

航天发射场供气系统健康管理技术*

胡清忠^{1,2}, 褚福磊¹

(1. 清华大学机械工程系 北京,100084) (2. 航天发射场可靠性技术重点实验室 西昌,615000)

摘要 针对新一代航天发射场采用全新的在线供气模式,难以有效评估单样本设备健康状态的问题,提出一种基于隐马尔可夫的设备健康状态管理与预测方法。首先,利用设备监测数据构建隐马尔可夫健康状态评估模型,通过对不同观测序列与不同观测次数下的预测准确率进行仿真,确定出最优的模型参数;其次,把实时数据代入模型,根据模型的计算结果取最小值,从而判断出设备的健康状态;最后,将当前数据与历史数据进行拟合,预测出系统的安全可靠寿命。经实际检验,该方法有效解决了单样本多状态设备的健康评估。

关键词 隐马尔可夫;状态预测;健康管理;航天发射场

中图分类号 TH17;V215.7

引言

由于压缩气体具有制取容易、响应较快及远距离输送等优点,在中国新一代航天发射场中一改传统的气瓶供气模式,首次采用高压在线供气模式。在全新的供气模式下需要准确掌握其健康状态、预测其发展趋势,才能将发射风险降低到最小程度。由于发射场设备往往仅生产和使用一套或几套,且受近海盐雾和高温、高湿的影响,使用传统参数表征系统的可靠性和健康状态有较大的偏差,可信度不高。在这种情况下,以预测方法和技术为核心的故障预测和健康管理技术(prognosis and health management,简称 PHM)满足此要求^[1-5],对航天发射场的故障预测和健康管理技术具有重要的意义与用途。

目前,预测与健康状态管理的方法有 4 种:基于物理模型的预测方法、基于数据驱动的预测方法、基于模型驱动的预测方法^[6]和基于信息融合的预测方法^[7]。基于物理模型的预测方法利用对系统内部的深层认识建立模型进行预测,其效果依赖于模型的精确度,而在实际工程中,预测对象的精确模型很难建立,对发射场这种特有的大型设备就更难。基于数据驱动的预测方法利用来自传感器的数据信息进行预测,在预测过程中容易出现陷入局部最优解和计算过程收敛慢的缺陷。基于模型驱动的健康状态预测方法需要耗费较长的时间,不适合设备在线预

测。基于信息融合的预测方法易受权重值大的因素影响。因此,需要探索一种适用天航天发射场的健康预测方法。

由于发射场供气系统的健康状态不能直接观测,只能通过温度、压力和变形等参数表征其健康状态,这种通过观察参数来判断系统隐藏的健康状态与隐马尔可夫模型(hidden Markov models,简称 HMM)相通,两者都不可直接观测到结果,都有一个潜在的结构,在一定的时间跨度上系统的参数空间和时间一起发生变化,生成一个多变量的动态模式,可利用隐马尔可夫模型对供气系统的健康状态进行描述。

1 隐马尔可夫概述

隐马尔可夫是由马尔可夫链的演变发展而成的一种概率模型,能够将随机过程的统计特性表征出来^[8]。近年来,一些学者开展了隐马尔可夫模型的故障分类与预测研究。Chinanam 等^[9]和 Kwan 等^[10]在设备剩余寿命预测方面应用了隐马尔可夫模型。文献[11]采用有限元法和隐马尔可夫模型进行了设备故障模式识别。这些研究都取得了不错的效果。

隐马尔可夫模型和马尔可夫链不同,是一个双重的随机过程,其中一个用来反映状态的转移情况,另一个用来反映对象状态和对对象观察值之间的统计

* 国家自然科学基金资助项目(11472147)

收稿日期:2017-03-01;修回日期:2017-06-28

对应关系^[11]。在隐马尔可夫模型中,状态和状态之间的转移是一个随机过程,状态观察值也是随机的。如果通过观察者的方式查看对象的观察值,对象的明确状态不能直接看到,只有通过剩下的那个随机过程的描述才能感知对象状态的特性和存在。

