

基于 HMM 的模拟电路故障诊断方法

许丽佳¹⁾, 黄建国²⁾, 王厚军²⁾

¹⁾(四川农业大学信息与工程技术学院 雅安 625014)

²⁾(电子科技大学自动化学院 成都 610054)

(lijiaxul3@163.com)

摘 要: 针对电子系统,尤其是模拟电路的早期故障诊断是重要却又困难的问题,提出一种基于隐马尔可夫模型(HMM)的模拟电路早期故障诊断方法.首先提取出模拟电路的电压特征;然后用改进的线性判别分析法(LDA)对电压特征进行降维并消除其冗余,采取一些改进措施来消除 LDA 的不足;最后将改进 LDA 提取的特征构成多个观测序列并用于训练和测试 HMM,以实现模拟电路的早期故障诊断.将该方法与其他方法进行比较的实验结果表明,其具有良好的故障识别能力.

关键词: 隐马尔可夫模型;线性判别分析;特征提取;故障诊断

中图法分类号: TP277

A Method for the Diagnosis of the Incipient Faults in Analog Circuits Using HMM

Xu Lijia¹⁾, Huang Jianguo²⁾, and Wang Houjun²⁾

¹⁾(School of Information & Engineering Technology, Sichuan Agriculture University, Ya'an 625014)

²⁾(School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 610054)

Abstract: Diagnosis of incipient faults for electronic systems especially for analog circuits, is important yet difficult. The paper proposes a new method using HMM for the diagnosis of the incipient faults in analog circuits. First, the voltage feature vectors are extracted from analog circuits; Then, the improved LDA is used to reduce dimensionality of the voltage feature vectors and remove their redundancy, where the performance of LDA is improved through overcoming shortcomings existing in original LDA; Finally, the processed feature vectors are used to form the observation sequences, which are sent to HMM to accomplish the diagnosis of the incipient faults. The experimental results on performance of the proposed method indicated that the method has better recognition capability than the other methods.

Key words: hidden Markov model; linear discriminant analysis; feature extraction; fault diagnosis

电子系统由电子元件按一定的电路原理组成,其中多数为数字电路,但约有 80% 的故障发生在模拟电路中,因此模拟电路的故障诊断尤其重要.模拟电路的故障诊断始于 20 世纪 60 年代,对其的理论研究是从网络元件参数可解性^[1]开始的,常用的有故障字典法和参数辨识法,但电路系统故障的多样

性、元件参数的容差性以及结构的复杂性,使得对于模拟电路的故障诊断的研究发展很缓慢.20 世纪 90 年代后,随着人工智能技术的发展,模糊理论、神经网络、小波技术以及支持向量机都相继应用于该领域并取得了良好的效果^[2-7],但上述方法都是在硬故障诊断中(即元件短路或断路)效果显著,将其用于

软故障诊断时在元件参数变化较大的情况下才具备较好的诊断能力,而上述方法对电路早期故障的研究很少。目前,多数文献设置模拟电路软故障的故障元件参数几乎都偏离正常容差范围的 50% 以上,测点处的故障征兆(即被测参数)已很明显,此时的电路故障常常会导致电子系统部分功能失效甚至整个系统失灵。对此,本文主要研究模拟电路的早期软故障,即故障元件虽已超出容差范围但其偏离在正常容差范围的 40% 以内甚至更小(依据其正常容差范围的大小来确定),对那些能检测出异常但还未导致电子系统完全失效的情况,若此时就能诊断并替换故障元件将会防患于未然。然而,早期故障的征兆辨别难度较大,尤其是模拟电路更是如此。

本文提出一种特征提取算法,尝试用改进的线性判别分析(linear discriminant analysis, LDA)对电路的频响电压进行降维提取,以消除冗余并减轻分类器的计算负担,用隐马尔科夫模型(hidden Markov model, HMM)作分类器来识别电路系统的早期故障。与其他方法进行比较的实验结果验证了该方法的有效性。

1 LDA 和 HMM 的基本原理

1.1 LDA 原理及其改进

LDA 是一种广泛应用于人脸识别^[8]的特征提取法,其目的是消除特征冗余和降低其维数以减轻分类器负担。LDA 运用 Fisher 判别,旨在寻找一个线性变换(即投影方向),原始数据经此变换映射到特征子空间后使得类间散度与类内散度之比最大,这样不仅减少了输入向量的维数而且提高了分类精度。Fisher 准则为

$$J(\eta_{\text{opt}}) = \arg \max \frac{\eta^T S_b \eta}{\eta^T S_w \eta} \quad (1)$$

