ~ 10] nF
f4	C2 ↓	5 nF	[0.5 ~ 4] nF
f5	R1 ↑	5.18 kΩ	[6.22 ~ 10.36] kΩ
f6	R1 ↓	5.18 kΩ	[0.52 ~ 4.14] kΩ
f7	R2 ↑	1 kΩ	[1.2 ~ 2] kΩ
f8	R2 ↓	1 kΩ	[0.1 ~ 0.8] kΩ
f9	R3 ↑	2 kΩ	[2.4 ~ 4] kΩ
f10	R3 ↓	2 kΩ	[0.2 ~ 1.6] kΩ
f11	R4 ↑	4 kΩ	[4.8 ~ 8] kΩ
f12	R4 ↓	4 kΩ	[0.4 ~ 3.2] kΩ
f13	R5 ↑	4 kΩ	[4.8 ~ 8] kΩ
f14	R5 ↓	4 kΩ	[0.4 ~ 3.2] kΩ

3.1.2 频率响应分析

图 6 给出了 f1、f4、f5、f7 4 类故障模式与无故障状态 f0 的频率响应曲线对比, 可以看出在这 4 类软故障中, f5 与 f0 的频率响应特性最为接近, 二者在大部分频率点上存在重合, 使得 f5 的诊断相对较难, 余下三类故障模式与 f0 均在不同的频率区间上可分。

通过各类样本的模糊度分析, 提取出该 CUT 故障的最小模糊度特征为 $S^* = 0, 3.9, 9.0, 10.6, 11.2, 12.5, 16.0, 16.8, 17.0, 19.5, 20.8, 23.9, 25.7, 26.1, 33.4, 34.8, 48.5, 78.2, 91.7, 97.6, 100.0$ (kHz), 共 21 个频率点。

3.1.3 诊断性能比较

表 3 给出了按照所选特征频率点三种方法的诊断性能及时间的比较, 表中的粗体字代表了该项性能指标中的最好结果, 其中测试时间为 1500 个测试样本的平均测试时间。通过表 3 可以看出: 1) 在诊断精度上, MKL-mRVM 方法的精度最高, 分类准确度能够达到 96.40%, SVM 次之, 略高于 kELM; 2) 在训练时间上, kELM 拥有最快的训练速度, SVM 次之, 而 MKL-mRVM 的训练时间高达 381.4s, 这是由于 MKL-mRVM 较多的迭代步数极大地增加了总体训练时间,

表 3 三种方法的诊断性能对比

Table 3 Diagnostic performance comparison of 3 methods

方法	漏判率	误判率	检测率	隔离率	准确率	训练时间/s	测试时间/s
MKL-mRVM	0.0107	0.0200	0.9986	0.9893	0.9640	381.43	3.007E-04
OAO-SVM	0.0071	0.0600	0.9957	0.9928	0.9160	2.2103	1.781E-04
kELM	0.0114	0.0900	0.9935	0.9886	0.9020	0.1287	3.607E-05




图6 几类故障的频率响应曲线

Fig.6 Frequency response curves of faults

图6显示了MKL-mRVM的训练过程,算法在迭代1502步后收敛,迭代步数几乎等于训练样本数;3)在平均测试时间上,kELM依然拥有最快的速度,SVM次之,MKL-mRVM略慢于SVM,这是由于MKL-mRVM在测试中需要计算样本属于各类别的概率,而概率信息对于诊断结果的评价具有重要作用。

在MKL-mRVM的诊断结果中,所有故障模式里诊断正确率最低的是f5,对应的正确率为89%,诊断正确率最高的是f4,对应的正确率为98%,从诊断结果来看,MKL-mRVM对本案例中的各类故障模式均有较好的区分能力,并且诊断正确率和该故障模式与其他故障模式频率响应的相似度相关,频率响应曲线越相似,诊断的正确率越低。