隐马尔可夫模型的研究对象为一数据序列,包含一个具有状态转移概率阵 \mathbf{A} 的马尔可夫链和一个具有输出观测值的随机过程。由于被观察的对象状态是隐藏的,只能通过对观测序列随机过程的描述才能表现出来,状态之间要通过观测概率矩阵 \mathbf{B} 才能联系。单个隐马尔可夫模型可记为

$$\lambda = (N, M, \boldsymbol{\pi}, \mathbf{A}, \mathbf{B}) \quad (1)$$

简写为

$$\lambda = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B}) \quad (2)$$

其中: N 为模型的状态数目; M 为隐马尔可夫模型的观察符号数; $\boldsymbol{\pi}$ 为初始状态的概率集合, $\boldsymbol{\pi} = (\pi_1, \pi_2, \dots, \pi_N)$ 。; $\pi_i = P(q_1 = S_i), 1 \leq i \leq N$; S 为状态的集合; q_1 为初始时刻为 1 的状态; \mathbf{A} 为隐马尔可夫模型中的状态转移概率矩阵, $\mathbf{A} = \{a_{ij}\}_{N \times N}; a_{ij} = P(q_{i+1} = S_j | q_i = S_i), 1 \leq i, j \leq N$; \mathbf{B} 为隐马尔可夫模型中的观测值概率矩阵, $\mathbf{B} = \{b_{jk}\}_{N \times M}; b_{jk} = P(o_i = V_k | q_i = S_j), 1 \leq j \leq N, 1 \leq k \leq M$ 。

隐马尔可夫模型主要解决评估、解码和学习 3 类问题^[12]。

2 供气系统的 HMM 模型

采用隐马尔可夫模型对系统进行健康状态管理,需要进行健康状态特征的提取、建立 HMM 模型并进行训练以及作出健康状态评估 3 个步骤。其基本过程如图 1 所示。

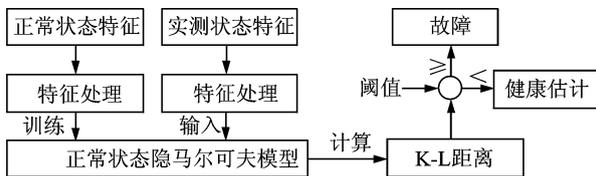


图 1 基于 HMM 的健康管理流程图

Fig. 1 Health management flow chart based on hmm

2.1 健康状态特征的提取

特征提取是进行健康状态预测的基础。在多个监测信号的情况下提取的特征就有多个,这些健康状态特征具有冗余性和高维性的特点。如将这些特征直接应用于健康状态评估,将会极大降低评估与预测效率,从而出现偏差,所以必须根据工程的实际

需求和算法实现的需要,对获得的特征进行必要的空间状态变换,从而在低维空间内获取最优的健康状态特征,有效实现对系统的健康精确评估与故障预测。健康状态的特征提取过程如图 2 所示。

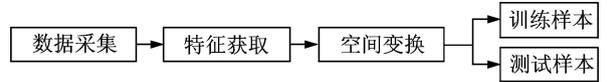


图 2 特征提取示意框图

Fig. 2 Feature extraction diagram

2.2 隐马尔可夫模型的训练

为满足隐马尔可夫模型进行健康状态管理与预测所需要的多组观测数据序列,采用从设备正常状态的特征数据中随机选择 N 次观测值的方法,把这些观测值重新组合,构成一组观测数据序列来满足 HMM 的需要。

对于观测数据系列,HMM 训练可使用鲍姆-韦尔奇算法进行极大似然估计,得到模型参数 $\lambda = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 。对于连续隐马尔可夫模型,使用维特比匹配算法把样本分成 N 个段,分成的每一段对应了隐马尔可夫模型的一个状态,利用 K 均值聚类算法给每个观测矩阵分配对应的状态序号,估算出初始模型参数。对于离散隐马尔可夫模型,通过改进训练算法确定初始参数值。为了提高隐马尔可夫模型在使用中的稳定性,需要应用重估算法对多组观测数据序列进行 HMM 训练。

