

基于状态维修的电子设备故障预测技术研究

田沿平, 叶晓慧, 尹明

(海军工程大学 电子工程学院, 武汉 430033)

摘要: 为解决电子设备结构复杂, 故障信息不足, 故障预测困难, 并且现有方法不能直接对电子设备进行状态预测等问题, 文中提出了基于状态维修 (CBM) 的最小二乘支持向量机 (LSSVM) 和隐马尔科夫模型 (HMM) 组合故障预测方法; 首先采取灵敏度分析法确定电路中要可能发生变化的元件, 通过改变元件参数来设置电路的不同退化状态; 其次建立组合故障预测模型; 最后对该电路进行状态预测; 结果表明, 文中提出的方法能够直接预测电路的不同状态, 进而实现直接预测电子设备的故障状态, 预测精度可以达到 93.3%。

关键词: CBM; LSSVM; HMM; 故障预测

Electronic Equipment Failure Prediction Technology based on CBM

Tian Yanping, Ye Xiaohui, Yin Ming

(School of Electrical Engineering, Naval University of Engineering, Wuhan 430033, China)

Abstract: In order to solve the complex electronic equipment and hard to predict the fault, and existing methods cannot predict the state of the electronic equipment and other issues directly, we propose least square support vector machine and hidden Markov model portfolio fault prediction method. First, according to sensitivity analysis to determine the circuit elements to be changed to set the circuit by changing the parameters of the different components degraded state; secondly, create a combination failure prediction model; Finally, the circuit state prediction. The results show that the proposed method can directly predict the different states of the circuit, so as to realize the fault state prediction of the electronic equipment directly, the prediction accuracy can reach 93.3%.

Keywords: CBM; LSSVM; HMM; state prediction

0 引言

状态维修 (CBM) 也被称为预测性维修^[1], 是根据获得的实际运行状态信息来确定设备的维修需求^[2]。准确的故障预测是状态维修的前提, 能够在故障发生前探测出设备的潜在故障, 及时进行维修, 降低损失。目前主要的故障预测方法包括人工神经网络^[3]、支持向量机^[4]、灰色系统理论^[5]、隐马尔科夫模型^[6]、遗传算法^[7]等, 但任何单一方法几乎都不能直接对设备的状态进行预测。

隐马尔科夫模型 (HMM) 是一种关于统计分析的模型, 具有数据结构严谨和计算性能可靠的优点, 在语音、文字识别^[8]和故障诊断^[9]已经得到了广泛的使用, 并取得了良好效果。最小二乘支持向量机 (LSSVM) 可以较好的处理高维、局部极小值、小样本等实际问题, 因此被广泛用于故障诊断和故障预测中。本文采用 HMM 和 LSSVM 相结合的方式实现故障状态预测, 利用 LSSVM 进行故障预测, 再利用 HMM 的解码功能求解预测的未来状态, 从而达到直接预测故障状态的目的。

1 相关理论基础

1.1 HMM 基本原理

HMM 是一种用参数表示的用于描述双内嵌式随机过程统计特性的概率模型^[10], 其基本原理如图 1 所示。

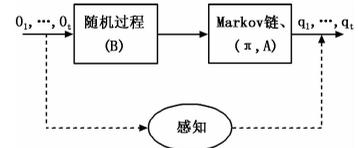


图 1 HMM 的基本原理

HMM 根据观测信号不同可分为离散隐马尔科夫模型和连续隐马尔科夫模型, 对于电子设备来说通常采用连续隐马尔科夫模型更能取得较好的实验效果^[11]。一个连续的 HMM 共包含 5 个基本参数: N 为模型中马尔可夫链的状态数目, M 为每个状态对应的可能的观测值数目, π 为初始概率分布, A 为状态转移概率矩阵, B 为观测值概率矩阵, 因此一个 HMM 可记为: $\lambda = (N, M, \pi, A, B)$, 简写为 $\lambda = (\pi, A, B)$ 。

HMM 主要解决 3 个基本问题^[12]:

- 1) 解码问题, 即已知模型和一组观测序列求产生该序列最大概率的状态序列, 可用 Viterbi 算法计算;
- 2) 评估问题, 即已知模型和观测序列, 求该序列在模型下出现的概率, 常用前向-后向算法;
- 3) 学习问题, 通过对大量的观测序列进行训练, 得到一组模型参数, 常用 Baum-Welch 算法。

1.2 LSSVM 预测原理分析

采用 LSSVM 来进行故障预测实质就是根据某个变化量的

收稿日期: 2014-09-12; 修回日期: 2014-10-17。

基金项目: 总装预研基金 (9140A27020113JB11393)

作者简介: 田沿平 (1989-), 女, 吉林长春人, 硕士研究生, 主要从事综合测试与故障预测方向的研究。

叶晓慧 (1962-), 男, 湖北武汉人, 教授, 博导, 主要从事故障诊断与综合保障方向的研究。

观测数据建立一个故障预测模型，得到对未来某个时刻或某个状态的预测值，建立模型的关键是确定输入输出关系。LSSVM 的学习样本为：

$$\begin{cases} X = \begin{bmatrix} x_1 & x_2 & \cdots & x_m \\ x_2 & x_3 & \cdots & x_{m+1} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n-m} & x_{n-m+1} & \cdots & x_{n-1} \end{bmatrix} \\ Y = \begin{bmatrix} x_{m+1} \\ x_{m+2} \\ \vdots \\ x_n \end{bmatrix} \end{cases} \quad (1)$$

从式 (1) 中可以看到输入与输出之间是一一映射的，其中 $f: R^m \rightarrow R^m$ ， m 为嵌入维数， m 的确定根据最终预测误差 (FPE) 准则^[13]。

$$FPE(k) = \frac{n+k}{n-k} \sigma_k^2 \quad (2)$$

可以看出 $FPE(k)$ 是随着 k 变化而变化的，当 $FPE(k)$ 取得最小值时，则最优解 m 就是最佳嵌入维数 $m = k_{opt}$ 。

在确定了输入输出关系和嵌入维数后就可以开始 LSSVM 模型训练，得到 LSSVM 回归函数为：

$$y_t = \sum_{i=1}^{n-m} \alpha_i K(x_i, x_t) + b \quad (3)$$

得到第 1 步预测为：

$$y_{n+1} = \sum_{i=1}^{n-m} \alpha_i K(x_i, x_{n-m+1}) + b \quad (4)$$

同时还可以得到 $x_{n-m+2} = \{x_{n-m+2}, x_{n-m+3}, \dots, x_n, \hat{x}_{n+1}\}$ ，其中 \hat{x}_{n+1} 代表第 $n+1$ 个数据的预测值，即 $\hat{x}_{n+1} = y_{n+1}$ 。

则第 2 步预测为：

$$y_{n+2} = \sum_{i=1}^{n-m} \alpha_i K(x_i, x_{n-m+2}) + b \quad (5)$$

以此类推，得到第 k 步的 LSSVM 预测模型：

$$y_{n+k} = \sum_{i=1}^{n-m} \alpha_i K(x_i, x_{n-m+k}) + b \quad (6)$$

其中： $x_{n-m+k} = \{x_{n-m+k}, \dots, x_{n+1}, \dots, x_{n+k-1}\}$

本文采用的是径向基核函数：

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (7)$$

2 组合故障预测模型

本文采用 LSSVM 与 HMM 的组合方法，建立了一种组合故障预测模型，实现对模拟电路进行故障状态预测，主要分为 3 个模块：

模块 1：数据采集。对电路进行分析确定要改变的元件参数，选择合适的监测信号进行仿真，通过改变元件参数设置电路的不同状态，获得各状态数据，对数据进行预处理并将其分为训练数据和测试数据；

模块 2：故障预测。将训练数据输入到 LSSVM 模型进行回归训练，确定模型参数，训练结束后，通过前几个状态的观测数据对未来状态进行预测，得到未来状态的预测值；

模块 3：状态识别。首先将获得的各状态训练数据输入到 HMM 模型，得到各状态的 HMM 模型，再将 LSSVM 的预测值组成序列输入到训练好的 HMM 模型中进行状态识别，分