其中, S_b 是类间散度矩阵,

$$S_b = \sum_{j=1}^c (m_j - m)(m_j - m)^T, \quad m = \frac{1}{n} \sum_{i=1}^n x_i \quad (2)$$

S_w 是类内散度矩阵

$$S_w = \sum_{j=1}^c \sum_{i=1}^{n_j} (x_i^j - m_j)(x_i^j - m_j)^T, \quad m_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_i^j \quad (3)$$

x_i^j 是第 j 个类的第 i 个向量, n_j 是第 j 类的向量总数。

通过计算 $S_w^{-1} S_b$ 的特征值并按从大到小排序,可获得特征空间中的 q 个主要分量以实现降维。但 LDA 存在 2 个问题: 1) 小样本问题, 导致类内散度矩阵 S_w 不可逆; 2) 边缘类的存在造成投影空间中

近邻样本重叠的问题, 即过度强调边缘类与其他类的类间距离大小, 导致在投影空间中近邻类样本的重叠。

针对小样本问题, 本文采用 Ye 等^[9]提出的方法来解决小样本导致 S_w 非奇异的问题。该方法将 LDA 与广义奇异值分解相结合, 它不要求类内散度矩阵必须是非奇异阵, 而是对 $S_i^+ S_b$ 计算其广义特征值分解。若总散度矩阵 S_t 是非奇异的, 那么就等效于对 $S_i^{-1} S_b$ 进行特征值分解; 若 S_w 和 S_t 均是非奇异阵, 则有

$$\Phi = \arg \max_{\Phi} \frac{|\Phi^T S_b \Phi|}{|\Phi^T S_w \Phi|} \Leftrightarrow \Phi = \arg \max_{\Phi} \frac{|\Phi^T S_b \Phi|}{|\Phi^T S_t \Phi|} \quad (4)$$

由式(4)获得的映射矩阵就等于由 LDA 获得的映射矩阵。尽管该方法可以解决 S_w 阵的非奇异问题, 但从式(1)中可知, 映射矩阵的计算过分强调起主导作用的边缘类与其他类的类间距离大小, 导致在投影空间中近邻类样本的重叠, 使那些近邻类更不易区分。为了消除边缘类在选择特征映射向量的影响, 类间散度矩阵重新定义^[10]为

$$\tilde{S}_b = \sum_{i=1}^{c-1} \sum_{j=i+1}^c p_i p_j w(\Delta_{ij}) (\mu_i - \mu_j)(\mu_i - \mu_j)^T \quad (5)$$

其中, p_i, p_j 是类 i 和 j 的先验概率; Δ_{ij} 是 C_i 和 C_j 类均值向量间的欧氏距离,

$$\Delta_{ij} = \sqrt{(\mu_i - \mu_j)^T (\mu_i - \mu_j)};$$

定义 $w(\Delta_{ij}) = (\Delta_{ij})^{-2d}$, $d=1, 2, 3, \dots$, 此处设置 $d=$

1. 从式(5)可知, $\tilde{S}_b$ 只考虑类间距离的方向而忽略其距离的大小, 这就有效地解决了边缘类对影响选取投影方向的问题。总散度矩阵重新定义为 $\tilde{S}_t = \tilde{S}_b + S_w$ 。至此, 同时改进了对 LDA 2 个缺点。

1.2 HMM 的基本原理

HMM 是 19 世纪 60 年代末由 Baum-Welch 等人提出, 其广泛用于语音识别^[11]、工业过程故障检测^[12]和机电系统状态监控^[13]的双重随机过程, 也逐渐用于电子系统的状态监测^[14], 有强大的时序模式分类能力。它主要解决 3 类问题: 1) 评估问题。计算由给定模型 λ 产生观测序列 O 的概率 $P(O|\lambda)$; 2) 解码问题。对给定模型 λ 和观测序列 O , 求可能性最大的状态序列 S ; 3) 学习问题。对给定观测序列 O , 求在最大似然度下学习模型参数。

HMM 常用五元组来描述 $(\Omega_x, \Omega_o, A, B, \pi)$ 。 $\Omega_x = \{q_1, \dots, q_N\}$ 表示状态的有限集合; $\Omega_o = \{v_1, \dots, v_M\}$ 表示观测值的有限集合; $A = \{a_{ij}\}$, 其中 $a_{ij} =$

