

DOI: 10.13382/j.jemi.B2104292

基于 Entropy-SKF 的机载氧气浓缩器退化分析*

张庆一¹ 景博¹ 焦晓璇¹ 王生龙¹ 鲍杰¹ 龙迎利² 窦雯³

(1. 空军工程大学 航空工程学院 西安 710038; 2. 威海技师学院 威海 264200; 3. 空军成都代表局 成都 610000)

摘要:基于分子筛床变压吸附原理的机载氧气浓缩器是飞机生命保障系统的核心部件,可以为飞行员在飞行过程中提供氧气。对机载氧气浓缩器进行退化分析,可以实现故障预警,对机载氧气浓缩器的视情维修和构建飞机健康管理具有重要意义。机载氧气浓缩器的退化过程可以分为平稳阶段和加速退化两个阶段,但是由于退化模式变化点的不确定性,导致了退化模式转变的不确定性,因此正确识别退化模式转折点十分重要。氧分压值是反映机载氧气浓缩器制氧能力的一个重要参数,利用数据驱动的方法,针对模式转换的模糊性,首先提取数据的香农熵,然后通过转换卡尔曼(SKF)滤波器对实时数据样本进行处理,根据稳态退化和加速退化两个滤波器之间的后验概率来识别当前的退化模式,识别结果与实际情况相符,最后与小波分解和 K-means 算法进行对比,证明了基于信息熵的转换卡尔曼滤波器(Entropy-SKF)算法的有效性。

关键词:氧气浓缩器;香农熵;卡尔曼滤波;阶段识别

中图分类号: TN702; TP202 **文献标识码:** A **国家标准学科分类代码:** 510.40

Degradation stage identification of airborne oxygen concentrator based on Entropy-SKF

Zhang Qingyi¹ Jing Bo¹ Jiao Xiaoxuan¹ Wang Shenglong¹ Bao Jie¹ Long Yingli² Dou Wen³

(1. College of Aeronautics Engineering, Air Force Engineering University, Xi'an 710038, China;

2. Weihai Technician College, Weihai 264200, China; 3. Chengdu Representative Office of Air Force, Chengdu 610000, China)

Abstract: Airborne oxygen concentrator based on molecular sieve bed pressure swing adsorption principle is the core component of aircraft life support system, which can provide oxygen for pilots during flight. The degradation analysis of airborne oxygen concentrator can realize fault early warning, which is of great significance for the condition based maintenance of airborne oxygen concentrator and the construction of aircraft health management system. The degradation process of airborne oxygen concentrator can be divided into two stages: steady stage and accelerated degradation stage. However, due to the uncertainty of degradation mode change point, the transformation of degradation mode is uncertain. Therefore, it is very important to correctly identify the turning point of degradation mode. Oxygen partial pressure is an important parameter to reflect the oxygen production capacity of airborne oxygen concentrator. In this paper, the Shannon entropy of the data is extracted by using the data-driven method. Then the SKF filter is used to process the real-time data samples. The current degradation mode is identified according to the posterior probability between the steady-state degradation filter and the accelerated degradation filter, the recognition results are consistent with the actual situation. Finally, compared with wavelet decomposition and K-means algorithm, the effectiveness of Entropy-SKF algorithm is proved.

Keywords: oxygen concentrator; Shannon entropy; Kalman filtering; stage identification

0 引言

机载氧气浓缩器是构成飞机生命保障系统的重要机

载部件,通过利用分子筛床的变压吸附原理将空气中的氮气溶质进行吸附,得到提纯的富氧气体。机载氧气浓缩器为飞机提供飞行期间自主制氧的能力,在空气稀薄的高空为飞行员提供呼吸所需的氧气,保证其正常工作

收稿日期: 2021-05-15 Received Date: 2021-05-15

* 基金项目: 国防科技创新特区项目(193-M06-001-002-05)、航空科学基金(20200033096001)、空军预先研究项目(3030507-2)资助