2.3 健康状态评估

为了对系统进行精确的健康状态估计与预测,引入 Kullback-Leibler 距离对健康状态特征进行定量评估,根据 Kullback-Leibler 距离的大小计算系统偏离正常状态的程度,从而准确评估出系统的健康状况。

2.4 供气系统的 HMM 模型

在供气系统的健康状态评估中,一般将其健康状态划分为两类:正常状态与故障状态。由于健康的正常状态劣化至故障状态是一个缓变的历程,其健康状况是逐渐劣化,如果能对劣化过程详细描述并赋予其相应的中间状态来表示,就可以解释其故障发生过程,从而采取有效措施避免故障发生,真实反映出供气系统的健康状态,所以增加一个中间故障态来反映设备的健康变化过程。

由于设备故障的严重程度是随时间而逐渐变大的,从正常健康状态到故障状态的过程具有不可逆

变性,所以采用左右型的隐马尔可夫模型对供气系统进行健康状态评估与预测,能够真实反映出设备健康劣化过程,如图 3 所示。

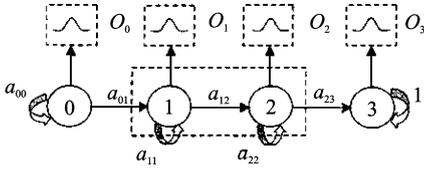


图 3 供气系统的 HMM 结构

Fig. 3 HMM structure of gas supply system

如图 3 所示,将供气系统的健康状态分成正常工作状态(0),早期故障状态(1),中间故障状态(2)和完全故障状态(3)。中间的状态由状态 1 和状态 2 构成。HMM 模型状态间的转移概率值用 a_{ij} ($i, j=0, 1, 2, 3$) 表示,观测数据序列用 O_k ($k=0, 1, 2, 3$) 表示。

供气系统工作初期,系统工作正常。HMM 中的初始状态概率参数设为

$$\boldsymbol{\pi} = [1 \quad 0 \quad 0 \quad 0] \quad (6)$$

状态转移概率矩阵 \mathbf{A} 为

$$\mathbf{A} = \begin{bmatrix} a_{00} & a_{01} & 0 & 0 \\ 0 & a_{11} & a_{12} & 0 \\ 0 & 0 & a_{22} & a_{23} \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (7)$$

由于观测值是连续的,因此采用连续隐马尔可夫模型来确定观测矩阵 \mathbf{B} 。针对实际应用过程中高斯概率密度函数不能满足使用要求这种情况,采用

多个高斯概率密度函数的线性组合来模拟产生对象的观测序列。通过大量的观测样本特征统计能够得到高斯概率密度函数自身的均值和协方差矩阵。观测矩阵 \mathbf{B} 为

$$\mathbf{B} = \{b_j(\mathbf{O}), j=1, 2, \dots, N\} \\ b_j(\mathbf{O}) = \sum_{m=1}^M C_{jm} H[\mathbf{O}, \mu_m, \mathbf{U}_{jm}] \quad (8)$$

其中: \mathbf{O} 为观测序列矩阵; C_{jm} 为状态 j 的第 m 个混合系数; H 为高斯概率密度; μ_m 为状态 j 的第 m 个混合成分均值; \mathbf{U}_{jm} 为协方差矩阵。

由于 HMM 模型的参数已确定,因此供气系统的隐马尔可夫模型记为 $\lambda = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 。

3 供气系统的健康状态评估

新一代航天发射场液氮供气系统气源由液氮汽化而成,为满足大流量的用气要求,采用大型低温液氮贮罐进行液氮贮存。液氮贮罐监测的参数有贮罐压力(P_{119})、上部温度(T_{109})、下部温度(T_{110})和夹层温度(T_{111})。

选取供气系统在实际工作中液氮贮罐预冷过程时的所有数据作为供气系统 HMM 的训练数据。其中:正常数据为液氮预冷和汽化过程中的正常数据;异常数据为贮罐预冷过程中发生爆破膜破裂和压力传感器异常的数据。正规化后数据(无量纲)如表 1 所示。根据式(6)~(8),采用系统的观测序列训练 HMM,为了增加系统 HMM 的稳定性,训练时采用系统多组观测序列的重估算法。

