

DOI: 10.19650/j.cnki.cjsi.J2412464

基于模糊残差收缩网络与人机协同的 机械装备健康评估方法*

江伟雄¹, 王吉², 吴军^{1,4}, 朱海平^{3,4}, 李新宇^{3,4}

(1. 华中科技大学船舶与海洋工程学院 武汉 430074; 2. 工业和信息化部电子第五研究所 广州 511370;
3. 华中科技大学机械科学与工程学院 武汉 430074; 4. 国家智能设计与数控技术创新中心 武汉 430074)

摘要:为全面评估机械装备健康状态并制定分级运维决策策略,提出了一种机械装备人机协同健康评估方法。首先,从振动、压力、扭矩等监测数据中分别提取机械装备症状参数;接着,设计一种新的模糊残差收缩网络,确定机械装备状态隶属度函数,建立基于症状参数的单一评估模型。然后,将各单一评估模型输出的状态隶属度转化为集体犹豫模糊健康评估矩阵;采用 best worst method 计算各模型的评估优先级,利用语义 Z 数环境下的 TOPSIS 方法,发现不同运行状态对装备行为的影响差异。最后,通过犹豫模糊加权平均算子,定义机械装备健康指标,并引入多功能 k-means 聚类算法判定装备健康等级,以指导装备分级运维决策。验证结果表明:所提出的方法在场景适用性和性能稳定性方面有着尚佳的表现。

关键词: 机械装备; 人机协同健康评估; 模糊残差收缩网络; 多功能 k-means 聚类

中图分类号: TH17 TN911 文献标识码: A 国家标准学科分类代码: 460.40

Health assessment of mechanical equipment based on fuzzy residual shrinkage network and human-machine collaboration

Jiang Weixiong¹, Wang Ji², Wu Jun^{1,4}, Zhu Haiping^{3,4}, Li Xinyu^{3,4}

(1. School of Naval Architecture and Ocean Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;
2. China Electronic Product Reliability and Environmental Testing Research Institute, Guangzhou 511370, China;
3. School of Mechanical Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;
4. National Center of Technology Innovation for Intelligent Design and Numerical Control, Wuhan 430074, China)

Abstract: A human-machine cooperative health assessment method is proposed for mechanical equipment to evaluate its health condition and support hierarchical maintenance decisions. First, symptom parameters are extracted from collected vibration, pressure, and torque signals. A novel fuzzy residual shrinkage network is then developed to establish the status membership function of the mechanical equipment, forming the individual assessment model based on the extracted parameters. Next, the status memberships from each model are integrated into a collective hesitation fuzzy health assessment matrix. The Best-Worst Method is applied to calculate the priority of each assessment model, while TOPSIS with linguistic Z-numbers is employed to analyse the impact of different operational states on the equipment's behaviour. Finally, a hesitation fuzzy weighted average operator is used to define the health index of the mechanical equipment, and health levels are identified using the versatile k-means clustering method to support hierarchical maintenance decisions. Validation results demonstrate that the proposed method excels in adaptability to different conditions and stability in performance.

Keywords: mechanical equipment; human-machine cooperative health assessment; fuzzy residual shrinkage network; versatile k-means cluster

0 引 言

目前,风力发电装备、工业机器人、航空发动机、船舶推进轴系等机械装备正向着高精高效高可靠的方向不断发展。不过,一旦机械装备发生故障,可能会导致其运行效率降低,出现计划外停机、甚至引发安全事故^[1]。因此,科学的健康评估方法对提升装备服役可靠性,改善其运行效率、降低其维护成本等具有至关重要的意义。

机械装备健康评估技术已经被国内外学者广泛关注。Zhang 等^[2]采用模糊回声状态网络和振动信号来有效识别旋转机械的故障类别,并评估装备健康程度。Ribeiro Junior 等^[3]利用人工神经网络与振动信号快速判断三相电机的故障类别,并评估故障严重程度。Ameyaw 等^[4]提出一种基于振动信号特征概率的故障检测与评估方法,用于机械装备的故障诊断与运行可靠性评估。Silva-Romero 等^[5]通过定子电流信号和故障隔离系统,精准评估反激式转换器的电感器铁芯饱和健康状态。Rey 等^[6]提出了红外温度测量数据和温度补偿方法,用于评估电气设备的健康状态。Zhou 等^[7]设计了实际电机扭矩和无迹卡尔曼滤波器,通过观察实际扭矩和车辆控制单元输出扭矩间的差异来诊断四轮电机驱动车辆的故障。上述方法分别从振动、温度、扭矩、电流等角度反映了装备健康状况。然而,单一物理量无法同时评估多种故障类别下装备的健康状态。例如,振动与声学信号可有效监测机械类故障,但对电子类或液压类故障往往束手无策。此外,装备运行工况多变、服役环境复杂,严重的信号干扰与有限的评估信息,导致仅仅通过单一物理量难以准确评估装备健康状况。