是飞机飞行安全的重要保障。因此,需要对其进行退化分析,以掌握其实际性能状况和性能的发展趋势,并根据监测和诊断的结果作出合理的维修安排^[1]。


退化状态识别主要包括提取退化特征以及建立退化模型两个关键步骤^[2],并且现有的方法实际上很难直接应用于具有非线性退化过程的对象^[3]。对于多退化模式的剩余寿命建模,大多数学者采用多模型融合的方法。Li 等^[4]提出了局部加权线性回归方法来建模机载轴承的多个退化模型,并利用集成学习方法进行在线模式识别。Xiao 等^[5]提出了一种基于内模 GM 和最小二乘支持向量机(LSSVM)的组合预测模型,并证明比单一预测模型更准确。上述方法采用不变模型,各模型的权重由离线数据训练得到,并在运行过程中锁定,当设备参数不同时,每个型号的型号和重量可能不准确。此外,Shakya 等^[6]应用切比雪夫不等式和马氏距离。虽然能够在在线识别故障的严重程度,但是精度较低,不能准确识别状态变化,Singh 等^[7]计算各 IMF 之间的 JRD 作为相似性评估参数,优选集成经验模态分解的 IMF,并运用幅值特征来评估机械器件退化状态。JRD 值在度量状态相似性上具有优异表现,但是作为反应退化敏感性和单调性方面不理想。Tomoaki 等^[8]运用反馈神经网络处理传统统计特征和经验模态分解(EMD)的 IMF 能量熵来评估设备退化状态,但传统的统计特征和 EMD 能量熵不具有良好的单调性。

针对机载氧气浓缩器退化过程中变化点的不确定性,提出了寻找退化过程转折点的基于信息熵的转换卡尔曼滤波器(Entropy-SKF)的算法。本文先对机载氧气浓缩器的工作原理和退化机理进行分析,然后介绍整个算法的流程,最后进行数据验证和三种算法对比。结果表明,该算法能够实时对机载氧气浓缩器的退化进行分析,对故障预警和视情维修具有重要意义。

1 机载氧气浓缩器工作原理及退化分析

机载氧气浓缩器采用三床式结构^[9],其结构原理如图 1 所示。

在飞机空中制氧时,从飞机发动机引出的压缩空气经过飞机环控系统净化、冷却后进入氧气浓缩器,流经入口过滤器进入进气罐中的减压器,经减压后的气体进入电控气动阀和电磁阀,电磁阀断电,通过对电控气动阀膜上腔气压的间接控制,使排气阀关闭,进气阀开启,进而使分子筛床加压吸附,并打开单向活门输出富氧产品气,同时通过冲洗装置向另外两个分子筛床输出冲洗流量;电磁阀通电,使排气阀开启、进气阀关闭,进而使分子筛床卸压解吸。3 个分子筛床如此交互循环工作,实施加压吸附、卸压解吸和冲洗净化过程,获得富氧产



1. 入口过滤器;2. 压力传感器;3. 进气罐;4 安全活门;5. 电控气动阀;6. 电磁阀;7. 单向阀;8. 冲洗装置;9. 分子筛床; 10. 出口过滤器;11. 储气罐;12. 氧分压传感器

图 1 氧气浓缩器原理

Fig. 1 Schematic diagram of oxygen concentrator

品气^[10]。

分子筛是机载氧气浓缩器的重要组成部分,结构如图 2 所示^[11],湿空气中主要成分是 H₂O 和 N₂,氧气浓缩器在工作时,水汽分子在 N₂ 分子之前被优先吸附,而且已经吸附了水汽分子的分子筛不再具有吸附 N₂ 分子的能力。从宏观上说,水蒸气存在时相当于减少分子筛的装填量。若吸附剂所吸附的水汽不能在正常的变压吸附空气过程中得到很好的解吸,则必然导致系统气体分离产氧能力的下降。在通常情况下,引气中都会留存一定量的水蒸气,从而导致了氧气浓缩器性能的退化。




图 2 分子筛结构

Fig. 2 Molecular sieve structure

2 基于 Entropy-SKF 算法的退化模式分析

基于性能退化数据的可靠性研究通常通过性能退化数据来进行分析^[12], 由于在实际工作中, 维修人员主要通过氧分压值的变化来判断当前机载氧气浓缩器的制氧能力, 所以本文对退化数据的氧分压值进行分析。随着高度的增加, 大气压力将会降低, 对于机载氧气浓缩器工作机理进行分析, 环境压力的降低有利于氮气的排出, 因此, 高度的变化可能会引起氧分压的波动。考虑到高度的影响, 对 2 000~12 000 m 的数据每 1 000 m 进行一次分段, 对不同飞行高度段的数据分别进行研究。