别计算各模型产生该预测序列的概率，根据最大似然概率值即可判断当前预测序列代表的退化状态，实现状态预测。

本文应用 LSSVM 的回归预测算法得到的是未来状态的预测值，而不是设备未来的状态，因为设备的状态是隐藏的。但 HMM 具有解码功能，能够进行状态识别，因此将 LSSVM 的预测值输入 HMM 中便可以估计出设备所处的状态和状态退化路径。所以 LSSVM 与 HMM 的组合方法能够实现直接对设备的状态进行故障预测。具体的组合故障预测流程如图 2 所示。

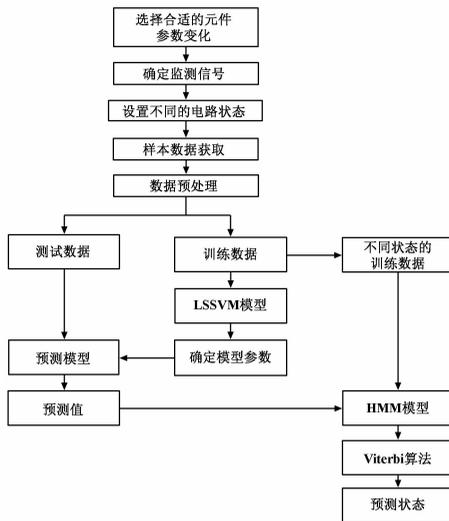


图 2 组合故障预测流程

3 实验仿真与结果分析

由于电子设备的退化状态数据很难获得，对整个电子设备（一个具有串并联结构的系统，如图 3 所示）的故障预测研究可以从一个类似的模拟电路故障预测研究出发，本文以 Sallen-Key 带通滤波器（图 4 所示）为例，采用 PSPICE 软件对该电路进行分析仿真，来获得退化状态数据。

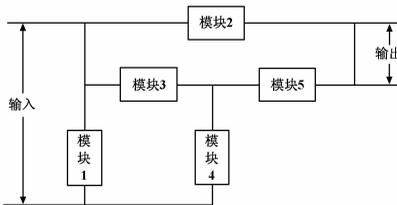


图 3 一个具有串并联结构的系统

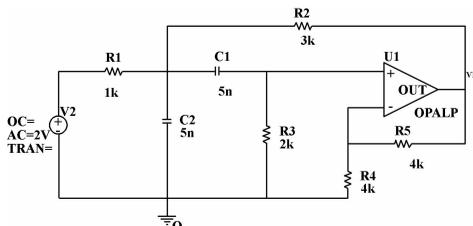


图 4 Sallen-Key 带通滤波器

3.1 数据来源

本文采用的信号源是 PSPICE 中的 VAC 模型，幅值 2 V，

幅角 0° , R_1, R_2, R_3, R_4, R_5 的容差为 $\pm 10\%$, C_1, C_2 的容差为 $\pm 5\%$ 。首先对该电路进行灵敏度分析, 发现 C_2 的变化对输出电压 $V(V_0)$ 的波形影响最大, 如图 5 所示, 当 C_2 取标称值和不同值时输出电压的波形曲线变化很明显, 因此对 C_2 的不同变化进行研究。

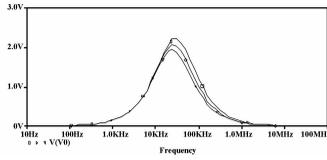


图 5 电路输出响应

本文只考虑 C_2 的变化对整个电路系统的影响, 其他元件参数均在容差范围内均匀变化, 以端节点 V_0 作为测试点, 对该电路进行频率响应分析。设 C_2 的容差变化范围分别为 $[5, 10]\%$, $[10, 15]\%$, $[15, 20]\%$, $[20, 25]\%$, $[25, 30]\%$, $[30, 35]\%$, $[35, 40]\%$, $[40, 45]\%$, $[45, 50]\%$ 来模拟该电路系统的故障退化过程, 加上正常状态共设置了 10 种状态, 分别对得到的每种状态进行 50 次蒙特卡罗分析, 图 6 为正常状态时 (所有元件都在容差范围内变化) 的仿真结果。