针对变工况复杂环境下的机械装备,目前多种联合方法被用于评估装备的健康状况。Oh 等^[8]将多个观测信号输入由卷积神经网络和经验模式分解组成的集成评估系统中,评价航空柱塞泵在不同外界环境与运行工况下的性能表现。Kang 等^[9]提出了一种基于 k -means 聚类和混合博弈论的工业机器人闭环健康评估方法,试图提取包括机械臂中电机扭矩和温度信号在内的监测数据,从而评估机器人电机性能表现。Ali 等^[10]提出了一种短时傅里叶变换与机器学习联合的方法,通过测量定子电流信号与振动信号,评估复合故障情况下驱动电机的健康状况。Mao 等^[11]设计了一种自适应卡尔曼滤波器,基于谐波电流信号和纵向振动信号计算转子定位误差,从而评估电机健康状态。相比于基于单一物理量进行装备健康评估,上述方法可同时适用于机械、电子与液压类故障下装备的健康评估,但是由于精度不高,往往难以满足工业应用的需求。其主要是由于多种原始评估信息被直接融合,深层次状态表征尚未被有效地挖掘与利用。此

外,大多数健康评估方法输出的是故障类别或故障严重程度等定性度量结果^[8]。然而,在高层次健康管理框架中,判断发生的故障是否会影响装备关键性能,量化评估装备当前健康状况,制定最优运维方案是另一个亟待解决的问题^[12-15]。

经调研发现,研究者通常将装备的健康评估与运行维护视为多属性决策制定(multiple criteria decision making, MCDM)问题。专家根据自身经验与知识确定影响装备健康状态的主要因素,评估其对装备行为的危害程度,掌握装备整体健康状态,从而制定运维方案。Hafezalkotob 等^[16]组建了汽车发动机损伤评估专家组,确定汽车发动机损坏的主要因素并量化其危害程度,最后通过层次分析法推导汽车发动机损坏属性权重,并以此为依据给出维修顺序与维修手段方面的建议。Khan 等^[17]利用三角模糊数环境下的 VIKOR(vise kriterijumska optimizacija kompromisno resenje)方法确定影响数控机床刀具健康的主要因素,按照风险等级制定运维方案,逐一排查危害刀具正常工作的风险因素。马英海等^[18]提出了基于退化程度的可变权重模糊模型来评估空对空导弹设备的健康状态,并通过多种 MCDM 方法实现健康等级评定,从而确定维修时机与维修级别。俞翔等^[19]针对武器装备完好性评价问题,提出了基于设备技术状态的装备完好性评价方法,通过对某型驱逐舰的完好性模拟评价验证了该方法的可行性,并根据完好性评估结果给出装备修复意见。然而,机械装备终端往往计算资源有限,通常无法实时处理大量监测数据与专家评估意见,确定完整的健康状态排序^[20],甚至在紧急情况下无法等待完整的状态排序结果,即要根据当前健康状态,快速制定装备运维方案。

为解决上述问题,提出一种基于模糊残差收缩网络的机械装备人机协同健康评估方法。该方法利用提出的模糊残差收缩网络(fuzzy residual shrinkage network, FRSN)和多准则决策制定方法,构建全面反映机械装备运行状态的集体犹豫模糊评估矩阵,进而引入犹豫模糊加权平均(hesitation fuzzy weighted average, HFWA)算子与多功能 k -means 聚类方法定义装备健康指标,评定机械装备健康等级。本文的贡献主要有 3 个方面:1)提出了一种融合监测数据和专家知识的人机协同健康评估方法,全面地反映了机械装备健康状况;2)设计了一种新的模糊残差收缩网络,精准构建了机械装备状态隶属度函数;3)引入多功能 k -means 聚类方法,客观地判定了机械装备健康等级,并给出层次化的运维建议。