如图 3 所示, 机载氧气浓缩器的退化过程具有非线性特点, 前半阶段数据波动程度较小, 机载氧气浓缩器制氧效果好, 在使用的过程中分子筛的填充量增加, 制氧能力下降, 造成后半阶段数据震荡下降, 最后数据发生突变, 通过查询部件返厂记录, 发现数据突变原因为膜片破损。




图3 氧分压变化折线图

Fig. 3 Line chart of oxygen partial pressure change

退化特征提取主要计算反映性能退化规律的特征参数, 是实现退化状态识别的基础^[13]。本文利用 Entropy-SKF 的方法, 首先求取数据的特征熵, 提取数据的退化特征, 最后利用 SKF 判断机载氧气浓缩器的退化阶段。

2.1 基于香农熵的退化特征提取

香农熵是热力学的概念, 用来表征信息不确定性的^[14]大小, 在数据处理中, 香农熵可以用来表示数据的复杂度, 可以通过香农熵的计算来进行数据的分类。对机载氧气浓缩器飞行氧分压分段进行香农熵的求取, 式(1)为香农熵公式。

$$H(X) = - \sum_{x \in X} p(x) \log p(x) \quad (1)$$

式中: $H(X)$ 代表确定度的大小; $p(x)$ 是一个概率值, 数据越混乱, 信息熵越大。 $H(X)$ 越大, 数据的信息越不容易搞清楚, 处理数据就是 $H(X)$ 减小的过程。

对机载氧气浓缩器退化数据进行分段处理, 可以取某一个时间间隔内的数据分为一段, 然后对每一段进行香农熵的计算, 计算过程如下:

- 1) 对每一段的数据归一化处理;
- 2) 列出归一化后数据的最大值 a 和最小值 b , 最大值与最小值之间的差值 d ;
- 3) 数据平均分为 n 段, 每段的段落间隔为 d/n ;
- 4) $p(x)$ 为各个小间隔内的数据量与总数据量的比值;
- 5) 代入公式计算香农熵。

如图 4 所示, 经过求取香农熵之后, 到达某一点后, 香农熵会直线上升, 并且能够维持在较高水平, 与机载氧气浓缩器氧分压折线图一致。




图4 香农熵变化值

Fig. 4 Shannon entropy change value

2.2 基于 SKF 的退化阶段识别

卡尔曼滤波器是一种递推线性最小方差滤波器^[15]。在存在系统噪声和量测噪声的情况下, 可以根据最小方差准则实现状态的动态估计。卡尔曼滤波过程状态的空间模型描述如式(2)、(3)。

状态方程:

$$\mathbf{X}_k = \Phi_{k,k-1} \mathbf{X}_{k-1} + \Gamma_{k-1} \mathbf{W}_{k-1} \quad (2)$$

量测方程:

$$\mathbf{Z}_k = \mathbf{H}_k \mathbf{X}_k + \mathbf{V}_k \quad (3)$$

式中: \mathbf{X} 为系统中无法通过观测直接得到的待估计状态; \mathbf{Z} 为传感器采集的数量序列, 间接反映 \mathbf{X} 的值; Φ 为系统的一步状态转移矩阵; \mathbf{H} 为测量矩阵; Γ 为系统噪声驱动矩阵; \mathbf{W} 为系统噪声序列, \mathbf{V} 为测量噪声序列。

卡尔曼滤波器的信息更新过程包括式(4)、(5)中的时间更新过程和式(6)~(8)中的量测更新过程。

时间更新:

$$\hat{\mathbf{X}}_{k|k-1} = \Phi_{k,k-1} \hat{\mathbf{X}}_{k-1} \quad (4)$$

$$\mathbf{P}_{k|k-1} = \Phi_{k,k-1} \mathbf{P}_{k-1} \Phi_{k,k-1}^T + \Gamma_{k-1} \mathbf{Q}_t \Gamma_{k-1}^T \quad (5)$$

量测更新:

$$\hat{X}_k = X_{klk-1} + K_k(Z_k - H_k \hat{X}_{klk-1}) \quad (6)$$

$$K_k = P_{klk-1} H_k^T (H_k P_{klk-1} H_k^T + R_k)^{-1} \quad (7)$$

$$P_k = (I - K_k H_k) P_{klk-1} \quad (8)$$

式中: Q 为系统噪声方差矩阵; R 为测量噪声方差矩阵。

即使在有噪声干扰的情况下,卡尔曼滤波器也能对系统的下一个状态做出有根据的预测^[16]。卡尔曼滤波使用线性状态方程来估计系统的状态,当系统方程和测量方程是非线性且时变时,则卡尔曼滤波很难对其进行精确估计。为了克服这一局限性,本研究采用 SKF 滤波器对非线性系统进行实时状态估计。