虽然MKL-mRVM的训练时间较长,但其构建分类模型实际用到的样本很少.由图7可以看出,由于采用了增量训练方法,MKL-mRVM在每一步迭代中仅对1500个训练样本中的1个进行学习来更新超参数矩阵 \mathbf{A}_* ,并根据更新后的 α 值来判断该样本是否保留在模型中.当算法收敛时,原有1500个训练样本中的绝大多数样本的超参数 $\alpha = \infty$,仅保留了其中15个 $\alpha < \infty$ 的样本作为相关向量来构建分类模型,因此在实际使用中可通过减少训练样本的数量来减少模型的训练时间.文献[27]提出了一种用于传统RVM的训练样本集精简方法,其基本思想利用Gram-Schmidt算法检测样本之间的线性相关性,从而剔除样本集中的冗余样本点,理论上可以应用到MKL-mRVM中.此外,对于已经训练好的MKL-mRVM分类模型,若有新的故障样本出现,MKL-mRVM能够在原有分类模型的基础上通过增量训练对新样本进行单独学习,通过算法流程的步骤2~5来快速更新模型参数,无需纳入之前的所有样本重训模型,使得MKL-mRVM可以应用到样本序贯输入的在线诊断中。




图7 MKL-mRVM的迭代过程

Fig.7 Diagnostic performance comparison of 3 methods

3.1.4 特征选择及分类置信度分析

MKL-mRVM算法在输入的21个原始故障特征上建立了基本核函数,基本核函数的加权系数 β 可以表示故障特征对分类的重要程度.图8显示了模型训练后加权系数 β 的大小,可以看出,大多数的加权系数都在 10^{-10} 以下,对应的特征为无关特征,将其从模型中剔除,剩下系数较大的7个特征被认为是重要特征,即MKL-mRVM所选择的最能代表故障特点并将各类故障进行区分的频率点最小集合.根据训练结果,本案例的最优特征集为 $\mathbf{S}_{\text{opt}} = 0, 10.6, 11.2, 12.5, 20.8, 23.9, 100.0$ (kHz)。

MKL-mRVM分类器能够输出测试样本属于各类别的后验概率,因此可将分类结果对应的概率大小作为诊断结果的置信度.为分析诊断结果与置信度的关系,我们从正确诊

断的样本和错误诊断的样本中各随机挑选 20 个样本, 所选样本的诊断结果与诊断置信度的关系如图 9 所示. 可以看出, 诊断正确样本的诊断置信度明显高于诊断错误样本的诊断置信度. 在本案例的所有测试样本中, 诊断正确的样本平均诊断置信度达到 0.8505, 而诊断错误的样本平均诊断置信度仅为 0.4103. 因此, MKL-mRVM 所输出的概率信息能够对诊断结果的质量进行评价, 具有一定的实用价值.




图 8 故障特征对应的加权系数值
Fig. 8 The weighting factors of fault features




图 9 诊断结果的置信度
Fig. 9 Confidence of diagnostic results

3.2 Biquad 低通滤波电路诊断

3.2.1 实验设计

Biquad 低通滤波电路的电路结构如图 10 所示. 该电路包含较多的元件数量, 仿真实验共注入各类故障 92 个, 详见表 4, 其中, 软故障 PCH ↓ 和 PCH ↑ 对应的元件参数服从均匀分布 $U(0.1X_n, X_n - 2t)$ 和 $U(X_n + 2t, 2X_n)$, 硬故障中, ROP、NSP 接入的阻值服从均匀分布 $U(100\text{ k}\Omega, 1\text{ M}\Omega)$, LRB、GRB 接入的阻值服从均匀分布 $U(10\ \Omega, 1\text{ k}\Omega)$.