表 1 选取的训练数据

Tab. 1 Selection of training data

状态	参数	各时段值						
		t_1	t_2	t_3	t_4	t_5	t_6	t_7
正 常 数 据	P_{119}	-1.862 5	-1.862 5	-1.862 5	-1.862 5	-1.853 0	-1.853 0	-1.853 0
	T_{109}	-1.524 0	-1.524 0	-1.524 0	-1.524 0	-1.524 0	-1.524 0	-1.524 0
	T_{110}	1.340 1	1.340 1	1.340 1	1.351 0	1.361 9	1.361 9	1.361 9
	T_{111}	1.870 4	1.858 9	1.858 9	1.858 9	1.858 9	1.858 9	1.847 3
异 常 数 据	P_{119}	2.232 2	2.232 2	2.232 2	2.196 3	2.196 3	2.196 3	2.160 5
	T_{109}	-1.774 8	-1.774 8	-1.774 8	-1.753 6	-1.753 6	-1.753 6	-1.753 6
	T_{110}	-1.339 9	-1.339 9	-1.339 9	-1.339 9	-1.339 9	-1.299 9	-1.299 9
	T_{111}	-2.155 4	-2.155 4	-2.155 4	-2.155 4	-2.155 4	-2.155 4	-2.114 8

根据训练结果,液氮罐的状态转移矩阵 \mathbf{A} 为

$$\mathbf{A} = \begin{bmatrix} 0.824 8 & 0.175 2 & 0 & 0 \\ 0 & 0.935 2 & 0.064 8 & 0 \\ 0 & 0 & 0.926 6 & 0.073 4 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

系统的观测值概率矩阵 \mathbf{B} 为

$$\mathbf{B} = \begin{bmatrix} 0 & 0.592 5 & 0.407 5 & 0 \\ 0.271 2 & 0.073 8 & 0.209 1 & 0.445 9 \\ 0.183 2 & 0.061 6 & 0.182 5 & 0.572 7 \\ 0.035 0 & 0.109 2 & 0.367 9 & 0.487 9 \end{bmatrix}$$

通过基于 Viterbi 算法的训练得到转移矩阵 A 和混淆矩阵 B 。为了考察其序列长度与预测准确率之间的关系,采用逐步递增的方法观察状态系列从 10 增加到 1 000,记录各次预报准确率的情况,预测结果准确率如图 4 所示。可以看到,随着测试系列的增加,预测准确率会越来越高,在 300 个测试序列以上的情况下准确率已经达到了 99%,因此选择 300 个测试序列作为其分析标准。

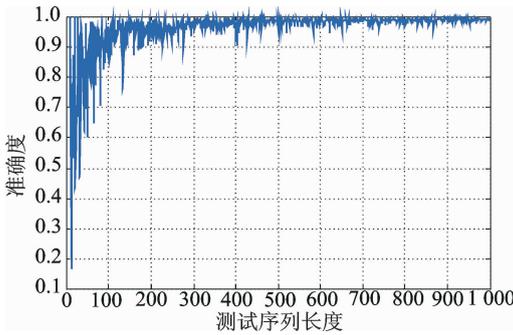


图 4 不同测试序列下的预测准确率

Fig. 4 Under different test sequence prediction accuracy

为了检验在 300 个观察测试序列情况下的预测的准确率,采用多次观察检验的方法,在随机 200 次的情况下记录各次预报准确率。随着测试次数的增加,预测准确率有一定的波动,但是准确率都在 90% 以上,准确率的平均值为 0.973 9,方差为 0.018 9,说明选择 300 个测试序列作为其分析标准是可行的。

以上试验表明,供气系统的隐马尔可夫模型是可行和可信的,因此选取供气系统实际数据进行应用测试。在实际工作过程中发生了 4 个典型情况,开始时,液氮罐处于正常的静态贮存,然后系统补充液氮进入液氮罐,这些液氮在线汽化生产供给产品使用,工作完成后又转入常规贮存状态。选取不同的状态对模型进行测试和状态识别,依次将时间序列数据正规化送入 HMM 计算正常态、弱故障态、中间故障态和完全故障态(均为无量纲),从中取最小值作为最终判定结果,测试结果如表 2 所示。

