

基于 RVM 和相空间重构的模拟电路 PHM 研究

陈卓, 颜学龙

(桂林电子科技大学 电子工程与自动化学院, 广西 桂林 541004)

摘要: 针对模拟电路健康管理的特点, 提出了一种基于 RVM 的模拟电路故障诊断和预测方法; 首先对模拟电路作蒙特卡罗分析得到输出频域响应, 然后利用小波分解方法提取模拟电路的故障特征, 最后用相关向量机分别对电路进行了单一故障和双故障的诊断研究; 接着, 对电路进行参数分析, 得到不同参数值下的输出响应, 计算其与电路无故障标准响应的欧氏距离作为故障特征, 并以此表征电路元件健康值, 结合相空间重构方法, 得到相关向量机的输入输出样本, 随后训练学习并实现对各个时间点元件的健康值变化轨迹进行预测; 仿真结果表明, 该方法在小样本情况下, 诊断和预测效果好, 适用于健康管理中实时预测, 具有较好的实用性。

关键词: 相关向量机; 相空间重构; 欧氏距离; 模拟电路; 健康管理

Research on Analog Circuit PHM Based on RVM and Phase Space Reconstruction

Chen Zhuo, Yan Xuelong

(School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China)

Abstract: Aimed at the characteristics of prognostic and health management (PHM) in analog circuits, a new method for analog circuit fault diagnostics and prediction based on relevance vector machine (RVM) is proposed in this paper. Firstly, getting frequency domain response by the Monte Carlo analysis of analog circuits, fault features are extracted by wavelet decomposition and reconstruction to make single-fault and double fault diagnosis utilizing relevance vector machine, combining the phase space reconstruction method, the health value of circuit components is represented through calculating the Euclidean distance between output of standard and different parameter analysis, and the trend of health value trajectory with respect to time points can be predicted by training samples of inputs and outputs of RVM, the proposed approach is appropriate for real time prediction in PHM. Simulation results validate the good practicability and effectiveness of the proposed method.

Keywords: relevance vector machine; phase space reconstruction; Euclidean distance; analog circuits; health management

0 引言

近年来, 故障预测与健康管理的 PHM^[1] 彻底改变了电子设备的可靠性, 并且广泛应用于航空航天与军事系统、医疗器械、汽车电子、云计算、智能电网、制造业等诸多领域。其目的是建立一个软硬件相结合的集成环境, 帮助系统实现提高可靠性、健康评估、实时性预测、主动维护等。PHM 系统一般具备故障探测、故障诊断、故障预测等功能^[1], 而电子设备集成度增加使得模拟电路的复杂性增强。伴随模拟电路密集度、元件容差、非线性等问题的出现, 对模拟电路故障定位和实时性, 准确性要求越来越高^[2-3], 因此有必要对模拟电路进行故障预测与健康管理的研

PHM 核心技术在于故障诊断及预测, 其中的关键研究方法主要分为三大类^[4-5]: 基于物理模型^[6]、基于数据驱动^[6-7]、基于概率统计^[5]。模拟电路的诊断的方法一直迭代更新, 从故障字典法, 原件参数识别, 故障验证, 到当前研究最多的基于机器学习的神经网络^[8]方法、支持向量机 (SVM)^[9]、超限学习机 (ELM)^[10]。国内外虽然有些不少研究成果, 但依旧有些限制和不足。

相关向量机 (RVM) 是基于稀疏贝叶斯框架理论的机器学习模型^[11-13]。由美国学者 Tipping 于 2001 年提出的一种分类、回归的新模型。基于 SVM 方法, 将核函数与贝叶斯推理结合, 具有 SVM 不具备的核函数选择不受 Mercer 条件的限制, 稀疏性强, 同时有后验概率分布等特点^[14], 还保持了 SVM 原有特性, 较神经网络方法在小样本训练, 全局最优, 泛化能力上有明显的优势。已成功应用在如机械故障预测^[15], 电池寿命预测^[16], 交通流预测^[17]等领域。