SKF 滤波器由多个标准卡尔曼滤波器组成,并针对每个退化过程建立模型,以反映其退化趋势。多个过滤器同时过滤单个样本的实时数据,广义伪贝叶斯(GPB)算法对前一时刻每个滤波器输出的状态估计值进行加权求和来实现系统状态的动态估计。多卡尔曼滤波的具体流程如下。

通过模型概率 S_k^i 和模型转换概率 T_{ij}^i 得到模型转换条件概率 S_k^{ij} ,其表示系统状态从 S_{k-1}^i 转换为 S_k^j 的概率:

$$S_k^{ij} = \frac{T_{ij}^i S_{k-1}^i}{\sum_{i=1}^n T_{ij}^i S_{k-1}^i} \quad (9)$$

根据每个滤波器在前一时刻的状态和每个滤波器的条件转移概率,通过折叠法更新输入状态 \hat{X}_{k-1} 和方差 \hat{P}_{k-1}^i ,如下:

$$\hat{X}_{k-1}^j = \sum_{i=1}^n S_k^{ij} \hat{X}_{k-1}^i \quad (10)$$

$$\hat{P}_{k-1}^j = \sum_{i=1}^n S_k^{ij} [\hat{P}_{k-1}^i + (\hat{X}_{k-1}^i - \hat{X}_{k-1}^j)(\hat{X}_{k-1}^i - \hat{X}_{k-1}^j)^T] \quad (11)$$

然后,标准卡尔曼滤波器操作通过式(11)~(15)修正状态和方差,同时给出了各模型的状态估计 \hat{X}_{k-1} 和方差 \hat{P}_{k-1}^i 。在时间更新步骤式(11)和(12)后,通过状态测量和状态估计的偏差得到测量残差 V_k 和残差方差 C_k ^[17],如下:

$$V_k^i = Z_k^i - H_k^i \hat{X}_{klk-1}^i \quad (12)$$

$$C_k^i = H_k^i \hat{P}_{klk-1}^i H_k^{iT} + R_k^i \quad (13)$$

以残差方差的正态分布概率 Lm_k^i 作为每个滤波器的概率,每个滤波器的概率为均值为 0、方差为 C_k^i 的正态分布在 V_k^i 处的概率:

$$Lm_k^i = N(V_k^i; 0, C_k^i) \quad (14)$$

从状态转移矩阵和上一时刻每个模型的概率 S_{k-1}^i 计算此时每个滤波器的概率 Lt_k^i :

$$Lt_k^i = \sum_{i=1}^n T_{ij}^i S_{k-1}^i \quad (15)$$

结合测量残差导出的滤波器概率 Lm_k^i 和状态转移导出的滤波器概率 Lt_k^i ,定义各模型的归一化概率如下:

$$S_k^i = \frac{Lm_k^i Lt_k^i}{\sum_{i=1}^n (Lm_k^i Lt_k^i)} \quad (16)$$

每次迭代更新的输入状态:

$$\hat{X}_k = \sum_{i=1}^n (S_k^i \hat{X}_k^i) \quad (17)$$

每次迭代更新的输入方差:

$$P_k = \sum_{i=1}^n S_k^i [P_k^i (\hat{X}_k^i - X_k)(\hat{X}_k^i - X_k)^T] \quad (18)$$

式中: $i, j = 1, 2, 3, \dots, n$ 为滤波器序号, $k = 1, 2, 3, \dots, m$ 为时间。不同模型之间的模型概率关系反映了目前各退化阶段的置信度。通过实时监测模型概率,可以判断退化过程的阶段。