$P(s_{t+1}=q_j | s_t=q_i)$ 表示状态一步转移概率阵; $B=\{b_{ik}\}$, 其中 $b_{ik}=P(O_t=v_k | s_t=q_i)$ 表示输出概率阵; $\pi=\{\pi_i\}$, $\pi_i=P(s_1=q_i)$ 表示初始状态分布概率。HMM 常记为 $\lambda=\{\pi, A, B\}$ 。常用前向-后向算法^[15]来计算由 λ 产生观测序列 O 的概率, 用 Viterbi 算法^[15]来计算由 λ 和给定观测序列 O 确定最佳状态序列及其概率, 用 Baum-Welch 算法^[15]通过观测序列在最大似然估计概率下训练获得最佳 λ , λ 适合与否则会影响 HMM 的监测能力。Baum-Welch 算法是先任意给定一个初始 λ_0 。以及观测序列 O , 通过前向-后向算法计算 $P(O|\lambda_0)$, 并由 EM 算法迭代训练获得新模型参数 λ_{new} 。

图1所示为HMM的结构框图,可以看出,HMM由可观测过程(观测信号)和不可观测过程(即隐含状态)组成,故障形成过程就是一个典型的双重随机过程,它是不能直接观测的,但可以通过若干监测信号来感知和辨识故障。HMM的训练算法是先任意给定一个初始模型 λ_0 , 基于 λ_0 以及观测序列 O , 由前向-后向算法计算得到 $P(O|\lambda_0)$; 然后通过 EM 算法训练 HMM 来获得新的模型参数 λ , 若 $P(O|\lambda)-P(O|\lambda_0)<\text{阈值}$, 则训练结束, 否则令 $\lambda=\lambda_0$, 并反复训练, 一直到收敛为止。为增加 HMM 的稳定性, 本文用多组观测序列进行训练。




图1 HMM 的结构框图

2 故障诊断系统的设计

将 HMM 应用于模拟电路的早期故障诊断的详细流程分为训练过程和测试过程两部分。

选取激励信号源为 PSPICE 软件中 Source. olb 库中的 VAC 信号。电子系统发生单类故障的概率是总故障的 70%~80%，故本文只考虑模拟电路的单类故障，并通过对其进行多次 Monte-Carlo 仿真来提取故障特征：故障态时，任意时刻仅一个元件在其故障范围内随机取值，其余元件均在各自的容差

范围内随机变化；正常态时，所有元件都在各自的容差范围内随机变化。设电路共有 $C+1$ 类状态（其中故障态为 C 类，外加正常态），训练过程步骤如下：

Step1. 在电路的每类状态下，连续 N 次输入给定的激励信号，在电路的测点处以一定频率采集来获得频响电压波形，在该波形图中提取各测试频率所对应的频响电压值 $[V_{f_1}, \dots, V_{f_i}]$ ，其中 f_i 表示各测试频率，从而构成 N 个高维电压特征向量。

Step2. 采用改进的 LDA 对所有状态下的电压特征向量降维，提取并保留相应的映射矩阵 W_{LDA} ，以获得每类工作状态的 N 个低维特征向量。

Step3. 对每类状态的 N 个低维特征向量进行归一化处理，设 Q 为输入数据， $\hat{Q}$ 是归一化后的数据，则两者的关系为

$$\hat{Q} = \frac{2(Q - \min(Q))}{(\max(Q) - \min(Q))} - 1.$$

Step4. 选择任意 k 个已归一化处理后的特征向量构成一组观测序列，从而每类状态下均获得 M 组观测序列 ($M=N/k$)， k 称为观测序列长度。将各类状态的 M 组观测序列用于训练各自的 HMM，共需训练 $C+1$ 个 HMM。

测试过程步骤如下：

Step1. L 次输入给定的激励信号，采用同样的方法获得 L 个高维电压特征向量 ($L \ll N$)。

Step2. 用 W_{LDA} 对 L 个高维电压特征向量进行映射，以此得到 L 个低维特征向量。

Step3. 将上述 L 个低维特征向量构成一组测试序列并进行归一化处理，其中 L 称为测试序列长度。

Step4. 将归一化后的测试序列输入已训练后的 $C+1$ 个 HMM，计算得到各个似然概率值 $P(O|\lambda_0), P(O|\lambda_1), \dots, P(O|\lambda_C)$ ，最大似然概率值对应的 HMM 决定电路的故障类型。