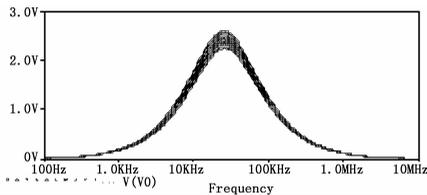


图 6 蒙特卡罗分析

结合图 5 和图 6 发现在 $25 \sim 300$ kHz 之间 C_2 的变化对电路的影响最为明显, 因此分别对每个状态取 25 kHz、50 kHz、80 kHz、100 kHz、150 kHz、200 kHz、300 kHz 对应的 7 个频响电压幅值构成一个 7 维的电压特征向量, 作为原始特征向量。其中每种状态有 50 组特征向量, 30 组作为训练样本, 20 组作为测试样本。

3.2 LSSVM 模型训练与预测

对正常状态和各退化状态取得的 7 维电压特征向量取平均值, 构成训练数据, 表 1 为各状态在对应频率下输出电压的平均值, 1~10 分别代表电路的正常状态、退化状态 2~9 和完全故障状态。

表 1 模拟电路在各状态下输出电压平均值

状态	25 kHz	50 kHz	80 kHz	100 kHz	150 kHz	200 kHz	300 kHz
1	2.4094	1.9761	1.4365	1.1856	0.8141	0.6257	0.4176
2	2.3748	1.9136	1.3792	1.1353	0.7773	0.5968	0.3980
3	2.3399	1.8540	1.3259	1.0888	0.7436	0.5704	0.3801
4	2.3048	1.7971	1.2763	1.0458	0.7126	0.5462	0.3637
5	2.2697	1.7429	1.2299	1.0059	0.6840	0.5239	0.3487
6	2.2346	1.6913	1.1865	0.9688	0.6576	0.5034	0.3349
7	2.1996	1.6421	1.1459	0.9342	0.6332	0.4844	0.3221
8	2.1649	1.5952	1.1079	0.9019	0.6104	0.4668	0.3103
9	2.1304	1.5506	1.0721	0.8717	0.5892	0.4504	0.2993
10	2.0962	1.5080	1.0384	0.8434	0.5694	0.4351	0.2761

从表 1 可以看出随着该电路的状态逐渐退化, 其所对应的各频率下的输出电压也逐渐降低, 因此证明了通过改变 C_2 的容差来模拟状态退化过程是合理的。

通过对训练样本训练, 确定嵌入维数为 4, 采用径向基核函数, 通过模型训练和对测试样本的预测确定 (σ^2, γ) 为 $(0.25, 100)$ 。从表 1 中选取 25 kHz 的各状态数据对其进行故障预测, 选取状态 1~4 的数据作为第一次训练样本, 得到状态 5 的预测值, 再选取状态 2~5 的数据作为第二次训练样本, 得到状态 6 的预测值, 依次类推, 得到状态 5~10 的预测值, 表 2 为各状态在 25 kHz 下的预测结果和误差率 (预测值-实际值)/实际值, 图 7 为各状态在 25 kHz 下的预测曲线。

表 2 各状态实际值与预测值的比较

状态	实际值	预测值	误差率 (%)
5	2.2697	2.2712	0.0658
6	2.2346	2.2373	0.1226
7	2.1996	2.2028	0.1452
8	2.1649	2.1701	0.2411
9	2.1304	2.1366	0.2913
10	2.0962	2.1028	0.3142