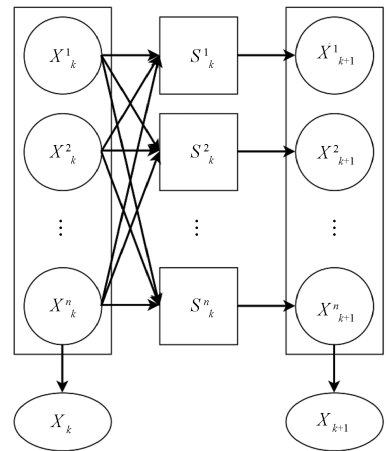


图 5 SKF 滤波原理

Fig. 5 schematic diagram of SKF filtering

2.3 算法流程

Entropy-SKF 算法算法流程如图 6 所示。具体实施步骤如下。

1) 特征提取,对数据进行香农熵的提取,估计退化的粗略趋势。

2) 数据过滤,根据式(9)~(15)将实时数据输入滤波器,多个卡尔曼滤波器同时进行处理。对标准卡尔曼滤波器中的参数进行更新,每个滤波器的输出为预测状态估计 \hat{X}_k^i 、预测估计协方差 P_k^i 、测量残差和残差协方差 C_k^i 。

3) 阶段识别,使用式(14)~(16)计算各模型的归一化概率 S_k^i 。随着退化过程的加剧,平稳退化模型概率减小,加速退化模型概率 S_k^i 相应增大,因此该概率可视为对相应退化模式的置信度。如果进入加速退化阶段,继续进行下一步,定义预测起始点,并在变化点和起始点之间采样训练集。如果没有进入加速退化阶段,则继续滤

波过程。

4) 处理完成。

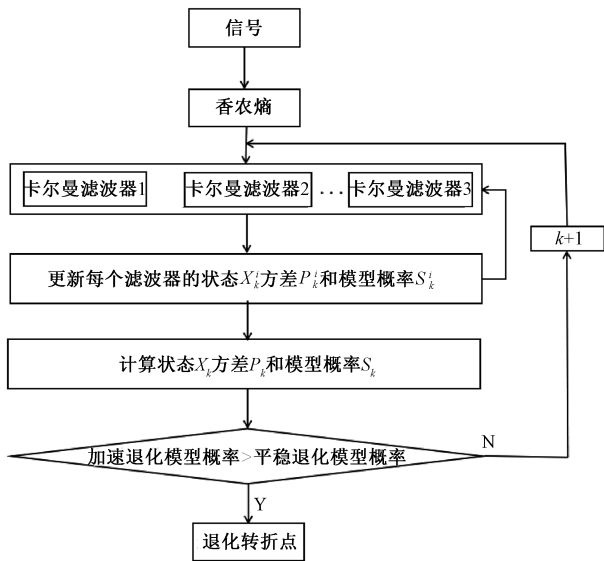


图6 Entropy-SKF 算法流程

Fig. 6 Entropy-SKF algorithm flow chart

3 算法验证

数据为某外场飞机实际飞行数据,对 10 个飞行高度中机载氧气浓缩器的氧分压数据进行分析来验证该算法。

图 7 和 8 所示分别为飞行高度 11 000~12 000 m, 10 000~11 000 m 的数据,通过对图 7 和 8,可以明显地看出该退化阶段分为平稳过程和加速退化过程,对这两组飞行高度数据求取香农熵,结果如图 9 和 11 所示,对求取的香农熵的数据进行阶段识别,识别结果如图 10 和 12 所示。




图7 11 000~12 000 m 氧分压值变化折线图

Fig. 7 Line chart of oxygen partial pressure change in 11 000~12 000 meters




图8 10 000~11 000 m 氧分压值变化折线图

Fig. 8 Line chart of oxygen partial pressure change in 10 000~11 000 meters




图9 11 000~12 000 m 氧分压香农熵变化值

Fig. 9 Shannon entropy change of oxygen partial pressure in 11 000~12 000 meters




图10 11 000~12 000 m 氧分压值退化转折点

Fig. 10 The turning point of oxygen partial pressure degradation in 11 000~12 000 meters

对图 10 进行分析,曲线 1 代表平稳阶段的发生概

率,曲线 2 代表加速退化阶段的发生概率,两个发生概率之和为 1,在点 17 530 之前,曲线 1 位置明显高于曲线 2,




图 11 10 000~11 000 m 氧分压香农熵变化值

Fig. 11 Shannon entropy change of oxygen partial pressure in 10 000-11 000 meters




图 12 10 000~11 000 m 氧分压值退化转折点

Fig. 12 The turning point of oxygen partial pressure degradation in 10 000-11 000 meters