3 实 例

3.1 实验 1

图2所示的电路是一个二次高通滤波器^[5]，分析得知该电路的转折频率为 10 kHz，其中电阻的容差为 $\pm 5\%$ ，电容的容差为 $\pm 10\%$ ，选择 $R_1, R_2, R_3, R_4, C_1, C_2$ 作为故障元件，每个元件参数都有减小和增大 2 类故障，外加电路正常态共有 13 类状态。依据电路各元件的容差范围设置其早期故障范围： R 的变化范围为 $[-15\%, -5\%) \cup [-5\%, 5\%) \cup (-15\%, -5\%]$ ， C 的变化范围为 $[-20\%, -10\%) \cup [-10\%, 10\%) \cup (10\%, 20\%]$ 。故 R (或 C) 的变化范围可划分为减小、正常与增大，用 $\downarrow$ 和 $\uparrow$ 分别表示减小和增大 2 类软故障。图2中， $R_1=R_2=R_3=6.2\text{ k}\Omega$ ， $R_4=1.6\text{ k}\Omega$ ， $R_5=5.1\text{ k}\Omega$ ， $R_6=10\text{ k}\Omega$ ； $C_1=C_2=5\text{ nF}$ 。




图 2 高通滤波电路

考虑转折频率附近的频率所对应的输出电压随参数变化较敏感,本文实验中选取 500 Hz,750 Hz,900 Hz,1 kHz,1.5 kHz,2 kHz 和 3 kHz 作为测试频率,激励源 VAC 的幅值置为 2 V,幅角为 0°,电路输出作为测点.从电路的输出电压波形中获取各测试频率对应的 7 个频响电压值并将之作为一个电压特征向量,多次 Monte-Carlo 仿真获得每类状态的 600 个电压特征向量,各取一半特征向量作为训练样本和测试样本.

由于电路信号的连续性和状态的不可逆性,选择无跳跃的左右型连续 HMM 较合适,选取隐含状态数为 10,电路系统在初始时处于正常态,故初始状态概率置为 $\pi=[1,0,0,\cdots,0]$.一般认为电路处于原有状态和转移到下一个状态的概率是相同的,故设置 $A=[0.5,0.5,0,\cdots,0;0,0.5,0.5,0,\cdots,0;0,\cdots,0,0,1]$.HMM 训练的精度受初始参数影响较大,尤其是观测阵 B 的初始值, B 的初始值可由 K 均值算法迭代多次来获得,状态的观测概率由 3 个高斯概率密度函数联合决定

$$b_j(X) = \sum_{k=1}^n c_{jk} N(X, \mu_{jk}, \Sigma_{jk}) \tag{6}$$

其中, $N(\cdot)$ 为多维高斯概率密度函数, μ_{jk} 为均值矢量, Σ_{jk} 为方差矩阵, n 为组成 $b_j(X)$ 的混合概率密度函数个数, c_{jk} 为组合系数.

HMM 对应的是观测序列而不是单个特征向量,尤其是早期的故障态更应当以多次观测值来判断电路的故障类型,设置各类状态的训练序列与测试序列的长度均为 10.分别用改进 LDA、主成分分析(principal component analysis,PCA)对原始电压特征降维,并将处理后的特征和原始电压特征用来训练 HMM,对应的测试样本用来检验其故障识别

能力.LDA 降维后的特征维数量为 4,PCA 降维后的特征维数量为 6,实验结果如表 1 所示.

表 1 各类特征与 HMM 结合的故障识别率 %

类别	原始特征	PCA 特征	改进 LDA 特征
正常态	98.67	97.33	99.33
$R_1 \uparrow$	100.00	100.00	100.00
$R_1 \downarrow$	92.67	96.67	95.33
$R_2 \uparrow$	96.67	98.00	97.33
$R_2 \downarrow$	99.33	100.00	100.00
$R_3 \uparrow$	96.00	96.67	98.00
$R_3 \downarrow$	99.33	100.00	100.00
$R_4 \uparrow$	86.00	86.00	82.67
$R_4 \downarrow$	75.33	73.33	81.33
$C_1 \uparrow$	100.00	100.00	100.00
$C_1 \downarrow$	100.00	100.00	100.00
$C_2 \uparrow$	95.33	93.33	97.33
$C_2 \downarrow$	89.33	95.33	96.67
平均值	94.51	95.13	96.00

从表 1 可知,改进 LDA 提取的特征包含了最多的分类信息,因此由该类特征训练的 HMM 具有最高的故障识别率.这是因为 PCA 主要侧重于最小均方误差最小的信号重构理论,是一种无监督的降维提取法,提取过程中没有考虑各类特征类别信息,而改进 LDA 提取的特征更有利于分类.

在每类状态的训练数据和训练序列不变的情况下,选取测试序列长度 L 分别为 6~10,各类特征应用于 HMM 获得的平均故障识别率如表 2 所示.从表 2 可知,随着 L 的减小,故障识别率也在下降,但改进 LDA 提取的特征应用于 HMM 具备最好的识别能力.为了考察训练特征数与故障识别率能力的

关系,设置每类状态的训练数据个数为 180~300,训练和测试序列长度仍为 10,将数据部分重叠使训练序列仍为 30 组,实验结果如表 2 所示.从表 2 可知,训练数据的减少并没有使故障识别率发生较大的变化,说明本文方法在训练数据较少时也具有良好的故障识别能力.