表 4 Biquad 低通滤波电路故障描述
Table 4 Faults in Biquad low-pass filter

编号	故障描述	编号	故障描述	编号	故障描述	编号	故障描述
f0	无故障	f24	ROP (R4, +)	f48	LRB (R4, +, -)	f72	GRB (n2, in)
f1	PCH (C1 ↑)	f25	ROP (R5, +)	f49	LRB (R5, +, -)	f73	GRB (n2, n4)
f2	PCH (C1 ↓)	f26	ROP (R6, +)	f50	LRB (R6, +, -)	f74	GRB (n2, n5)
f3	PCH (C2 ↑)	f27	ROP (R7, +)	f51	LRB (R7, +, -)	f75	GRB (n2, out)
f4	PCH (C2 ↓)	f28	ROP (U1, 1)	f52	LRB (U1, 1, 2)	f76	GRB (n3, in)
f5	PCH (R1 ↑)	f29	ROP (U1, 2)	f53	LRB (U1, 2, 3)	f77	GRB (n3, n5)
f6	PCH (R1 ↓)	f30	ROP (U1, 3)	f54	LRB (U1, 3, 4)	f78	GRB (n3, out)
f7	PCH (R2 ↑)	f31	ROP (U1, 4)	f55	LRB (U1, 4, 5)	f79	GRB (n4, in)
f8	PCH (R2 ↓)	f32	ROP (U1, 5)	f56	LRB (U1, 5, 1)	f80	GRB (n4, out)
f9	PCH (R3 ↑)	f33	ROP (U2, 1)	f57	LRB (U2, 1, 2)	f81	GRB (n5, in)
f10	PCH (R3 ↓)	f34	ROP (U2, 2)	f58	LRB (U2, 2, 3)	f82	GRB (n6, in)
f11	PCH (R4 ↑)	f35	ROP (U2, 3)	f59	LRB (U2, 3, 4)	f83	GRB (n6, n3)
f12	PCH (R4 ↓)	f36	ROP (U2, 4)	f60	LRB (U2, 4, 5)	f84	GRB (n6, n5)
f13	PCH (R5 ↑)	f37	ROP (U2, 5)	f61	LRB (U2, 5, 1)	f85	GRB (n6, out)
f14	PCH (R5 ↓)	f38	ROP (U3, 1)	f62	LRB (U3, 1, 2)	f86	GRB (in, out)
f15	PCH (R6 ↑)	f39	ROP (U3, 2)	f63	LRB (U3, 2, 3)	f87	NSP (n1, [2, 3] [1, 4])
f16	PCH (R6 ↓)	f40	ROP (U3, 3)	f64	LRB (U3, 3, 4)	f88	NSP (n1, [2, 4] [1, 3])
f17	PCH (R7 ↑)	f41	ROP (U3, 4)	f65	LRB (U3, 4, 5)	f89	NSP (n1, [3, 4] [1, 2])
f18	PCH (R7 ↓)	f42	ROP (U3, 5)	f66	LRB (U3, 5, 1)	f90	NSP (n4, [2, 3] [1, 4])
f19	ROP (C1,+)	f43	LRB (C1, +, -)	f67	GRB (n1, 0)	f91	NSP (n4, [2, 4] [1, 3])
f20	ROP (C2,+)	f44	LRB (C2, +, -)	f68	GRB (n1, n3)	f92	NSP (n4, [3, 4] [1, 2])
f21	ROP (R1,+)	f45	LRB (R1, +, -)	f69	GRB (n1, n4)		
f22	ROP (R2,+)	f46	LRB (R2, +, -)	f70	GRB (n1, n5)		
f23	ROP (R3,+)	f47	LRB (R3, +, -)	f71	GRB (n2, 0)		