1 模糊残差收缩网络

He 等^[21]于 2016 年首次提出深度残差网络用于图像

识别。Ma 等^[22]结合深度残差网络与解调后的时频域特征,对非稳定运行状态下的行星齿轮箱进行故障诊断。Zhao 等^[23]提出了深度残差收缩网络,引入软阈值模块解决了传统深度残差网络抗噪能力不足的问题,并用于旋转机械的故障诊断任务。然而,上述网络仅能定性判断装备故障类别,无法有效量化故障状态,因此本文提出一种新的模糊残差收缩网络(fuzzy residual shrinkage network, FRSN),用于构建状态隶属度函数,精准评估机械装备运行状况。FRSN 网络结构如图 1 所示,主要由残差收缩模块与模糊规则模块构成。

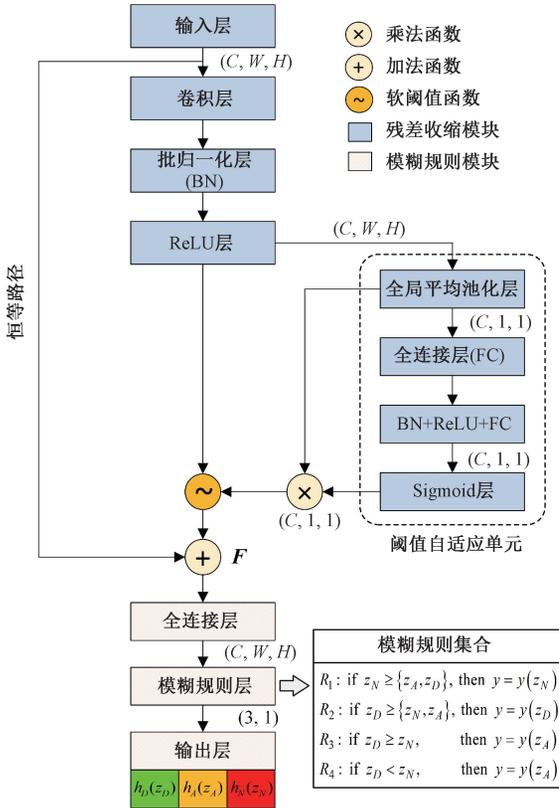


Fig. 1 The structure of fuzzy residual shrinkage network

1.1 残差收缩模块

残差收缩模块(residual shrinkage model, RSM)是由残差网络(residual network, ResNet)演化而来,通过在 ResNet 中引入软阈值函数,自适应地消除噪声相关的特征,从而提高模型分类性能^[23]。软阈值函数将绝对值低于软阈值的原始特征值转化为零,将绝对值高于软阈值的原始特征值向零值靠近,即:

$$f(x) = \begin{cases} x - \tau, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ x + \tau, & x < -\tau \end{cases} \quad (1)$$

其中, x 为输入特征, $f(x)$ 为输出特征, τ 为阈值。软

阈值由残差收缩模块中的阈值自适应单元自动确定,可以使有用特征保持稳定,将无用特征从 $[-\tau, \tau]$ 转化为零。

阈值自适应单元由全局平均池化层、全连接层、批量归一化、ReLU 激活函数层和 Sigmoid 函数组成。全局平均池化层用于将特征图 x 转换为二维向量。在 2 个全连接层的末端,使用 Sigmoid 函数将全连接层的输出转换为 $[0, 1]$ 范围,即:

$$\alpha_c = \frac{1}{1 + e^{-z_c}} \quad (2)$$

其中, z_c 表示 2 个全连接层的输出, α_c 是不同通道的缩放值。每个通道的软阈值描述如下:

$$\tau_c = \alpha_c \times \text{average}_{w,h} |x_{w,h,c}| \quad (3)$$

其中, W, H 和 C 分别表示特征图 x 的宽度、高度和通道数。经过上述操作,原始输入中的高维特征 F 被提取。

1.2 模糊规则模块

模糊规则模块中,由残差收缩模块提取出的高维特征 F 和样本标签被输入至全连接层用于模型训练。为了建立统一的健康评估矩阵,将评估模型推导得出的运行状态设定为正常、注意和危险 3 种状态。全连接层中的前向传播过程如下:

$$z_N = \sum_{p=1}^P W_{pq,N}^l F^{l(p)} + b_{q,N}^l \quad (4)$$

$$z_A = \sum_{p=1}^P W_{pq,A}^l F^{l(p)} + b_{q,A}^l \quad (5)$$

$$z_D = \sum_{p=1}^P W_{pq,D}^l F^{l(p)} + b_{q,D}^l \quad (6)$$

其中, N, A 和 D 表示正常、注意和危险状态, $W_{pq,N}^l$ 、 $W_{pq,A}^l$ 和 $W_{pq,D}^l$ 分别是 3 种状态下第 l 层第 p 个神经元与第 $(l+1)$ 层第 q 个神经元之间的权重向量, $b_{q,N}^l$ 、 $b_{q,A}^l$ 和 $b_{q,D}^l$ 分别是 3 种运行状态下第 $(l+1)$ 层第 q 个神经元的偏置, z_N, z_A 和 z_D 分别是 3 种运行状态下第 q 个神经元输出的对数值, $F^{l(p)}$ 表示高维特征。

高斯激活函数(适用于注意状态)和 2 个指数激活函数(适用于正常和危险状态)被用作状态隶属度函数。FRSN 输出层结构可表示为一系列“if-then”模糊规则的集合,即:

$$y = \begin{cases} y(z_N) = a_1 - \frac{1}{b_1} \ln\left(\frac{1 - z_N}{z_N}\right), & \text{if } z_N \geq \{z_A, z_D\} \\ y(z_D) = a_3 - \frac{1}{b_3} \ln\left(\frac{1 - z_D}{z_D}\right), & \text{if } z_D \geq \{z_N, z_A\} \\ y(z_A) = a_2 + \sqrt{2b_2^2 \ln(z_A)}, & \text{if } z_D \geq z_N \\ y(z_A) = a_2 - \sqrt{2b_2^2 \ln(z_A)}, & \text{if } z_D < z_N \end{cases} \quad (7)$$

其中, $\{a_1, b_1\}$, $\{a_2, b_2\}$ 和 $\{a_3, b_3\}$ 分别代表正常、

注意和危险状态下状态隶属度函数的参数。logits 值分为 3 种状态,如图 2 所示。

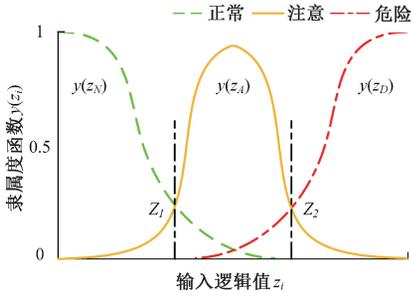


图 2 状态隶属度函数

Fig. 2 The schematic of status membership function

通过隶属度函数,计算出 3 种运行状态的状态隶属度,并将其规整为犹豫模糊数 (hesitation fuzzy number, HFN),如下所示。

$$h = y(z_N) \vee y(z_A) \vee y(z_D) = \langle h_N(z_N), h_A(z_A), h_D(z_D) \rangle \quad (8)$$

其中, h 为反映运行状态的犹豫模糊数, $h_N(z_N)$ 、 $h_A(z_A)$ 和 $h_D(z_D)$ 分别为正常、注意和危险状态的概率。

对于 M 个评估模型,可将 3 种运行状态的评估信息汇总。

$$\mathbf{H} = \{h_{N,i}(z_N), h_{A,i}(z_A), h_{D,i}(z_D) \mid i \in \{1, \dots, M\}\} = \{(h_{N,1}, \dots, h_{N,M}), (h_{A,1}, \dots, h_{A,M}), (h_{D,1}, \dots, h_{D,M})\} \quad (9)$$

其中, \mathbf{H} 为集体犹豫模糊评估矩阵, M 为评估模型的个数, $h_{N,i}(z_N)$ 、 $h_{A,i}(z_A)$ 和 $h_{D,i}(z_D)$ 分别为 3 种评估模型下正常、注意和危险状态的概率。

1.3 网络更新规则

在训练过程中,使用传统的训练方法更新隶属度函数的参数会破坏隶属度函数模糊完整性,从而影响模型诊断和评估性能。这里,采用约束梯度可靠性算法^[24]更新模型参数。对于给定的一个训练样本,它由训练数据集 $x^{(p)}$ 和实际样本标签 $L_d^{(p)}$ 组成, $p = 1, 2, \dots, P$, P 是训练样本的数量。实际样本标签 $L_d^{(p)}$ 如下所示:

$$L_d^{(p)} = \{L_N^{(p)}, L_A^{(p)}, L_D^{(p)}\}^T = \begin{cases} \{1, 0, 0\}^T, & \text{if } y^{(p)} \in N \\ \{0, 1, 0\}^T, & \text{if } y^{(p)} \in A \\ \{0, 0, 1\}^T, & \text{if } y^{(p)} \in D \end{cases} \quad (10)$$