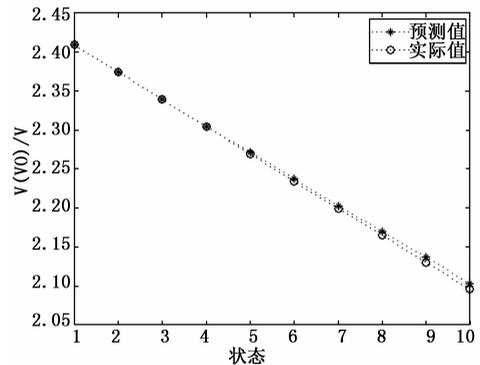


图 7 各状态实际值与预测值的比较

根据表 2 和图 7 可知, 采用 LSSVM 对电路进行故障预测效果较好, 误差率较低, 可见 LSSVM 能够实现对电子设备的退化状态进行预测。

3.3 状态预测

1) 对 HMM 进行模型训练, 状态数目为 5, 初始矩阵为 $[1, 0, 0, 0, 0]$, 状态转移矩阵 $[0.5, 0.5, 0, 0, 0; 0, 0.5, 0.5, 0, 0; 0, 0, 0.5, 0.5, 0; 0, 0, 0, 0.5, 0.5; 0, 0, 0, 0, 1]$ 。B 的初始值随机取值, 训练的迭代次数设为 60。将每种状态的训练样本输入模型中进行训练, 可获得 10 种 HMM 模型。

2) 将测试样本输入模型中进行状态识别, 概率最大则判定测试样本处于当前状态, 通过测试样本对模型进行检验, 直到达到理想状态识别时结束训练和测试。

3) 对状态 5~10 的每个频率进行对应的 LSSVM 预测, 可获得状态 5~10 在各个频率下的预测值, 每个状态可组成一个 7 维的预测向量, 每个状态可获得 10 个预测向量, 将预测向量输入训练好的 HMM 模型中进行状态识别, 得到状态预测结果如表 3 所示, 横向表示未来状态 5~10, 纵向表示当前应该所处的状态 5~10。

从表 3 中可以看出通过 LSSVM 预测得到的预测值再经过 HMM 状态识别便可以直接得到系统的预测状态，并且二者的组合能够得到很高的状态预测精度，本文的状态预测精度为 93.3%。从表 3 中还可以看出即使状态预测中出现了错误的判断，但都是将当前应该所处状态判断为下一个或两个退化状态，从维修角度考虑，这样判断的结果是提前对系统进行维修，同样可以降低维修费用，并保证系统的安全运行。

表 3 状态预测结果

状态	5	6	7	8	9	10
5	9	1				
6	8	1	1	7	10	
7			10			
8	10	9	9	1		
9					9	1
10						10

4 结论

针对现有故障预测方法不能对电子设备直接进行退化状态预测，本文提出了 LSSVM 与 HMM 组合故障预测方法，充分利用了 LSSVM 良好的非线性回归预测能力和 HMM 较强的解码功能，二者的结合能够直接预测模拟电路的故障状态，为状态维修提供了可靠的理论依据，且该方法具有一定的实际应用性，能够实现了对电子设备的状态预测。

参考文献:

[1] 康建设, 尹健, 王希星. CBM 系统与设备状态监测 [J]. 仪器仪表学报, 2006, 27 (6): 1748 - 1751.

(上接第 1484 页)

故障检测与诊断机制下过程控制系统前期稳态特征值线性增大并逐步趋于高稳态且功耗增加率较低，而无条件约束的故障检测与诊断机制使得过程控制系统始终处于低稳态，易受到故障、干扰等因素的影响，从而增加过多系统功耗，系统性能较差。

4 结束语

为了满足工业过程控制系统的稳定性需求和保障安全可靠的生产过程，研究了一种具有自定义多条件约束的多传感器故障检测与诊断机制。首先建立多输入多输出的非线性过程控制系统，加入稳态、时间和空间特征分析，得出多故障模型；然后在 R^n 空间内给出单故障、并发故障和通信故障描述及其约束规则及空间独立特性法则；最后给出了基于自定义多条件约束的多故障检测与诊断机制。实验分析结果表明，所提多故障检测与诊断机制不仅可以降低平均检测概率，避免并发故障导致系统性能下降，而且可以在统计测量过程中保持高稳态特性，并不增加过多系统功耗。

参考文献:

[1] Jong M L, S. Joe Qin, In-Beum Lee. Fault detection and diagnosis based on modified independent component analysis [J]. AIChE

[2] 彭宇, 刘大同, 彭喜元. 故障预测与健康管理技术综述 [J]. 电子测量与仪器学报, 2010, 24 (1): 1 - 9.