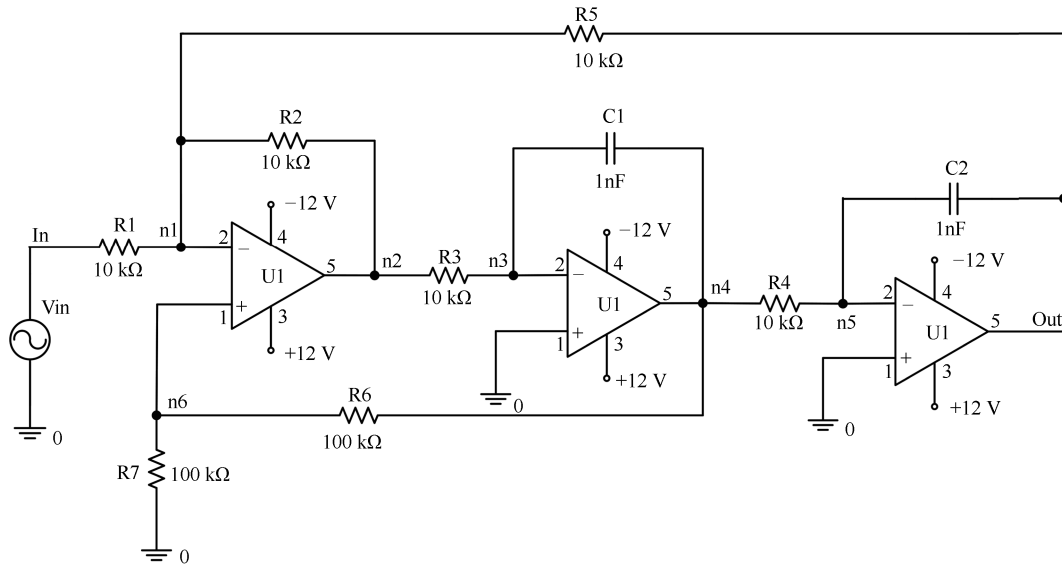


图 10 Biquad 低通滤波电路结构图
Fig. 10 Biquad low-pass filter circuit diagram




图 11 几类故障的频率响应曲线
Fig. 11 Frequency response curves of faults

将从 [1 Hz, 200 kHz] 中等间隔离散化得到的 1000 个激励信号输入到仿真器中, 设置 Monte Carlo 仿真次数 $n = 100$, 得到每类 100 个故障样本 (共 9300 个). 同样按类别将其平均分为 2 组, 分别作为训练样本集和测试样本集.

3.2.2 频率响应分析

图 11 给出了 9 类故障模式与无故障状态 f_0 的频率响应曲线对比, 可以直观的看出 f_5 、 f_{19} 、 f_{43} 、 f_{48} 、 f_{87} 5 类故障在所选频率区间内与 f_0 有很好的可分性, f_1 与 f_0 在部分区间内可分, 而 f_{28} 、 f_{64} 、 f_{77} 与 f_0 的频率响应极为相似, 四者在绝大部分频率点上重合. 根据模糊度分析本案例共提取出 $N_{S^*} = 350$ 个最小模糊度特征.

3.2.3 诊断性能比较

由于许多故障模式的频率响应曲线和无故障状态的频率响应曲线过于相似, 使得分类器根据所选的特征频率点依然难以精确地诊断出每类故障. 因此, 对于表 4 中的各类故障我们设置不同模糊组门限 λ 来给出故障所属的模糊组. 图 12 给出了无故障状态 f_0 所对应的模糊组, 图中 λ 所在圆的内部所有的故障两两互为模糊组, 当 $\lambda = 1$ 时不存在模糊组, 随着 λ 减小, 越来越多故障表现相似的故障类型落入到同一模糊组中, 可以看出图 11 中 f_{28} 、 f_{64} 、 f_{77} 三类难以区分的故障均在 f_0 的模糊组中. 表 5 给出了不同模糊组门限 λ 下三种方法的诊断性能, 在存在模糊组的前提下, 只要诊断结果为实际故障所在模糊组中的任意一种故障我们就假定诊断正确.

通过表 5 可以看出: 1) 当 $\lambda = 1$, 即不考虑模糊组的情况下, 三种方法的分类准确率都比较高, 同时故障误判率也非常高, 这是由于多种故障的频率响应曲线和 f_0 非常接近, 分类器难以将正常状态从多类故障状态中区分出来, 随着 λ 降低, 征兆相似的故障不断落入同一个模糊组中, 在考虑模糊组的情况下, 三种方法的分类准确率也随之上升, 当 $\lambda < 0.5$ 时, MKL-mRVM 的分类准确率能够达到 85% 以上; 2) 在不同模糊组的诊断中, MKL-mRVM 均拥有最高的分类准确率, SVM 次之, kELM 最低, MKL-mRVM 在 $\lambda = 0.3$

时的分类准确率就已经高于 $\lambda = 0.1$ 时 SVM 和 kELM 的分类准确率; 3) kELM 依然拥有最快的训练速度和测试速度, 而 MKL-mRVM 的训练和测试速度最慢, 模型的训练花费了近 6 个小时, 较多的故障类别和特征维数大大增加了 MKL-mRVM 的训练时间.