FRSN 的目标函数为:

$$Obj = \frac{1}{3} \sum_{p=1}^P g_p [(L_N^{(p)} - h_N(x^{(p)}))^2 + (L_A^{(p)} - h_A(x^{(p)}))^2 + (L_D^{(p)} - h_D(x^{(p)}))^2] \quad (11)$$

其中, $h_N(x^{(p)})$ 、 $h_A(x^{(p)})$ 和 $h_D(x^{(p)})$ 分别是训练样本对运行状态 N 、 A 和 D 的状态隶属度值。 $A_B = \{A_{B1}, A_{B2}, \dots, A_{Bi}, \dots, A_{BM}\}$ 是增益系数。

2 人机协同健康评估方法

为全面评估机械装备健康状况,本文提出一种基于模糊残差收缩网络的机械装备人机协同健康评估方法。在该方法中,提取多模态监测信号的症状参数 (symptom parameter, SP),利用提出的 FRSN 构建基于各 SP 的评估模型,并依据模型证据权重对各评估模型的评估结果进行融合,同时使用多个评估模型来反映装备的运行状态。此外,在专家评估意见的基础上,通过语义 Z 数环境下的 TOPSIS (technique for order preference by similarity to ideal solution) 方法确定各运行状态对装备行为的影响差异,获得不同状态风险权重下视情而定的健康评估结果。因此,该方法被称为基于模糊残差收缩网络的机械装备人机协同健康评估方法,如图 3 所示。该方法主要包含健康评估矩阵构建、健康评估信息整合和健康等级评定 3 个阶段,具体如下所述。

2.1 健康评估矩阵构建

在机械装备关键部件处安装相应传感器,采集监测信号,并从原始监测信号中提取各种症状参数。随后,将原始信号中提取的症状参数划分为训练集、验证集和测试集。使用训练集训练不同症状参数下的 FRSN 作为单一评估模型,并利用相应的验证集优化模型参数。值得注意的是,当症状参数有 M 种时,评估模型有 M 个。

接着,将测试集输入至训练好的 FRSN 中获取 3 种运行状态的状态隶属度,并将其规整为犹豫模糊数。

对于 M 个评估模型,可将 M 个评估模型输出的 HFN 转化为集体犹豫模糊健康评估矩阵。

2.2 健康评估信息整合

各评估模型输出的评估信息可被视为一条评估依据,它们的置信度是不同的,因此需要根据模型的评估表现调整模型证据权重。此外,还需要考虑不同运行状态对机械装备行为的影响差异。本文根据各评估模型的诊断准确率确定模型证据权重,在专家评估意见的基础上利用语义 Z 数环境下的 TOPSIS 方法确定运行状态权重,并通过犹豫模糊加权平均 (hesitation fuzzy weighted averaging, HFWA) 算子整合集体犹豫模糊评估矩阵,推导出机械装备的健康指标。

1) 模型证据权重确定:邀请 4 位专家组成模型评估小组,根据模型诊断性能挑选出最佳模型和最差模型^[25]。随后,将最佳模型的性能与其他评估模型的性能进行对比,用 1~9 的正整数来衡量性能差异。其中, A_{Bi} 表示最佳评估模型与第 i 个评估模型间的相对性能优势, A_{iW} 表示第 i 个评估模型与最差模型间的相对性能优势。