表 2 实际数据测试结果

Tab. 2 Actual data test result

工况	正常态	弱故障态	中间故障态	完全故障态	判定结果
静态贮存	39.097 5	48.245 9	532.871 2	393.315 9	正常态
转注液氮	48.854 6	37.487 7	235.512 4	241.404 5	弱故障态
使用液氮	45.802 0	46.238 7	88.540 3	91.376 8	正常态
常规贮存	41.592 7	44.328 4	723.128 6	634.692 3	正常态

由表 2 可知,在 4 种情况下系统测试结果表明只有在液氮转注过程中有弱故障情况,其他 3 种工况均正常,这与实际相符。这是因为液氮转注过程中,为防止贮罐超压,采取了手动控制进液量并打开贮罐放气阀的临时措施,这种情况判别为弱故障态是可以的。

对液氮贮罐预冷状态和任务状态的测试表明,HMM 模型能在液氮贮罐的健康状态判别中能有效识别各种状态。

4 供气系统健康状态预测

为有效评估系统的健康情况,引入健康指数对供气系统进行定量评估,规定 X_n 为正常状态的值, T 为供气系统健康状态的特征参数,则

- 1) 当 $T \in [0.90X_n \sim 1.00X_n]$,健康指数为 1;
- 2) 当 $T \in [0.80X_n \sim 0.90X_n]$,健康指数为 0.9;
-

3) 当 $T \in [0.05X_n \sim 0.10X_n]$,健康指数为 0。

采用以上方法对整个供气系统的健康状态进行评估,收集的数据为投入使用这一年的数据,健康状态的评估结果如图 5 所示。在当前工作条件下随着时间的推移,供气系统的健康状态逐步下降,其中出现了一次跳跃数据,这是由于根据任务使用需要,转入了大量的液氮,转注过程中温度升高所致。经处理后温度下降到正常值,继续使用直到工作结束。

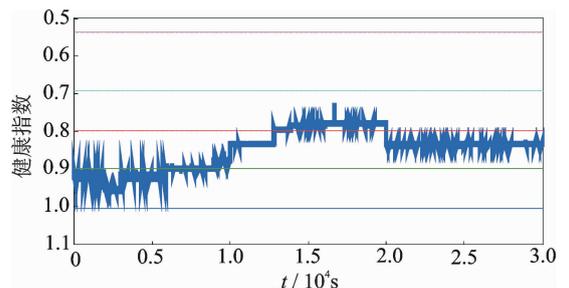
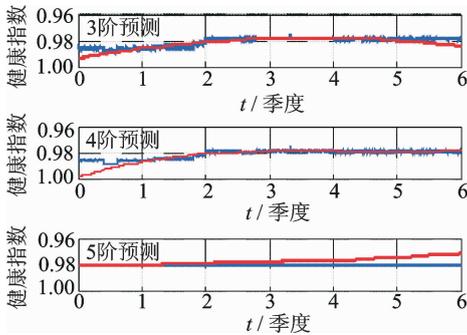