[3] 文莹, 肖明清, 胡雷刚, 等. 基于粗神经网络的航空电子设备故障预测研究 [J]. 计算机测量与控制, 2010, 18 (4): 807 - 809.

[4] Wang Q, Zhang S, Kang R. Research of small samples avionics prognostics based on Support Vector Machine [A]. Prognostics and System Health Management Conference (PHM - Shenzhen) [C]. 2011, 2011: 1 - 5.

[5] 范庚, 马登武, 邓力, 等. 基于灰色相关向量机的故障预测模型 [J]. 系统工程与电子技术, 2012, 34 (2): 424 - 428.

[6] 冯辅周, 司爱威, 江鹏程. 小波相关排列熵和 HMM 在故障预测中的应用 [J]. 振动工程学报, 2013, 26 (2): 269 - 275.

[7] 程进军, 夏智勋, 胡雷刚. 基于遗传神经网络的航空装备故障预测 [J]. 空军工程大学学报, 2011, 12 (1): 15 - 19.

[8] Jiang H, Li X W, Liu C J. Large margin hidden Markov models for speech recognition [J]. IEEE Transactions on Audio, Speech and Language Processing, 2006, 9 (5): 1584 - 1594.

[9] 黄景德, 郝学良, 黄义. 基于改进 HMM 的潜在电子故障状态识别模型 [J]. 仪器仪表学报, 2011, 32 (11): 2481 - 2486.

[10] 谭晓东. 基于 HMM 的滚动轴承故障预测技术 [D]. 北京: 国防科学技术大学, 2008.

[11] 许丽佳. 电子系统的故障预测与健康管理技术研究 [D]. 成都: 电子科技大学, 2009.

[12] Lee J M, et al. Diagnosis of mechanical fault signals using continuous hidden Markov model [J]. Journal of Sound and Vibration, 2004, 27 (6): 1065 - 1080.

[13] 连光耀, 吕晓明, 黄考利, 等. 基于最小二乘支持向量机的复杂装备故障预测模型研究 [J]. 计算机测量与控制, 2011, 19 (5): 1030 - 1032.

[1] Journal, 2006, 52 (10): 3501 - 3514.

[2] Ligang W, Peng S, Hui J G. State Estimation and Sliding-Mode Control of Markovian Jump Singular Systems [J]. IEEE Transactions on Automatic Control, 2010, 55 (5): 1213 - 1219.

[3] Bumiller, G., Lampe, L., Hrasnica, H. Power line communication networks for large-scale control and automation systems [J]. IEEE Communications Magazine, 2010, 48 (4): 106 - 113.

[4] 曲春绪, 霍林生, 李宏男. 基于 LMI 的结构主动控制系统故障诊断与隔离设计 [J]. 振动与冲击, 2012, 31 (10): 53 - 58.

[5] 王猛, 唐敦兵, 顾文斌, 等. 基于 RFID 离散制造业车间生产过程控制系统研究与开发 [J]. 中国制造业信息化, 2012, 41 (11): 13 - 17.

[6] 翟旭升, 谢寿生, 苗卓广, 等. 基于 T-S 模糊模型的航空发动机非线性分布式控制系统故障诊断 [J]. 航空动力学报, 2013, 28 (6): 1429 - 1435.

[7] 孙蓉, 刘胜, 李冰. 基于 UIO 的减摇鳍控制系统故障诊断算法 [J]. 哈尔滨工业大学学报, 2013, 45 (12): 105 - 110.

[8] 贾彩娟, 许晖. 基于改进多模滤波算法的控制系统故障诊断 [J]. 火力与指挥控制, 2012, 37 (3): 51 - 58.

[9] 柴天佑, 李少远, 王宏. 网络信息模式下复杂工业过程建模与控制 [J]. 自动化学报, 2013, 39 (5): 469 - 470.

[10] Wang C S, Wu M. Hierarchical Intelligent Control System and Its Application to the Sintering Process [J]. IEEE Transactions on Industrial Informatics, 2013, 9 (1): 190 - 197.