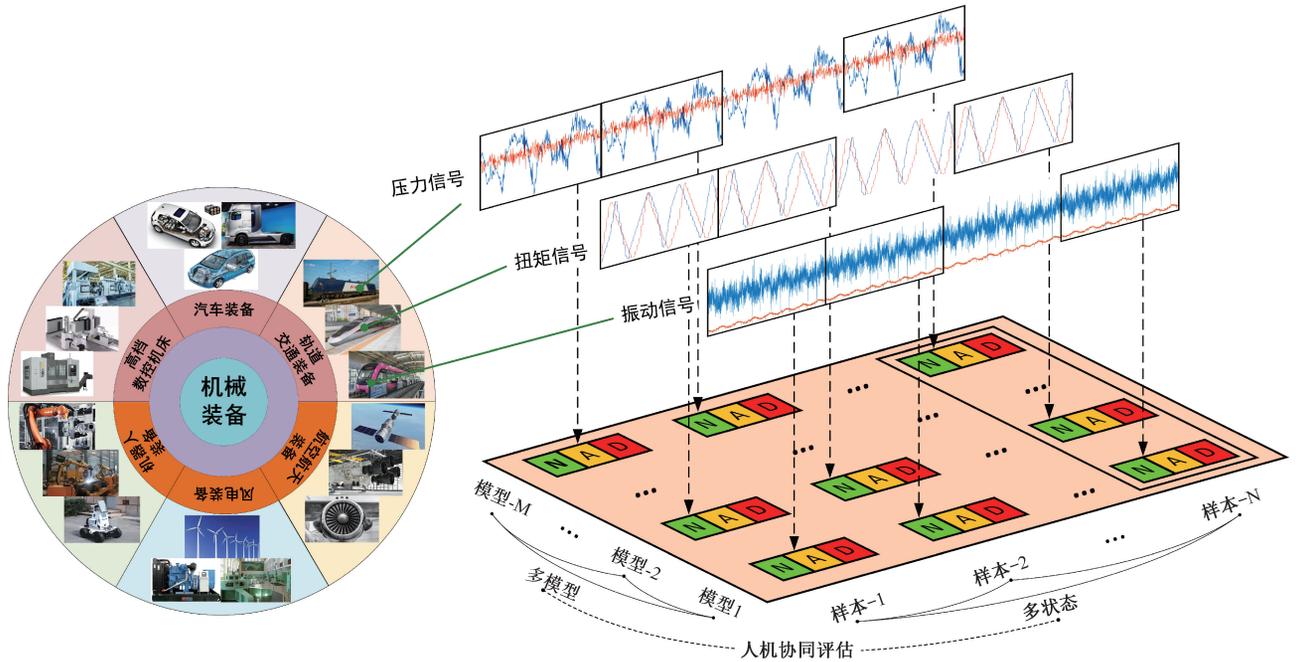


图3 机械装备人机协同健康评估方法

Fig. 3 The schematic of human-machine collaboration health assessment method for machinery and equipment

假设 w_i 为第 i 个评估模型的证据权重, 应满足 $w_B/w_i = A_{Bi}$ 和 $w_i/w_B = A_{iW}$ 。利用最大偏差法构建了基于专家经验的直觉模糊决策问题优化模型, 得出了模型证据权重。具体地, 通过最小化绝对差值 $|w_B/w_i - A_{Bi}|$ 和 $|w_i/w_B - A_{iW}|$, 确定模型证据权重^[16]。

$$\begin{aligned} & \min_{w_i} \max_i \{ |w_B/w_i - A_{Bi}|, |w_i/w_B - A_{iW}| \} \\ & \text{s. t.} \\ & \begin{cases} \sum_i w_i = 1 \\ w_i \geq 0, i = 1, 2, \dots, M \end{cases} \end{aligned} \quad (12)$$

2) 状态风险权重确定: 4位专家采用了2个不同的语义集 $S = \{s_0, s_1, s_2, s_3, s_4\} = \{\text{非常轻微、轻微、中等、严重、非常严重}\}$ 和 $S' = \{s'_0, s'_1, s'_2, s'_3, s'_4\} = \{\text{非常不可靠、不可靠、普通、可靠、非常可靠}\}$, 对3种运行状态的风险给出偏好意见, 并将其整合为语义 Z 数 $Z_{ij} = (\tau_1 Z_{ij}^1) \oplus (\tau_2 Z_{ij}^2) \oplus \dots \oplus (\tau_c Z_{ij}^c)$, 其中 $Z_{ij} = (\tau_1 Z_{ij}^1) \oplus (\tau_2 Z_{ij}^2) \oplus \dots \oplus (\tau_c Z_{ij}^c)$, $Z_{ij} = (\tau_1 Z_{ij}^1) \oplus (\tau_2 Z_{ij}^2) \oplus \dots \oplus (\tau_c Z_{ij}^c)$, $\varphi(i)$ 为语义等级数。本文赋予各位专家相同的意见权重, 并融合各专家给出的评估意见:

$$Z_{ij} = (0.25 \times Z_{ij}^1) \oplus (0.25 \times Z_{ij}^2) \oplus (0.25 \times Z_{ij}^3) \oplus (0.25 \times Z_{ij}^4) \quad (13)$$