表 2 不同测试序列长度和训练数据下的故障识别率 %

	测试序列长度					训练数据个数				
	6	7	8	9	10	180	210	240	270	300
原始特征	88.21	89.90	92.72	93.64	94.51	94.87	94.23	94.27	94.70	94.51
PCA 特征	88.97	91.23	93.23	92.51	95.13	95.00	94.70	94.53	94.02	95.13
改进 LDA 特征	90.10	92.35	93.08	94.21	96.00	95.00	95.77	95.21	95.77	96.00

已有一些文献^[3-7,16-17]对模拟电路的故障诊断进行了研究,其中 BP 网络是应用于模拟电路故障诊断最广泛也是最成功的工具.在 P4 2.13 GHz CPU, 512 MB 内存和 Windows XP 操作系统环境下,训练和测试数据个数均为 300,训练精度设为 0.01,将本文方法与文献^[5-7,16-17]的方法进行比较,实验结果如表 3 所示.其中, $n=3$ 表示测点数, $L=6$ 为测试序列长度, K 表示在某一测点测试数据所需要的成本.

表 3 实验 1 中各类故障诊断方法的对比

方法	故障识别率/%	运行时间/s	测试成本
文献[5]	48.17	28.29	K
文献[6]	8.43	41.61	K
文献[7]	9.18	37.24	K
文献[16]	62.35	101.62	$K \times (1+n)$
文献[17]	48.13	45.10	K
本文方法	90.10	54.75	$K \times L$

本文对上述方法进行了 3 个方面的性能比较:

1) 故障识别能力.从表 3 可知,本文方法的故障识别能力远远超过其他方法.由于其他方法是采用将各类特征(如小波特征^[5]、小波包分解+PCA 提取的特征^[6]、ARMA 特征^[7]、复合特征^[16])应用于 BP 网络,或是采用将电压特征应用于径向基神经网络^[17]来进行故障诊断,实验结果表明,无论是选取何种类型的特征应用于 BP 网络或径向基神经网络,获得的识别率都比较低,因此通过改变特征提取的方法来提高神经网络对电路早期故障的识别能力是行不通的.神经网络对电路的早期故障识别率低的原因在于早期故障特征变化较小,仅依据一次的观测值(即一个特征向量)很难辨识,而 HMM 一次接受的是一组观测序列(即连续几次观测值构成),因而可对早期故障准确的辨识.文献^[16]由于采用融合的故障诊断方法,因此有略好的识别能力.

2) 运行时间.每类状态都要训练对应的 HMM,因此状态类越多,需要训练的 HMM 个数也会增加,导致运行时间会增加.但改进 LDA 的设计减小了 HMM 的计算负荷,再加上 HMM 本身良好的收敛性,因此本文方法运行时间不算长;况且状态数的增加只是使得程序的训练时间增加,测试时间不会变.实际应用中各类 HMM 是已训练的,因此并不影响本文方法的应用.此外,一旦增加新的故障类,本文方法只需简单增加一个 HMM 而无需重新训练其余 HMM,但其他方法却不具备此优点.文献^[16]方法采用 2 类特征(电压和输出对输入的增益)分别训练 2 个 BP 网络,并对它们的诊断结果进行融合,导致程序运行时间增加;其余方法具有较强的快速性.

3) 测试成本.HMM 接受的至少是一组测试序列,而一组测试序列是由 L 个测试值构成,因此会增加测试成本.文献^[16]方法对多个测点的信号进行采样,也导致了测试成本的增加,说明诊断早期故障的测试成本(即测试代价)会高一些;其余方法都采样一个测点的信号,并且诊断时只需一个测试向量即可,因此测试成本低,表 3 中数据说明了这点.

3.2 实验 2

图 3 所示电路^[16]由 4 个二阶滤波器与一个加法器构成,其中, $R_1 \sim R_8$ 的容差为 $\pm 10\%$, $C_1 \sim C_8$ 的容差为 $\pm 5\%$,放大器的增益 $Av_1 \sim Av_4$ 的容差为 $\pm 1\%$, $R_9 \sim R_{11}$ 的容差为 $\pm 1\%$.分析图 3 可知,该电路具有 10 Hz,100 Hz,10 kHz 和 100 kHz 4 个转折频率.经灵敏度分析发现, Av_1, Av_2, Av_3 和 Av_4 变化时,对电路的频响输出电压影响较明显,故选取上述 4 个元件作为故障元件.由于元件的容差范围很小,故对每个元件设置 2 类早期故障: $A_v \uparrow 4\%, A_v \downarrow 4\%$,外加正常态共 9 类状态.图 3 中, $R_1 = R_2 = 320 \text{ k}\Omega, R_3 = R_4 = 32 \text{ }\Omega, R_5 = R_6 = 320 \text{ k}\Omega, R_7 = R_8 = 32 \text{ k}\Omega, R_9 = R_{10} = R_{11} = 1 \text{ k}\Omega; C_1 = C_2 = \dots = C_8 = 50 \text{ nF}; Av_1 = Av_2 = \dots = Av_5 = 1.75$.