RVM 在模拟电路故障诊断及预测中优势在于小样本计算, 适合对电路进行实时预测与健康管理的。分别对基于 RVM 的模拟电路故障诊断及预测模型进行了仿真研究。

1 故障特征提取

模拟电路的电阻, 电容等元件由于性能下降, 发生表

收稿日期: 2018-03-10; 修回日期: 2018-03-30。

基金项目: 广西自动检测技术与仪器重点实验室基金项目 (YQ17101)。

作者简介: 陈卓 (1993-), 男, 湖北武汉人, 硕士研究生, 主要从事可测性设计、故障诊断方向的研究。

颜学龙 (1962-), 男, 湖南衡阳人, 教授, 主要从事集成电路测试理论与仪器方向的研究。

现为偏离标准值的软故障, 针对故障诊断采用小波变换提取故障特, 故障预测采用频域响应作为特征量, 利用欧氏距离表征元件偏离标准值程度, 通过简单转换, 即可表征元件的健康值。

1.1 小波分解

小波方法是在时频分析上的成熟工具, 广泛应用在信号处理领域中, 其中小波分解主要用于故障特征提取方面, 以 haar 小波为例, 采用的分解方法步骤如下:

- 1) 采用 haar 小波对信号进行 n 层分解, 得到每层高频系数序列 D_n ;
- 2) 求取高频能量 $E_n = D_n^T * D_n$;
- 3) 将 $[E_1 E_2 \dots E_n]$ 中取出 $[E_x E_y]$ 作为特征向量。

1.2 欧氏距离

为了便于对模拟电路健康状态进行预测, 需要计算故障阈值, 即故障指示值 (FI), 文献 [18] 通过马氏距离计算故障指示值, 来对模拟电路剩余寿命进行预测。马氏距离中协方差矩阵会导致计算的不稳定性。在特征微小变化的反映过于强, 会放大引入的容差影响, 降低预测信息的完整性和准确性^[19], 而文献 [20] 用了余弦距离计算元件退化度, 但余弦距离主要从方向上区分差异, 对数值大小不敏感, 即在同方向上任意长度的向量的余弦距离值为 1, 在实验过程中得到的健康值几乎都是 1, 量纲在 $10^{-6} \sim 10^{-16}$ 之间, 不利于实时计算。文献 [21] 提出的利用皮尔逊相关系数表征健康值计算复杂。利用欧氏距离^[22]方法, 计算公式简单, 表征 n 维空间的两点的真实距离, 与方向和大小均有关。

两个向量的欧氏距离代表的是他们之间的相似程度, 在元件退化时, 元件值发生变化, 分析其输出的频域响应分别与标准响应作欧氏距离计算, 得到元件的失效程度, 即故障特征, 进而定义健康值 H 来作为预测指标。公式如下:

$$d(X, Y) = \sqrt{\sum_{i=0}^n (Y_i - X_i)^2}$$

$$H(Y) = 1 - d(X, Y)$$

2 相空间重构

相空间重构是为了找到 RVM 模型下的输入输出之间的对应关系^[23]。给定 1 个时间点的序列值 $\{x_1, x_2, \dots, x_l\}$, 假设 x_n 与前 d 个序列值之间存在某种非线性映射关系:

$$x_n = f(x_{n-d}, \dots, x_{n-2}, x_{n-1})$$

式中, $n = (d+1, d+2, \dots, l)$, d 为嵌入维数, $f(\cdot)$ 是非线性映射模型, 则可以得到 RVM 模型输入输出的训练集 $\{x, t\}$ 如下:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} = \begin{bmatrix} x_1 & x_2 & \cdots & x_d \\ x_2 & x_3 & \cdots & x_{d+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_N & x_{N+1} & \cdots & x_{d+N-1} \end{bmatrix}$$

$$\mathbf{t} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_N \end{bmatrix} = \begin{bmatrix} x_{d+1} \\ x_{d+2} \\ \vdots \\ x_{d+N} \end{bmatrix}$$