因此判定在点 17 530 之前处在平稳阶段,点 17 530 之后处在加速退化阶段,点 17 530 处两条曲线相交,两条曲线的交点即为退化过程转折点。从分析结果可以看出,飞行架次 1 记录的数据在点 17 530 处两条曲线相见,即在点 17 530 处退化阶段改变,点 17 530 在整个过程中位于位置 59.30%处,符合图 7 和 8 的预期情况。

对图 12 进行分析,可以得出,在点 14 090 之前为平稳退化阶段,点 14 090 之后为加速退化阶段。两条曲线在点 14 090 处相交,为退化阶段转折点,退化转折点位于整个过程的 57.87%处,同样符合图 7 和 8 的预期。

对 10 个不同飞行高度的氧分压数据采用同样的方法进行处理。由于文章篇幅限制,10 个不同飞行架高度的数据不在本文中一一列举,表 1 是对 10 个不同飞行高度的氧分压数据的处理结果。

由表 1 可以看出,机载氧气浓缩器的平稳阶段到加速退化阶段的转折点在全寿命周期的 56%~63%,由于产品批次、飞机飞行高度以及飞行时空气的温湿度等都

会对机载氧气浓缩器的退化造成影响,因此符合实际情况。

表 1 10 个飞行高度数据退化转折点

Table 1 Ten turning points of flight altitude data degradation

序号	高度/m	退化转折点所在位置/%
1	11 000~12 000	59.30
2	10 000~11 000	57.87
3	9 000~10 000	57.43
4	8 000~9 000	60.18
5	7 000~8 000	58.36
6	6 000~7 000	56.98
7	5 000~6 000	62.85
8	4 000~5 000	57.18
9	3 000~4 000	55.32
10	2 000~3 000	59.65

4 算法对比

为了验证该算法的有效性,本文将该算法与常用的小波分解及模式识别 K-means 进行对比,对比如图 13~16 所示。




图 13 11 000~12 000 m 氧分压值一级小波分解

Fig. 13 First-order wavelet decomposition of oxygen partial pressure at 11 000-12 000 meters

对 3 种算法识别结果进行量化分析,如表 2 所示。小波分解^[18]的方法虽然能够体现出机载氧气浓缩器的两个退化阶段,但是不能直观的说明退化阶段转折点所在的位置,同时小波分解的方法在受到噪声等误差干扰的情况下容易造成误判,如果把高频信号维持在较高水平持续一段时间作为退化转折的判据,会造成判断上的滞后性。




图 14 11 000~12 000 m 氧分压值三级小波分解

Fig. 14 Three-level wavelet decomposition of oxygen partial pressure in 11 000~12 000 meters




图 15 10 000~11 000 m 氧分压值一级小波分解

Fig. 15 First-order wavelet decomposition of oxygen partial pressure at 10 000~11 000 meters

表 2 识别结果对比分析

Table 2 Comparative analysis of recognition results

飞行高度/m	算法	识别转折点所在位置
11 000~12 000	Entropy-SKF 算法	59.30%
	小波分解	—
10 000~11 000	K-means	88.24%
	Entropy-SKF 算法	57.87%
10 000~11 000	小波分解	—
	K-means	74.44%

对同飞行架次的退化数据用聚类方法进行分析如图 17、18 所示,聚类是一种无监督的机器学习技术^[19],K-means 算法是一种常用的聚类算法,是通过多次重复迭代把多个对象分成 k 个不同的类簇,使之具有较高的簇内相似度,较低的簇间相似度^[20]。从图 17、18 和表 2 可




图 16 10 000~11 000 m 氧分压值三级小波分解

Fig. 16 Three-level wavelet decomposition of oxygen partial pressure in 10 000~11 000 meters

以看出,通过 K-means 方法进行的退化模式识别,识别结果与实际退化转折点存在较大差距,效果不如本文所提出的 Entropy-SKF 方法。

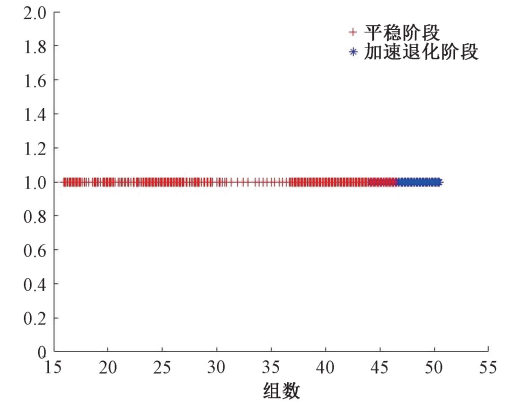


图 17 11 000~12 000 m 氧分压值 K-means 聚类分析

Fig. 17 K-means cluster analysis of oxygen partial pressure in 11 000~12 000 meters