图 3 带通滤波电路

本次实验中输入与实验 1 中相同的激励信号源,以电路的输出点作为测点.选取 5 Hz,10 Hz,30 Hz,70 Hz,100 Hz,200 Hz,500 Hz,4 kHz,10 kHz,30 kHz,70 kHz,100 kHz,200 kHz 等为测试频率,其对应的频响电压作为 13 维的电压特征向量.同样获得各类状态的 600 个电压特征向量,各取一半特征向量作为训练数据和测试数据,训练和测试序列长度仍为 10. HMM 的初始化同实验 1,改进 LDA 降维后的特征维数置为 4,PCA 降维后的特征维数置为 11,实验结果如表 4 所示.从表 4 可知,经改进 LDA 降维后的特征包含最多的类别信息,因此此类特征应用于 HMM 具有最高的故障识别率.

表 4 中每类状态的训练序列不变,分别选取测试序列长度为 6~10;同样设置每类状态的训练数据为 180~300,训练和测试序列长度仍为 10,数据部分重叠使得训练序列为 30 组,实验结果如表 5 所

示.从表 5 可知,测试序列长度和训练数据个数的减少对故障识别率的影响较小,验证了本文方法对训练数据个数要求不高的特点.

表 4 实验 2 中各类特征与 HMM 结合的故障识别率

				%
状态类	原始特征	PCA 特征	改进 LDA 特征	
正常态	80.00	96.67	100.00	
$Av_1 \uparrow$	48.00	58.67	72.00	
$Av_1 \downarrow$	56.00	60.67	92.00	
$Av_2 \uparrow$	58.67	70.67	83.33	
$Av_2 \downarrow$	55.33	56.67	82.00	
$Av_3 \uparrow$	77.33	99.33	100.00	
$Av_3 \downarrow$	86.67	99.33	100.00	
$Av_4 \uparrow$	94.00	100.00	100.00	
$Av_4 \downarrow$	89.33	99.33	100.00	
平均值	71.70	82.37	92.15	

表 5 实验 2 中不同测试序列长度和训练数据下的故障识别率

	测试序列长度					训练数据个数					%
	6	7	8	9	10	180	210	240	270	300	
原始特征	58.70	60.37	63.52	68.52	70.19	64.69	63.83	68.89	70.37	70.19	
PCA 特征	78.52	79.26	81.48	80.49	82.41	80.86	80.49	81.85	83.58	82.41	
改进 LDA 特征	90.12	90.00	91.80	91.85	92.35	89.88	89.63	90.25	91.36	92.35	

在与实验 1 相同的系统环境下,本文方法与文献[5-7,16-17]方法进行比较,结果如表 6 所示,其中,测点数 $n=6$,测试序列长度 $L=6$, K 表示在某一测点测试数据所需要的成本.表 4 反映了其他方法对此例所设的早期故障仍然无法有效识别,本文

方法和文献[4]方法在此例中均表现出程序耗时较长且测试成本较高的特点,却具有较高的识别率,本文方法略优于文献[16]方法;其余方法显示出较强的快速性和测试成本低的优点,但识别率低.

表 6 实验 2 中各类故障诊断方法的对比

方法	故障识别率/%	运行时间/s	测试成本
文献[5]	11.90	26.22	K
文献[6]	11.09	38.50	K
文献[7]	11.10	29.48	K
文献[16]	68.34	136.54	$K \times (1+n)$
文献[17]	56.86	32.06	K
本文方法	90.12	73.53	$K \times L$

3.3 实验 3

图 4 所示电路是一个典型的自适应滤波器^[7],电阻的容差为±5%,电容的容差为±10%。该电路共有 8 个元件,每个元件有 2 类故障,外加电路正常态共有 17 类状态。图 4 中, $R_1=R_2=k_f=10\text{ k}\Omega$, $R_3=30\text{ k}\Omega$, $R_4=R_5=15.9\text{ k}\Omega$; $C_1=C_2=1\text{ nF}$ 。