其中: $N = l - d$ 为训练集中样本个数, 利用其训练 RVM 模型, 可以实现对未来时间点的序列值的预测。

3 RVM

它的基本原理是借助贝叶斯推断获得满足标准高斯分布的模型最优权值 ω 。通过定义 ω 的超参数的先验概率, 在贝叶斯框架下学习, 利用自相关判定理论移除不相关的点, 得到稀疏模型, 在样本迭代训练过程中, 大部分参数的后验分布趋于零, 而非零权值对应的样本即为相关向量, 体现了样本的核心特征。

3.1 分类模型

对于二元分类情况, 目标值 $\{t_i\}_{i=1}^N$ 只可能是 0 或 1, 分类问题时习惯使用 sigmod 函数:

$$p(t_i = 1 | \omega) = \sigma[y(x, \omega)] = \frac{1}{1 + e^{-y(x, \omega)}} \quad (4)$$

不同于回归模型, 此处无数据噪声, 得到:

$$p(t | \omega) = \prod_{i=1}^N \sigma[y(x_i, \omega)]^{t_i} \{1 - \sigma[y(x_i, \omega)]\}^{1-t_i} \quad (5)$$

该分布并不是标准高斯分布, 因此估计权值不能用回归模型方法, 采用 Laplace 方法找到 ω 最大值处, 即:

$$\omega_{MP} = \arg \max_{\omega} p(\omega | t, \alpha) = \arg \max_{\omega} \log\{p(t | \omega) p(\omega | \alpha)\} \quad (6)$$

而 $p(t | \omega)$ 和 $p(\omega | \alpha)$ 分布已知, 则:

$$\log\{p(t | \omega) p(\omega | \alpha)\} = \sum_{i=1}^N [t_i \log y_i + (1 - t_i) \log(1 - y_i)] - \frac{1}{2} \omega^T A \omega \quad (7)$$

式中, $A = \text{diag}(\alpha) = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$; $y_i = \sigma[y(x_i, \omega)]$, 利用 Newton 方法可以找到 ω_{MP} , 即:

$$\mathbf{g} = \Phi^T(t - \mathbf{y}) - A\omega \quad (8)$$

$$H = (-\Phi^T B \Phi - A)^{-1} \quad (9)$$

$$\Delta\omega = -H^{-1} \mathbf{g} \quad (10)$$

$$\omega_{MP} := \omega_{MP} + \Delta\omega \quad (11)$$

式中, $\mathbf{y} = [y_1, y_2, \dots, y_N]^T$; $\mathbf{B} = \text{diag}(y_1(1 - y_1), y_2(1 - y_2), \dots, y_N(1 - y_N))$ 。

而协方差矩阵 $\Sigma = (-H |_{\omega_{MP}})^{-1} = (\Phi^T B \Phi + A)^{-1}$ 。

更新超参数方法类似回归模型, 将 ω_{MP} 代替 μ :

$$\alpha_i^{new} = \frac{\gamma_i}{\omega_{MP}^2} \quad (12)$$

$$\gamma_i = 1 - \alpha_i \sum_{i,i} \quad (13)$$

式中, $\sum_{i,i}$ 是 Σ 中第 i 项在对角线上的元素给出 α 的初始猜测值, 按上式步骤更新迭代, 可以逼近 ω_{MP} 。

3.2 回归模型

假设 $\{x_i\}_{i=1}^N$ 是训练样本集的特征值, 目标值为 $t = [t_1, t_2, \dots, t_N]^T$ 且互相独立, 则带有噪声的模型为:

$$t_i = y(x_i, \boldsymbol{\omega}) + \boldsymbol{\varepsilon}_i \quad (14)$$

式中, $\boldsymbol{\omega}$ 是 ω_i 组成的模型权值向量, 噪声 $\boldsymbol{\varepsilon}_i \sim N(0, \sigma^2)$ 而 RVM 模型输出为:

$$y(x, \boldsymbol{\omega}) = \sum_{i=1}^N \omega_i k(x, x_i) + \omega_0 \quad (15)$$

$$p(t_i) = N(t_i | y(x_i, \boldsymbol{\omega}), \sigma^2) \quad (16)$$

则在已知 $\{\omega_i\}_{i=0}^N$ 与 σ^2 的条件下可以得到 t 的概率分布:

$$p(t | \boldsymbol{\omega}, \sigma^2) = \prod_{i=1}^N N(t_i | y(x_i, \boldsymbol{\omega}), \sigma^2) = (\sigma^2)^{-\frac{N}{2}} \exp\left(-\frac{t - \boldsymbol{\Phi}\boldsymbol{\omega}^2}{2\sigma^2}\right) \quad (17)$$