图 18 10 000~11 000 m 氧分压值 k-means 聚类分析

Fig. 18 K-means cluster analysis of oxygen partial pressure in 10 000~11 000 meters

3 种算法对比如表 3 所示,可以得出 Entropy-SKF 和小波分解都可以用于退化阶段点的识别,但是 Entropy-SKF 明显优于小波分解,K-means 算法虽然广泛用于模式识别,但是在识别退化阶段点上效果不理想。

表 3 三种算法比较

Table 3 Comparison of three algorithms

算法	优点	缺点
Entropy-SKF 算法	具有实时性、精确性, 响应速度快	—
小波分解	准确度高, 响应速度快	有一定的滞后性, 容易受噪声等影响
K-means	在聚类分析上存在优势	响应速度慢、阶段识别不够准确

5 结 论

本文提出的 Entropy-SKF 算法把香农熵、卡尔曼滤波器相结合,具有思路清晰、可靠性高、鲁棒性强、实时性好等特点。经过对比,证明了 Entropy-SKF 算法的有效性。针对机载氧气浓缩器退化过程的多阶段,非线性特点,利用该算法可以实时有效的实现退化转折点的寻找。

Entropy-SKF 算法可以应用在机载氧气浓缩器等机械设备多阶段退化的模型中,能对退化阶段进行有效的识别。该算法同样适用于小样本的检验,可以实时跟踪退化模式的变化,准确地获取退化模式的变化点,这在设备健康管理中具有重要意义。

参考文献

- [1] 杨立乾,赵金楼,李根. 基于性能退化的船舶关键部件视情维修策略[J]. 哈尔滨工程大学学报, 2020, 41(4): 613-618.
YANG L Q, ZHAO J L, LI G. Condition-based maintenance strategy for critical components of ships based on performance degradation[J]. Journal of Harbin Engineering University, 2020, 41(4): 613-618.
- [2] 景博,徐光跃,黄以锋,等. 军用飞机 PHM 技术进展分析及问题研究[J]. 电子测量与仪器学报, 2017, 31(2): 161-169.
JING B, XU G Y, HUANG Y F, et al. Recent advances analysis and new problems research on PHM technology of military aircraft [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31 (2): 161-169.
- [3] JAVED K, GOURIVEAU R, ZERHOUNI N. A new multivariate approach for prognostics based on extreme learning machine and fuzzy clustering [J]. IEEE Transactions on Cybernetics, 2015, 45 (12): 2626-2639.
- [4] LI Z, WU D, HU C, et al. An ensemble learning-based prognostic approach with degradation-dependent weights for remaining useful life prediction [J]. Reliability Engineering & System Safety, 2019, doi: 10.1016/j.res. 2017. 12. 016.
- [5] XIAO Y H, HUA Z. Misalignment fault prediction of wind turbines based on combined forecasting model[J]. Algorithms, 2020, 13(3):56.
- [6] RAI A, UPADHYAY S H. Bearing performance degradation assessment based on a combination of empirical mode decomposition and k-medoids clustering [J]. Mechanical Systems and Signal Processing, 2017, 93: 16-29.
- [7] SINGH J, DARPE A K, SINGH S P. Bearing damage assessment using Jensen-Rényi divergence based on EEMD [J]. Mechanical Systems and Signal Processing, 2017, 87:307-339.
- [8] TOMOAKI N, TAKAYUKI N, DAICHIM, et al. Segmenting continuous motions with hidden semi-markov models and gaussian processes [J]. Frontiers in Neurorobotics, 2017, 11(4): 67-75.
- [9] 王慧丹,林贵平,王亮,等. 三床机载制氧系统性能仿真及影响因素分析[J]. 北京航空航天大学学报, 2011, 37(6): 717-722.
WANG H D, LIN G P, WANG L, et al. Performance simulation and influencing factors analysis of three-bed airborne oxygen generation system[J]. Journal of Beijing University of Aeronautics and Astronautics, 2011, 37(6): 717-722.
- [10] 徐正红,杜珍. 机载氧气浓缩器性能测试系统设计及校准技术研究[J]. 合肥工业大学学报, 2012, 35(8): 1068-1070.
XU ZH H, DU ZH. Research on Performance Test System Design and Calibration Technology of Airborne Oxygen Concentrator [J]. Journal of Hefei University of Technology, 2012, 35(8): 1068-1070.
- [11] 王世和,卢灿,许育林,等. 分子筛氧气浓缩监控器可靠性技术及管理研究 [J]. 兵器装备工程学报, 2017(4): 105-108.
WANG SH H, LU C, XU Y L, et al. Research on reliability technology and management of molecular sieve oxygen concentration monitor [J]. Journal of Weapon Equipment Engineering, 2017(4): 105-108.
- [12] 郑龙,杜永浩,邢立宁,等. 基于退化数据与 marker 数据综合的产品可靠性建模分析 [J]. 控制与决策, 2020, 35(2): 461-468.
ZHENG L, DU Y H, XING L N, et al. Product reliability modeling analysis based on degradation data and marker data synthesis [J]. Control and Decision, 2020, 35(2): 461-468.