图 4 自适应滤波器

由电路的拓扑结构可知有 2 对模糊组: ($T_1=R_4 \times C_1$)和($T_2=R_5 \times C_2$),因此共有 13 类状态。由于该电路中存在反馈电阻,使得早期故障的难度增加,故设置电阻和电容的故障范围为偏离正常值的±[20,40]%,激励信号源的选取同实验 1,以电路的输出点作为测点。选取 5 kHz,7 kHz,8.5 kHz,10 kHz,15 kHz,20 kHz 和 30 kHz 为测试频率,其对应的频

响电压值作为 7 维的电压特征向量。每类状态下各获取 600 个特征向量,各取一半特征向量作为训练样本和测试样本。HMM 的初始化同实验 1,训练与测试序列的长度均为 10,改进 LDA 降维后的特征维数置为 4,PCA 降维后的特征维数置为 6,实验结果如表 7 所示。从表 7 可得出与前相同的结论:改进 LDA 降维后的特征应用于 HMM 具有最高的故障识别率。

表 7 实验 3 中各类特征与 HMM 结合的故障识别率 %

类别	原始特征	PCA 特征	改进 LDA 特征
正常态	69.33	86.67	95.00
$R_1 \uparrow$	70.67	82.50	80.83
$R_1 \downarrow$	82.00	70.00	81.67
$R_2 \uparrow$	70.67	60.00	85.00
$R_2 \downarrow$	44.67	9.17	44.17
$R_3 \uparrow$	55.33	47.50	66.67
$R_3 \downarrow$	30.00	5.83	31.67
$R_f \uparrow$	69.33	69.17	91.67
$R_f \downarrow$	58.00	30.83	75.83
$T_1 \uparrow$	98.67	98.33	100.00
$T_1 \downarrow$	91.33	90.00	96.67
$T_2 \uparrow$	94.67	100.00	100.00
$T_2 \downarrow$	83.33	91.67	100.00
平均值	70.62	64.74	80.71

同样分别改变测试序列长度(6~10)和训练数据个数(180~300),训练和测试序列长度仍为 10,数据部分重叠使得训练序列为 30 组,实验结果如表 8 所示。从表 8 可知,测试序列长度和训练数据个数的变化对本文方法的故障识别能力影响较小,再次验证了本文方法具有较稳定的诊断能力。

表 8 实验 3 中不同测试序列长度和训练数据下的故障识别率 %

	测试序列长度					训练数据个数				
	6	7	8	9	10	180	210	240	270	300
原始特征	62.12	63.32	65.64	66.82	70.62	69.87	69.54	70.67	70.94	70.62
PCA 特征	61.49	62.05	62.62	64.23	64.74	64.01	64.10	64.87	64.70	64.74
改进 LDA 特征	75.13	75.74	76.99	79.95	80.71	78.56	79.59	80.09	79.08	80.71

在与实验 1 相同的系统环境下,本文方法与文献[5-7,16-17]方法的比较如表 9 所示,其中,测点数 $n=3$,测试序列长度 $L=6$, K 表示在某一测点测试数据所需要的成本。表 9 再次验证了本文方法具有最好的诊断能力,文献[16]方法的诊断能力次之,但这 2 类方法也体现出测试成本高以及程序运行时间较长的特点,本文方法仍优于文献[16]方法。其余方法与前 2 个实验一样,显示出较强的快速性和测试成本低的优点,但识别率低。

表 9 实验 3 中各类故障诊断方法的对比

方法	故障识别率/%	运行时间/s	测试成本
文献[5]	46.23	40.84	K
文献[6]	10.61	61.54	K
文献[7]	12.17	53.12	K
文献[16]	52.64	157.62	$K \times (1+n)$
文献[17]	35.69	58.78	K
本文方法	75.13	94.52	$K \times L$

4 结 论

本文针对电子系统早期故障的特点,提出基于 HMM 的模拟电路早期故障诊断方法,既充分利用 LDA 提取的优势,又结合 HMM 具有良好识别能力的特点,将两者有机结合起来实现对模拟电路早期故障的准确诊断,并与其他方法进行了详细的比较。具体研究了以下几个方面:1)针对电路早期故障的状态特征难以辨识的特点,提出了利用 LDA 对电路的频响电压特征进行消除冗余和降维处理,从而获得更有利于分类的有效特征,并减小分类器的计算负荷;2)对 LDA 的缺点提出了 2 个方面的改进措施:一方面重新定义了类间散度矩阵,以减弱边缘类对映射方向的影响,另一方面采用 Ye 等方法^[9]来避免类内散度矩阵出现非奇异的情况(该情况会导致 LDA 无法进行),并与 PCA 进行比较,通过实验验证了改进 LDA 提取的特征与 HMM 结合具有最好的识别能力;3)与其他方法进行了详细的比较的实验,结果表明,本文方法对模拟电路早期故障的识别能力优于其他方法,但其具有运行时间略长且测试成本较高的缺点,说明电路早期故障的诊断需要付出略多的测试成本。