然后, 通过 TOPSIS 方法确定状态风险评估距离矩阵, 计算正理想解与 Q 种运行状态间的总加权距离, 建立加权优化模型从而计算得出最优状态风险权重 δ ^[26]。

3) 健康指标推导: 考虑结合模型证据权重后, 各模型

的健康评估信息被汇总如下:

$$\begin{aligned} \mathbf{H} &= \{h_N, h_A, h_D\} = \\ & \left\{ \sum_{j=1}^M w_j \times h_{N,j}, \sum_{j=1}^M w_j \times h_{A,j}, \sum_{j=1}^M w_j \times h_{D,j} \right\} \end{aligned} \quad (14)$$

通过 HFWA 算子对健康评估信息进行汇总, 如下所示:

$$\begin{aligned} \tilde{\mathbf{H}} &= (\delta_N h_N) \oplus (\delta_A h_A) \oplus (\delta_D h_D) = \\ & \cup_{h_N, h_A, h_D} \left\{ 1 - \prod_{i=N}^{N,A,D} (1 - h_i)^{\delta_i} \right\} \end{aligned} \quad (15)$$

机械装备健康指标定义如下:

$$\text{HI} = \tilde{\mathbf{H}} = \cup_{h_N, h_A, h_D} \left\{ 1 - \prod_{i=N}^{N,A,D} (1 - h_i)^{\delta_i} \right\} \quad (16)$$

2.3 装备健康等级评定

Dreher 等^[27] 提出了基于 k -means 聚类的装甲车辆健康评估方法, 用于识别装备故障并优化维护计划, 降低维修成本。Wang 等^[28] 提出了一种基于改进 k -means 的聚类中心选择方法, 实现了不平衡故障样本下的车辆装备高精度故障诊断。 k -means 算法由于其算法复杂性低、场景适用性广等优点在诊断与评估领域被广泛应用。因此, 本文引入 k -means 聚类算法用于机械装备健康等级评定。当预设聚类数 k 等于健康状况等级数 T 时, 该算法用于闭环验证所提出方法的性能, 此时装备的健康状况被聚类至 T 种等级 (如健康、亚健康 and 紧急等级), 将聚类结果与实际健康状况标签对比, 从而闭环验证所提出方法的准确性; 当预设聚类数 k 大于健康状况等级数 T 时 (如健康、亚健康、紧急和危险等级), 该算法用于

客观评定装备健康等级,此时装备的健康状态被更详细地划分,提供层次化的运维建议。因此,该方法称为多功能 k -means 聚类。

多功能 k -means 聚类方法需要预先定义初始聚类中心和距离度量 2 个参数。从健康指标中随机挑选出 k 个初始聚类中心 $HI'_i (i = 1, 2, \dots, k)$ 。利用欧氏距离衡量每个样本与 k 个初始聚类中心间的差距。在多功能 k -means 聚类算法中,相同聚类簇中的样本距离较小,反之亦然^[29]。

$$d(HI'_i, HI) = \sqrt{\sum_{j=1}^P (HI'_{ij} - HI_j)^2}, \quad i = 1, 2, \dots, k \quad (17)$$

其中, P 为样本数。

3 实验验证

3.1 实验描述

本文基于自主搭建的航空柱塞泵实验台,验证所提出健康评估方法的有效性。据调研,航空柱塞泵配油盘作为液压系统关键部件,长期承担油流分配、压力控住、

过载保护等重要工作任务,需重点关注其健康状况。因此,该航空柱塞泵实验台通过更换不同磨损程度的配油盘来模拟不同等级的配油盘健康状况,如图 4 所示。配油盘磨损程度分为健康、轻微磨损和严重磨损。其中,健康情况下的配油盘不采取任何处理,轻微磨损只刮伤配油盘高压侧,严重磨损则在中等磨损基础上刮伤配油盘的高压侧转低压侧区,具体损伤情况如图 5 所示。