图 12 不同门限下 f_0 所在的模糊组

Fig. 12 Ambiguity groups of f_0 under different thresholds

3.2.4 采用其他特征的诊断性能

虽然较多的训练样本数以及特征数极大地增加了 MKL-mRVM 的训练时间, 但 MKL-mRVM 从 350 个特征中提取了 47 个作为诊断的最优特征, 由于冗余信息被剔除, MKL-mRVM 的分类准确率明显高于 SVM 和 kELM. 为比较故障特征以及最优化约简对诊断性能的 MKL-mRVM 影响, 表 6 给出了不考虑模糊组 ($\lambda = 1$) 的情况下分别采用高阶统计量 (峰值结合偏度)^[13]、电路规格参数 (峰值增益和 3 dB 截止频率)^[14] 以及未经约简的 MAF 作为特征时 mRVM 的诊断性能 (由于不需要特征约简故采用 mRVM), 可以看出, 相比本文提出的诊断方法, 高阶统计量和电路规格两种特征虽然计算复杂度小, 但诊断精度却远远低于本文方法, 难以应对大规模故障诊断的需求, 而未经约简的 MAF 虽然使得训练时间得以缩短, 但诊断精度不及本文所提方法. 此外, 尽管本文

表 5 三种方法的诊断性能对比

Table 5 Diagnostic performance comparison of 3 methods

方法	λ	漏判率	误判率	检测率	隔离率	准确率	训练时间 (s)	测试时间 (s)
MKL-mRVM	1	0.0165	0.9200	0.9899	0.9834	0.6069		
	0.7	0.0235	0.3400	0.9962	0.9765	0.7796		
	0.5	0.0215	0.0600	0.9993	0.9893	0.8602	2.0436E-05	1.7472
	0.3	0.0132	0.0200	0.9997	0.9867	0.9202		
	0.1	0.0132	0.0200	0.9997	0.9867	0.9406		
OAO-SVM	1	0.0254	0.9600	0.9894	0.9746	0.5303		
	0.7	0.0608	0.4400	0.9950	0.9656	0.6905		
	0.5	0.0196	0.0400	0.9996	0.9804	0.8009	4.6002E-02	0.1628
	0.3	0.0167	0.0400	0.9996	0.9833	0.8598		
	0.1	0.0167	0.0400	0.9996	0.9833	0.9191		
kELM	1	0.0402	0.9800	0.9890	0.9598	0.5006		
	0.7	0.0437	0.4800	0.9941	0.9563	0.6301		
	0.5	0.0243	0.0800	0.9991	0.9757	0.7623	1.9524	1.4584E-04
	0.3	0.0191	0.0600	0.9996	0.9809	0.8271		
	0.1	0.0191	0.0400	0.9996	0.9809	0.9013		

所提方法提高了故障诊断的准确率,然而当充分考虑现实中可能存在的各类故障时,上述方法都难以取得比较理想的诊断精度,在大规模故障诊断中依然存在着许多模糊组。

表 6 其他特征的诊断性能

Table 6 Diagnostic performance of other features

故障特征	分类算法	训练时间 (s)	分类准确率
高阶统计量	mRVM	6.1434E-03	0.2046
电路规格参数	mRVM	5.6213E-03	0.3871
MAF	mRVM	1.7324E-04	0.5113
MAF	MKL-mRVM	2.0436E-05	0.6069

4 结论

本文提出了一种基于 MKL-mRVM 的模拟电路故障诊断方法,相比已有方法,本文方法的主要贡献有: 1) 通过故障注入生成了参数连续的软故障和各类硬故障,并考虑了非故障原件的参数容差,使故障样本更贴合实际情况; 2) MKL-mRVM 能够约简原始故障特征,减少冗余信息,使得故障诊断结果的准确度更高; 3) 基于贝叶斯框架的 MKL-mRVM 分类算法能够给出诊断结果的置信度。然而模拟电路的故障诊断是一个复杂的问题,本文所提方法在应对大规模故障诊断时依然达不到理想的诊断精度,诊断结果依然存在着较多的模糊组,并且 MKL-mRVM 用于诊断时的训练时间较长,下一步的研究工作可集中于提高 MKL-mRVM 的训练效率。