图 5 供气系统健康指数

Fig. 5 Health index gas supply system

采用供气系统液氮贮罐近一年的监测数据,分别采用3,4,5阶对反映系统绝热状态的 T_{110} 温度变化情况进行液氮贮罐健康状态预测,如图6所示。



蓝色曲线为实测温度数据;红色为预测数据

图6 不同阶次的健康指数预测

Fig. 6 Different levels of health index forecast

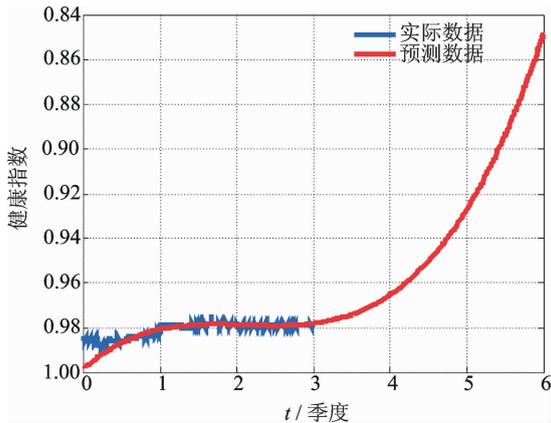


图7 供气系统寿命预测

Fig. 7 Gas supply system life prediction

5 结论

1) 对于具有与隐马尔可夫模型内部结构相同的单样本设备的健康状态评估与预测是可行的。

2) 对HMM进行训练时,随着样本系列的增加,预测准确率会越来越高。在300个测试序列以上的情况下,准确率已经达到了99%。

3) 采用历史数据对系统进行健康状态预测,历史数据量变大,预测结果的准确率就越高。

4) 基于隐马尔可夫模型与趋势预测方法在航天发射场供气系统实际应用表明其是有效可行的,对其他单样本健康状态管理提供了借鉴,具有良好的应用前景。

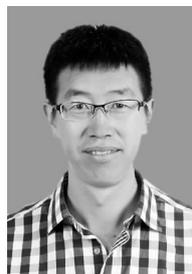
参 考 文 献

[1] 林泽力,郑国,莫固良,等. 基于模糊综合评判的飞机液压泵故障预测[J]. 振动、测试与诊断, 2016, 36(4): 747-750.

Lin Zeli, Zheng Guo, Mo Gulian, et al. Prediction of

aircraft hydraulic pump fault based on fuzzy comprehensive evaluation[J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(4): 747-750. (in Chinese)

- [2] 王俨凯,马进锐,廖明夫,等. 发动机振动趋势预测模型研究法[J]. 振动、测试与诊断, 2014, 34(3): 516-523.
Wan Yankai, Ma Jinrui, Liao Mingfu, et al. Research on trend prediction model of engine vibration[J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(3): 516-523. (in Chinese)
- [3] 曾庆虎. 机械传动系统关键零部件故障预测技术研究[D]. 长沙:国防科技大学, 2010.
- [4] Peng Yu, Liu Datong, Peng Xiyuan. A review: prognostics and health management[J]. Journal of Electronic Measurement and Instrument, 2010, 24(1): 1-9.
- [5] Andrew K S, Lin Daming, Dragan B J, et al. A review on machinery diagnostics and prognostics implementing condition-based maintenance[J]. Mechanical Systems and Signal Processing, 2006(20): 1483-1510.
- [6] 邵延君,潘宏侠,马春茂,等. 基于新陈代谢组合模型的装备故障预测[J]. 振动、测试与诊断, 2015, 35(2): 359-362.
Shao Yanjun, Pan Hongxia, Ma Chunmao, et al. Analysis of equipment fault prediction based on the metabolism combined mode[J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(2): 359-362. (in Chinese)
- [7] 刘勤明. 基于状态监测信息的设备在线健康预测及维护优化研究[D]. 上海:上海交通大学, 2014.
- [8] 许丽佳. 电子系统的故障预测与健康管理工作研究[D]. 成都:电子科技大学, 2009.
- [9] Chinanam R B, Baruah P. Autonomous diagnostics and prognostics through competitive learning driven HMM-based clustering[C]// Proceedings of the International Joint Conference on Neural Networks 2003. New York: [s. n.], 2003: 2466-2471.
- [10] Kwan C, Zhang X, Xu R, et al. A novel approach to fault diagnostics and Prognostics[C]// Proceedings of the 2003 IEEE International Conference on Robotics and Automation. New York: [s. n.], 2003: 604-609.
- [11] Li Zhinong, Han Jie, Sun Junjie, et al. Fault recognition method based on independent component analysis and hidden Markov model[J]. Journal of Vibration and Control, 2007, 13(2): 125-137.
- [12] Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition[J]. Proceedings of the IEEE, 1989, 77(2): 257-286.



第一作者简介:胡清忠,男,1972年6月生,高级工程师。主要研究方向为航天发射场机械故障诊断、预测和健康管理技术等。曾发表《基于 Hilbert 解调的滚动轴承故障诊断分析》(《振动与冲击》2010年第29卷)等论文。
E-mail: huqingz@163.com