式中, $\boldsymbol{\Phi}$ 是由各特征向量代入核函数 $k(x, y)$ 所得的 $N \times N + 1$ 维设计矩阵。

$$\boldsymbol{\omega} = [\omega_0, \omega_1, \omega_2, \dots, \omega_N]^T$$

$$\boldsymbol{\Phi} = [\varphi(x_1), \varphi(x_2), \dots, \varphi(x_N)]$$

$$\varphi(x_n) = [1, k(x_n, x_1), k(x_n, x_2), \dots, k(x_n, x_N)]^T$$

由于直接使用最大似然函数解 $\boldsymbol{\omega}$ 和 σ^2 , 通常会导致 $\boldsymbol{\omega}$ 中元素大部分不是 0, 即过多支持向量导致了过拟合, 因此采用在贝叶斯框架下, 定义的先验条件概率分布为:

$$p(\boldsymbol{\omega} | \boldsymbol{\alpha}) = \prod_{i=0}^N N(\omega_i | 0, \alpha_i^{-1}) \quad (18)$$

式中, $\boldsymbol{\alpha} = (\alpha_0, \alpha_1, \dots, \alpha_N)^T$ 含有 $N+1$ 个超参数, 超参数 α_i 调节与之对应着权值 ω_i , 由贝氏定理及上述公式, 可以推导出权值 $\boldsymbol{\omega}$ 的后验概率分布为:

$$\frac{p(t | \boldsymbol{\omega}, \sigma^2) p(\boldsymbol{\omega} | \boldsymbol{\alpha})}{p(t | \boldsymbol{\alpha}, \sigma^2)} \sim N(\boldsymbol{\omega} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) \quad (19)$$

后验协方差和均值分别为:

$$\boldsymbol{\Sigma} = (\sigma^{-2} \boldsymbol{\Phi}^T \boldsymbol{\Phi} + \mathbf{A})^{-1} \quad (20)$$

$$\boldsymbol{\mu} = \sigma^{-2} \boldsymbol{\Sigma} \boldsymbol{\Phi}^T t \quad (21)$$

式中, $\mathbf{A} = \text{diag}(\boldsymbol{\alpha}) = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$ 而超参数的边缘似然函数分布为:

$$p(t | \boldsymbol{\alpha}, \sigma^2) = \int p(t | \boldsymbol{\omega}, \sigma^2) p(\boldsymbol{\omega} | \boldsymbol{\alpha}) d\boldsymbol{\omega} \sim N(0, \boldsymbol{\Omega}) \quad (22)$$

式中, $\boldsymbol{\Omega} = \sigma^2 \mathbf{I} + \boldsymbol{\Phi} \mathbf{A}^{-1} \boldsymbol{\Phi}^T$, 权值参数 $\boldsymbol{\omega}$ 的最大后验估计直接受超参数 $\boldsymbol{\alpha}, \sigma^2$ 的影响, 通过最大化边缘似然函数 $p(t | \boldsymbol{\alpha}, \sigma^2)$ 可以实现超参数优化, 最大似然参数估计值为 $\boldsymbol{\alpha}_{MP}, \sigma_{MP}^2$, 把式(23)对 $\boldsymbol{\alpha}$ 和 σ^2 求偏微分等于零, 可以得到迭代公式:

$$\alpha_i^{new} = \frac{\gamma_i}{\mu_i^2} \quad (23)$$

$$(\sigma^2)^{new} = \frac{t - \boldsymbol{\Phi}\boldsymbol{\mu}^2}{N - \sum_{i=0}^N \gamma_i} \quad (24)$$

$$\gamma_i = 1 - \alpha_i \sum_{i,i} \quad (25)$$

式中, $\sum_{i,i}$ 是 $\boldsymbol{\Sigma}$ 中第 i 项在对角线上的元素, 先给出 $\boldsymbol{\alpha}$ 和 σ^2 的初始猜测值, 再由上式不断更新来逼近 $\boldsymbol{\alpha}_{MP}, \sigma_{MP}^2$ 。