References

- Sarathi Vasan A S, Long B, Pecht M. Diagnostics and prognostics method for analog electronic circuits. *IEEE Transactions on Industrial Electronics*, 2013, **60**(11): 5277–5291
- Ao Y C, Shi Y B, Zhang W, Li Y J. An approximate calculation of ratio of normal variables and its application in analog circuit fault diagnosis. *Journal of Electronic Testing Theory & Applications*, 2013, **29**(4): 555–565
- Tadeusiewicz M, Halgas S. A new approach to multiple soft fault diagnosis of analog BJT and CMOS Circuits. *IEEE Transactions on Instrumentation & Measurement*, 2015, **64**(10): 2688–2695
- Tang X F, Xu A Q. Practical analog circuit diagnosis based on fault features with minimum ambiguities. *Journal of Electronic Testing*, 2016, **32**(1): 83–95
- Liu Z B, Liu T M, Han J W, Bu S H, Tang X J, Pecht M. Signal Model-based fault coding for diagnostics and prognostics of analog electronic circuits. *IEEE Transactions on Industrial Electronics*, 2016, **64**(1): 605–614
- Jing Y P, Yuan L F, He Y G. An analog circuit diagnosis method based on Adaptive-Kernel ICA. *International Journal of Electronics and Electrical Engineering*, 2016, **4**(2): 116–120
- Luo H, Wang Y R, Lin H, Jiang Y Y. A new optimal test node selection method for analog circuit. *Journal of Electronic Testing*, 2012, **28**(3): 279–290
- Tan H, Peng M F. Minimization of ambiguity in parametric fault diagnosis of analog circuits: a complex network approach. *Applied Mathematics & Computation*, 2012, **219**(1): 408–415
- Kumar A, Singh A P. Fuzzy classifier for fault diagnosis in analog electronic circuits. *ISA Transactions*, 2013, **52**(6): 816–824
- Litovski V, Andrejević M, Zwolinski M. Analogue electronic circuit diagnosis based on ANNs. *Microelectronics Reliability*, 2006, **46**(8): 1382–1391
- Lin H J, Han J R, Zhang X H, Xu J B, Liu Y F. The research on fusion and diagnosis method of multi soft fault of nonlinear analog circuit. *International Journal of U & E Service, Science and Technology*, 2015, **8**(11): 191–198
- Cui J, Wang Y R. A novel approach of analog circuit fault diagnosis using support vector machines classifier. *Measurement*, 2011, **44**(1): 281–289
- Xie T, He Y G. Fault diagnosis of analog circuit based on high-order cumulants and information fusion. *Journal of Electronic Testing*, 2014, **30**(5): 505–514
- Yuan L F, He Y G, Huang J Y, Sun Y C. A new neural-network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor. *IEEE Transactions on Instrumentation & Measurement*, 2010, **59**(3): 586–595
- Kowalewski M. Two-center radial basis function network for classification of soft faults in electronic analog circuits. In: *Proceedings of the Instrumentation and Measurement Technology Conference*. Warsaw, Poland: IEEE, 2007. 1–6
- Stratigopoulos H G, Mir S, Hora C, Kruseman B. Diagnosis of local spot defects in analog circuits. *IEEE Transactions on Instrumentation & Measurement*, 2012, **61**(10): 2701–2712
- Zhang C L, He Y G, Yuan L F, He W, Xiang S, Li Z G. A novel approach for diagnosis of analog circuit fault by using GMKL-SVM and PSO. *Journal of Electronic Testing*, 2016, **32**(5): 531–540
- Yu W X, Sui Y B, Wang J N. The faults diagnostic analysis for analog circuit based on FA-TM-ELM. *Journal of Electronic Testing*, 2016, **32**(4): 459–465
- Han H, Wang H J, Tian S L, Zhang N. A new analog circuit fault diagnosis method based on improved mahalanobis distance. *Journal of Electronic Testing*, 2013, **29**(1): 95–102
- Xu Dan-Lei, Du Lan, Liu Hong-Wei, Hong Ling, Li Yan-Bing. Joint feature selection and classification design based on variational relevance vector machine. *Acta Automatica Sinica*, 2011, **37**(8): 932–943
(徐丹蕾, 杜兰, 刘宏伟, 洪灵, 李彦兵. 一种基于变分相关向量机的特征选择和分类结合方法. *自动化学报*, 2011, **37**(8): 932–943)
- Tipping M E. Sparse Bayesian learning and the relevance vector machine. *Journal of Machine Learning Research*, 2001, **1**(3): 211–244
- Psorakis I, Damoulas T, Girolami M A. Multiclass relevance vector machines: sparsity and accuracy. *IEEE Transactions on Neural Networks*, 2010, **21**(10): 1588–1598
- Carin L, Dobeck G J. Relevance vector machine feature selection and classification for underwater targets. In: *Proceedings of the OCEANS*. San Diego, USA: IEEE, 2003. 1110–1110