参考文献 (References):

- [1] Berkowitz R. Condition for network-element-value solvability [J]. IRE Transactions on Circuits Theory, 1962, 9(1): 24-29
- [2] El-Gamal M A. A knowledge-based approach for fault detection and isolation in analog circuits [C] //Proceedings of IEEE International on Neural Networks, Houston, 1997, 1580-1584
- [3] Cannas B, Fanni A, Manetti S, *et al.* Neural network-based analog fault diagnosis using testability analysis [J]. Neural Computing & Applications, 2004, 13(4): 288-298
- [4] Kabisatpathy P, Barua A, Sinha S. Artificial neural-network model-based observers [J]. IEEE Circuits and Devices Magazine, 2005, 21(4): 18-26
- [5] Aminian F, Aminian M, Collins H W, *et al.* Analog fault diagnosis of actual circuits using neural networks [J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(3): 544-550
- [6] Stopjaková V, Malošek P, Nagy V. Neural network-based defect detection in analog and mixed IC using digital signal preprocessing [J]. Journal of Electrical Engineering, 2006, 57(5): 249-257
- [7] Mohsen A A K, Abu El-Yazeed M F. Selection of input stimulus for fault diagnosis of analog circuits using ARMA model [J]. International Journal of Electronics and Communications, 2004, 58(3): 212-217
- [8] Zheng W S, Lai J H, Yuen P C. GA-fisher: a new LDA-based face recognition algorithm with selection of principal components [J]. IEEE Transactions on System, Man, and Cybernetics--Part B: Cybernetics, 2005, 35(5): 1065-1078
- [9] Ye J P, Janardan R, Park C H, *et al.* An optimization criterion for generalized discriminant analysis on under sampled problems [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(8): 982-994
- [10] Lotlikar R, Kothari R. Fractional-step dimensionality reduction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(6): 623-627
- [11] Raphael C. Automatic segmentation of acoustic musical signals using hidden Markov models [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(4): 360-370
- [12] Zhou S Y, Xie L, Wang S Q. On-line fault diagnosis in industrial processes using variable moving window and hidden Markov model [J]. Chinese Journal of Chemical Engineering, 2005, 13(3): 388-395
- [13] Liu Xinmin, Qiu Jing, Liu Guanjun. HMM-SVM based mixed diagnostic model and its application [J]. Acta Aeronautica Et Astronautica Sinica, 2005, 26(4): 496-500 (in Chinese)
(柳新民, 邱 静, 刘冠军. 基于 HMM-SVM 的混合故障诊断模型及应用[J]. 航空学报, 2005, 26(4): 496-500)
- [14] Xu Lijia, Wang Houjun, Long Bing. A method on state monitoring and health evaluation and its application to analog circuits [J]. Journal of Computer-Aided Design & Computer Graphics, 2008, 20(12): 1550-1556 (in Chinese)
(许丽佳, 王厚军, 龙 兵. 一种状态监测与健康评估方法及其在模拟电路中的应用[J]. 计算机辅助设计与图形学学报, 2008, 20(12): 1550-1556)
- [15] Yi Kechu, Tian Bin, Fu Qiang. The speech signal processing [M]. Beijing: Defense Industry Press, 2001: 210-300 (in Chinese)
(易克初, 田 斌, 付 强. 语音信号处理[M]. 北京: 国防工业出版社, 2001: 210-300)
- [16] Peng Minfang, He Yigang, Wang Yaonan, *et al.* Synthetic intelligence based fault diagnosis of analog circuits [J]. Proceedings of the Chinese Society for Electrical Engineering, 2006, 26(3): 19-24 (in Chinese)
(彭敏放, 何怡刚, 王耀南, 等. 模拟电路的融合智能故障诊断[J]. 中国电机工程学报, 2006, 26(3): 19-24)
- [17] Wang Cheng, Chen Guangju, Xie Yongle. Fault diagnosis based on radial basis function neural network in analog and mixed-signal circuits [J]. Journal of Circuits and Systems, 2007, 12(2): 65-68 (in Chinese)
(王 承, 陈光楸, 谢永乐. 基于径向基函数的神经网络的模拟/混合电路故障诊断[J]. 电路与系统学报, 2007, 12(2): 65-68)