在给定一个新的输入样本数据 \boldsymbol{x} 条件下, 相应预测输出的概率分布为:

$$p(t_* | t) =$$

$$\int p(t_* | \boldsymbol{\omega}, \boldsymbol{\alpha}_{MP}, \sigma_{MP}^2) p(\boldsymbol{\omega} | t, \boldsymbol{\alpha}_{MP}, \sigma_{MP}^2) d\boldsymbol{\omega} \sim N(t_* | y_*, \sigma_*^2) \quad (26)$$

其中: 预测均值和方差为:

$$y_* = \boldsymbol{\mu}^T \boldsymbol{\varphi}(x_*) \quad (27)$$

$$\sigma_*^2 = \sigma_{MP}^2 + \boldsymbol{\varphi}(x_*)^T \boldsymbol{\Sigma} \boldsymbol{\varphi}(x_*) \quad (28)$$

4 仿真实验

4.1 诊断实例

通常, 模拟电路的故障以单一元件故障为主^[18], 如图 1 为 leapfrog 滤波器电路。元件无故障情况下, $C_1 = 10 \text{ nF}$, $C_2 = 20 \text{ nF}$, $R_1 = 10 \text{ k}\Omega$, 研究此 3 个元件做故障诊断研究。




图 1 跳蛙滤波器电路

分别设置电阻和电容元件的容差为 5% 和 10%^[24], 用均匀分布 $U(0, 1X_n, X_n - 2t)$ 和 $U(X_n + 2t, 2X_n)$ 分别表示元件正反向软故障偏差范围, 其中 t 为元件容差值^[25]。因此假设元件发生软故障的参数值为偏离标准值的 30%。

诊断步骤如下: 首先, 根据设置的故障参数 30% 分别对 C_1, C_2, R_1 设置正向软故障发生时对应的值即分别为 13 nF, 26 nF, 13 k Ω , 其他元件值为正常标准值。然后在 Pspice 里将电路的激励源扫频率范围设置为 10 Hz ~ 10 Mhz, 随后分别进行 100 次蒙特卡罗分析, 得到输出端的频域响应信号, 然后均匀采集响应信号 61 个频率点的电压值, 由此获得原始故障数据, 接着故障特征提取采用 2 层 haar 小波分解方法, 得到 $[E_1 \ E_2]$ 作为故障二维特征, 这样, 三类单故障经过特征提取一共得到 300 组故障特征数据; 分别对 C_2, R_1 做二分类诊断: 各取 75 组数据, 即 150 组数据作为训练样本, 故障特征作为 RVM 的输入, 故障样本类别标签为 $[1 \ 0]$ 作为 RVM 的输出, 分类模型做故障诊断剩余 50 组数据作为测试样本, 其中 RVM 核函数选为高斯核函数, 核参数 σ_{ker} 选取采用交叉验证获取, 如图 2, 平衡稀疏性和诊断误差将核参数设为 3, 随后用相同的方法分别对 C_1, C_2 和 C_1, R_1 作二分类故障诊断。

对于不同元件的单故障诊断, 传统做法是构造多分类器, 复杂度较高, 采用文献 [26] 提出的方法, 将 Multinomial probit 函数代替传统 RVM 中的 logistic sigmoid 函数从而将单个元件的二分类 RVM 模型推广到多分类。用上述的采集故障数据和特征提取方法得到 C_1, C_2, R_1 的 225 组故障数据作为训练样本, 故障样本类别标签为 $[3 \ 2 \ 1]$, 分别作为 RVM 的输入输出进行训练学习, 进行 RVM 单故障一次多分类故障诊断。