- 24 Li D F, Hu W C. Feature selection with RVM and its application to prediction modeling. *Lecture Notes in Computer Science*. Berlin: Springer-Verlag, 2006. 1140–1144
- 25 Girolami M, Rogers S. Variational Bayesian multinomial probit regression with Gaussian process priors. *Neural Computation*, 2006, **18**(8): 1790–1817
- 26 Tipping M E, Faul A C. Fast marginal likelihood maximisation for sparse bayesian models. In: *Proceedings of the 9th International Workshop on Artificial Intelligence and Statistics*. Key West, Florida, USA: Miketipping, 2003. 3–6
- 27 Yang Z R. A fast algorithm for relevance vector machine. In: *Proceedings of the International Conference on Intelligent Data Engineering and Automated Learning*. Burgos, Spain: Springer, 2006. 33–39
- 高明哲 中国人民解放军 91054 部队工程师. 分别于 2011 年、2013 年和 2017 年获得海军航空工程学院信息与通信工程学士学位、硕士学位和博士学位. 主要研究方向为模式识别, 电子设备的故障诊断与预测. 本文通信作者. E-mail: mac7872@163.com
(**GAO Ming-Zhe** Engineer at the Chinese People's Liberation Army 91054 Unit. He received his bachelor, master, and Ph.D. degrees in information and communication engineering from Naval Aeronautical and Astronautical University in 2011, 2013, and 2017, respectively. His research interest covers pattern recognition, fault diagnosis, and prediction of electronic equipment. Corresponding author of this paper.)
- 许爱强 海军航空工程学院科研部教授. 主要研究方向为电子信息系统的测试与故障诊断技术.
E-mail: hy_xuaiqiang@163.com
(**XU Ai-Qiang** Professor in the Department of Scientific Research, Naval Aeronautical and Astronautical University. His research interest covers testing and diagnosis of electronic information system.)
- 唐小峰 海军航空工程学院科研部博士研究生. 分别于 2007 年和 2010 年获得国防科技大学航天工程学士学位和武器系统与运用工程硕士学位. 主要研究方向为电路的测试、故障建模和故障诊断.
E-mail: vivorimage@126.com
(**TANG Xiao-Feng** Ph.D. candidate in the Department of Scientific Research, Naval Aeronautical and Astronautical University. He received his bachelor and master degrees in aerospace engineering and weapon systems and utilization engineering from National University of Defense Technology in 2007 and 2010, respectively. His research interest covers circuit test and diagnosis, fault modeling.)
- 张伟 海军航空工程学院科研部博士研究生. 分别于 2012 年和 2014 年获得海军航空工程学院信息与通信工程学士学位和硕士学位. 主要研究方向为核方法, 电子设备的智能故障诊断.
E-mail: hjhy1989@163.com
(**ZHANG Wei** Ph.D. candidate in the Department of Scientific Research, Naval Aeronautical and Astronautical University. He received his bachelor and master degrees in information and communication engineering from Naval Aeronautical and Astronautical University in 2012 and 2014, respectively. His research interest covers kernel methods, intelligent fault diagnosis of electronic equipment.)