- [13] 王冰,王蔚,胡雄,等. 基于 CG 模糊聚类的退化状态识别方法[J]. 仪器仪表学报,2018, 39(3): 21-28.
WANG B, WANG W, HU X, et al. Degenerate state recognition method based on CG fuzzy clustering [J]. Chinese Journal of Scientific Instrument, 2018, 39(3): 21-28.
- [14] 曾金芳,滕召胜. 信息熵在曲线拟合辨识中的应用[J]. 电子测量与仪器学报,2012, 26(2): 171-176.
ZENG J F, TENG ZH SH. Application of information entropy in curve fitting identification [J]. Journal of Electronic Measurement and Instrument, 2012, 26(2): 171-176.
- [15] 李奇越,吴忠,黎洁,等. 基于改进卡尔曼滤波的 NLOS 误差消除算法[J]. 电子测量与仪器学报,2015, 29(10): 1513-1519.
LI Q Y, WU ZH, LI J, et al. NLOS error elimination algorithm based on improved Kalman filter[J]. Journal of Electronic Measurement and Instrument, 2015, 29(10): 1513-1519.
- [16] 方安然,李旦,张建秋. 异常值和未知观测噪声鲁棒性的卡尔曼滤波器[J]. 系统工程与电子技术,2021, 43(3): 593-602.
FANG A R, LI D, ZHANG J Q. Outlier and unknown observation noise robust Kalman filter [J]. Systems Engineering and Electronics, 2021, 43(3): 593-602.
- [17] 梁红,靳成学. 基于混合卡尔曼滤波器组故障传感器定位方法[J]. 航空发动机,2019,45(2): 65-68.
LIANG H, JIN CH X. Sensor fault location based on bank of hybrid Kalman filters [J]. Aeroengine, 2019, 45(2): 65-68.
- [18] 孔令刚,焦相萌,陈光武,等. 基于 Mallat 小波分解与改进 GWO-SVM 的道岔故障诊断[J]. 铁道科学与工程学报,2020, 17(5): 1070-1079.
KONG L G, JIAO X M, CHEN G W, et al. Switch fault diagnosis based on Mallat wavelet decomposition and improved GWO-SVM[J]. Journal of Railway Science and Engineering, 2020, 17(5): 1070-1079.
- [19] 邵长龙,孙统风,丁世飞. 基于信息熵加权的聚类集成算法[J]. 南京大学学报,2021,57(2): 189-196.
SHAO CH L, SUN T F, DING SH F. Clustering ensemble algorithm based on information entropy weighting [J]. Journal of Nanjing University, 2021, 57(2): 189-196.
- [20] 佐磊,胡小敏,何怡刚,等. 小样本数据处理的加速寿命预测算法[J]. 电子测量与仪器学报,2020, 34(11): 26-32.
ZUO L, HU X M, HE Y G, et al. Accelerated life prediction algorithm for small sample data processing[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(11): 26-32.

作者简介



张庆一,2020 年于南昌大学获得学士学位,现为空军工程大学研究生,主要研究方向为故障预测与健康管理的。

E-mail:1428543902@qq.com

Zhang Qingyi received his B. Sc. degree from Nanchang University in 2020. He is currently a M. Sc. candidate at Air Force Engineering University. His main research interests include fault prediction and health management.