图 2 交叉验证选取核参数

对于多个元件同时发生故障的诊断, 假设 2 个元件同时发生正向软故障, 以 C_1 、 C_2 、 R_1 三个元件组合为例, 其他元件为正常值, 诊断步骤为: 设置 C_1 、 C_2 发生软故障的值, 保持 R_1 正常标准值, 此时同样对电路作 100 次蒙特卡罗分析, 接着设置 C_1 、 R_1 发生故障, C_2 保持正常, 最后设置 C_2 、 R_1 发生故障, C_1 保持正常, 作 100 次蒙特卡罗分析。进而得到三种双故障组合类型, 分别为 $C1C2+$, $C1R4+$, $C2R4+$, 将上述分析后的数据同样采集 61 个频率对应的输出电压值, 再用 2 层小波分解方法提取故障特征, 原始故障特征数据有 300 个, 225 故障特征样本用于训练输入, 故障样本类别标签为 $[3 \ 2 \ 1]$ 作为输出, 经过 RVM 学习后, 剩下 75 个用于测试诊断效果。

上述的某二类单故障诊断和单故障多分类诊断、双故障多分类诊断的结果分别如图 3、图 4、图 5。测试集诊断的实验结果见表 1。




图 3 二类单故障诊断仿真实验




图 4 多类单故障诊断仿真实验




图 5 多元件组合故障诊断仿真实验

表 1 诊断仿真实验结果

诊断类型	相关向量个数	诊断精度
$C1+$ 、 $C2+$ 二分类	5	100%
$C1+$ 、 $R4+$ 二分类	2	94.00%
$C2+$ 、 $R4+$ 二分类	3	100%
单故障多类诊断	3	96.00%
双故障多类诊断	5	94.67%

结果显示, 在单故障的二分类诊断效果主要受故障二维特征区分度影响, 整体诊断率可以达 94% 以上, 而多分类器的构造的诊断效果也有 96%, 而对于多类双故障诊断, RVM 的诊断效果达 94.67%, 整体诊断效果较为优秀, 并且诊断的模型中使用的相关向量个数少, 较为稀疏, 为大数据, 实时在线应用场景的诊断问题节约了计算存储资源。

4.2 预测实例

元件在随时间退化下其标称值发生改变, 这种状态趋势需要在其失效之前被预见, 从而预测出元件值失效的时间点。Sallen-Key 带通滤波器^[21,24]是很多文献进行仿真验证的标准电路之一, 设置与文献 [21] 相同的元件失效偏差值, 同样设置各元件的容差, 用 Pspice 对待测元件作参数分析, 观测其输出在元件值线性变化下的频域响应, 采集 61 个响应点用欧氏距离计算每次变化下的失效程度, 进而计算出每个时间点的健康值, 在软故障发生时间点下的健康值即为故障阈值。如图 6 为 Sallen-Key 带通滤波器电路。

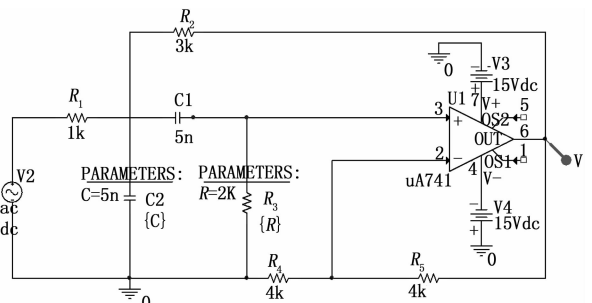


图 6 Sallen-Key 带通滤波器电路

研究 R_3 的失效故障, 设置其阻值在 2~3.2 K Ω 线性变化, 每个时间点变化 20 Ω ; 对电容 C_2 设置 5~2 nF 按每个

时间点减少 0.05 nF 线性变化, 初始 0 时刻元件健康值 h_1 为 1, 根据设置的元件偏差值, 时刻 50 即第 51 个时间点发生软故障。

对 R_3 , 利用相空间重构方法, 取其 0~40 时间段的 41 个真实健康值 $h_1 \sim h_{41}$ 构造训练集: 即 $l=41$, 设置嵌入维数为 $d=21$, 则训练集样本个数为 20; 可以得到训练集为 $\{x, t\}$, 其中: $\{x_1 | t_1\} = [h_1, h_2, \dots, h_{21} | h_{22}]; \{x_2 | t_2\} = [h_2, h_3, \dots, h_{22} | h_{23}], \dots, \{x_{20} | t_{20}\} = [h_{20}, h_{21}, \dots, h_{40} | h_{41}]$ 。训练完得到 RVM 回归模型 $f(\cdot)$, 进而得到训练集的健康预测值 $T = [H_{22}, H_{23}, \dots, H_{41}]$ 。接下来是预测第 41 个时间点以后的健康值: 由 $x_{21} = [h_{21}, h_{22}, \dots, h_{41}]$ 和 $f(\cdot)$ 计算出第 42 个时间点的健康预测值 H_{42} , 并得到新输入 $x_{22} = [h_{22}, h_{23}, \dots, h_{41}, H_{42}]$, 计算出第 43 个时间点的预测值 H_{43} , 再将 H_{42} 和 H_{43} 代入新输入 $x_{23} = [h_{23}, h_{24}, \dots, h_{41}, H_{42}, H_{43}]$, 反复一直更新输入, 得到一系列时间点的健康预测值。同样对 C_2 进行故障预测, 根据先前计算得到的故障阈值可以预测出故障发生的时间点, 便于 PHM 的视情维护。如图 7, 图 8 分别是 R_3 和 C_2 发生退化故障的状态曲线。




图 7 R_3 故障预测仿真实验




图 8 C_2 故障预测仿真实验

对 R_3 和 C_2 进行障预测仿真实验结果见表 2, 其中训练 MSE 分别达了 $6.32842E-09$ 、 $1.92347E-11$ 。

表 2 预测仿真实验结果

仿真实验	阈值点	阈值预测点	误差	预测 MSE
R3-60	50	48	-2	$1.78381E-06$
C2-60	50	55	5	$6.05641E-08$

由表 3 可以看出, 在小样本情况的预测中, 应用相空间重构的 RVM 算法可以对模拟电路进行较为精准的预测。

将提出的方法和文献 [21] 的预测效果比较, 对比预测部分的 MSE 见表 3。

表 3 方法对比

方法	文献[21]
$1.78381E-06$	$1.9830E-06$

当改变嵌入维数进行相同的实验得到的预测结果见表 4。

表 4 不同嵌入维数实验结果对比

嵌入维数	训练 MSE	预测 MSE
5	0.00226555	$5.13270E-06$
11	$1.69882E-08$	$3.59303E-06$
21	$6.32842E-09$	$1.78381E-06$
31	$1.33122E-09$	$7.00596E-07$

由表 4 可以得到当嵌入维数为 31 对 R_3 进行实验时, 预测 MSE 为 $7.00596E-07$, 发现增加嵌入维数可进一步提高预测效果, 也侧面说明了预测值与历史时段预测值的相关性。

5 结论

目前 RVM 在模拟电路故障预测中的应用较少, 提出一种基于相空间重构和 RVM 的模拟电路健康管理核心功能的研究方法, 特征提取提取方法对比之前的文献更加简单, 能在小样本情况下进行故障诊断和预测, 且预测效果具有一定优越性, 符合实际场景监测要求, 适用于 PHM 领域中大量样本的实时预测, 通用性良好。需要指出的是, 在尚未优化各个参数情况下, 在故障诊断精度有待提高, 预测精度也受嵌入维数的影响, 因此下一步研究工作可集中在包括嵌入维数在内的各个参数优化的方法的研究上。

参考文献:

[1] Pecht M G. Prognostics and Health Management of Electronics [M]. Hoboken: John Wiley&Sons, 2008; 2-82.
 [2] 胡鸿志, 田书林, 郭庆, 等. 面向三维空间的模拟电路故障建模与故障检测 [J]. 仪表技术与传感器, 2015 (10): 101-103.
 [3] 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.
 [4] 彭宇, 刘大同, 彭喜元. 故障预测与健康管理的综述 [J]. 电子测量与仪器学报, 2010, 24 (1): 1-9.
 [5] Hess A, Calvello G, Frith P. Challenges, issues, and lessons learned chasing the "Big P". Real predictive prognostics. Part 1 [A]. IEEE Aerospace Conference [C]. IEEE, 2005: 3610-3619.