图 4 航空柱塞泵实验平台

Fig. 4 The experimental platform of aerospace piston pump

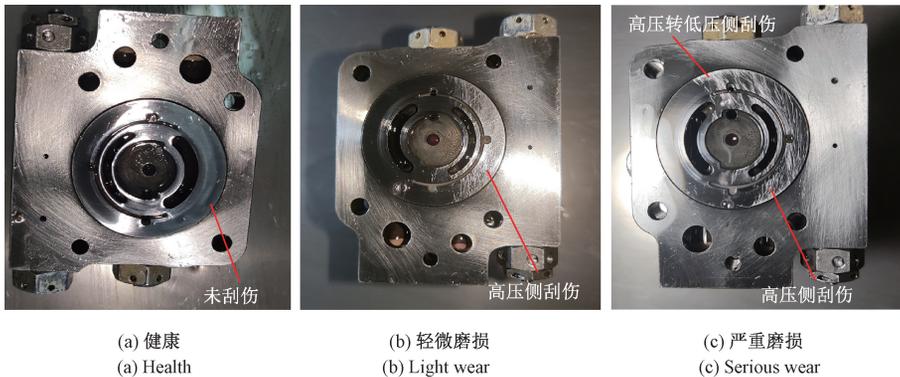


图 5 不同磨损程度的配油盘

Fig. 5 Oil pans with different levels of wear

航空柱塞泵出口管路上安装压力传感器,检测泵出口压力;柱塞泵电机处安装扭矩传感器,测量电机扭矩;泵壳铭牌处安装加速度传感器,测量泵体振动情况。传感器采样频率均为 10 240 Hz。对每种健康状况进行 1 000 次重复采样,每次采样时间为 0.2 s,每个样本包含 2 048 个采样点。需要指出,所有上述提到的算法在 Python v3.8 环境下运行,并在一台配置为 AMD Ryzen 55 600 G (3.9 GHz) CPU,16 GB 内存,Windows 11 的计算机上执行。

3.2 实验结果

1) 单一模型评估结果

目前,基于振动信号的监测方法被广泛使用^[30]。将振动信号转换成如绝对平均值、峰值、均方根、峭度系数和峰

值系数等症状参数;随后,研究症状参数变化与装备健康状况间的关联关系。均方根能有效表征故障扩展现象,可在故障早期阶段保持稳定,并随着故障的演化迅速上升。峰值系数是无量纲症状参数,对振动脉冲较为敏感。振动脉冲越强,峰值系数越大。本文使用振动信号的均方根与峰值系数构建了 2 个评估模型 M_1 和 M_2 ,如下所述:

$$RMS = \sqrt{\left(\sum_{i=1}^{N_v} v_i^2\right)/N_v} \quad (18)$$

$$CF = \sqrt{\left(\sum_{i=1}^{N_{vp}} |v_i|_p / RMS\right)/N_{vp}} \quad (19)$$

其中, RMS 为均方根, CF 为峰值系数, v_i 表示振动信号的采样点, $|v_i|_p$ 表示振动信号的绝对峰值, N_v 为振动

信号采样点的个数, N_{pp} 为区域峰值的个数。

压力信号能够反映机械内部结构密封性, 该信号对外部环境的干扰并不明显, 但在航空柱塞泵腔体密封性发生改变时会显著变化^[31]。因此, 基于压力脉动, 建立第3个评估模型 M_3 。

$$PF = \sqrt{\left(\sum_{i=2}^{N_p} (P_i - P_{i-1})\right) / (N_p - 1)} \quad (20)$$

其中, PF 为压力脉动, P_i 表示压力信号的采样点, N_p 为压力信号采样点的个数。

针对航空柱塞泵伺服电机, 通常会利用扭矩信号进行监测并将其转换为平均值。在正常状态下, 当工作负载和电机转速保持恒定时, 扭矩平均值是稳定的。一旦伺服电机发生故障, 故障扭矩平均值与正常扭矩平均值

间的差别变大^[32]。本文基于扭矩平均值, 构建第4个评估模型 M_4 。

$$TMV = \sqrt{\left(\sum_{i=1}^{N_t} t_i\right) / N_t} \quad (21)$$

其中, TMV 为扭矩平均值, t_i 表示扭矩的采样点, N_t 为扭矩采样点的个数。

航空柱塞泵运行状态分为正常、注意和危险3种。本文利用所提出的FRSN确定各运行状态的状态隶属度函数, 构建基于各症状参数的评估模型。为消除样本选择对模型的影响, 进行了20次重复试验, 基于4种症状参数构建的评估模型如图6所示。其中 $h_N(z_N)$, $h_A(z_A)$ 和 $h_D(z_D)$ 分别是评估模型正常、注意和危险状态下的隶属度函数。

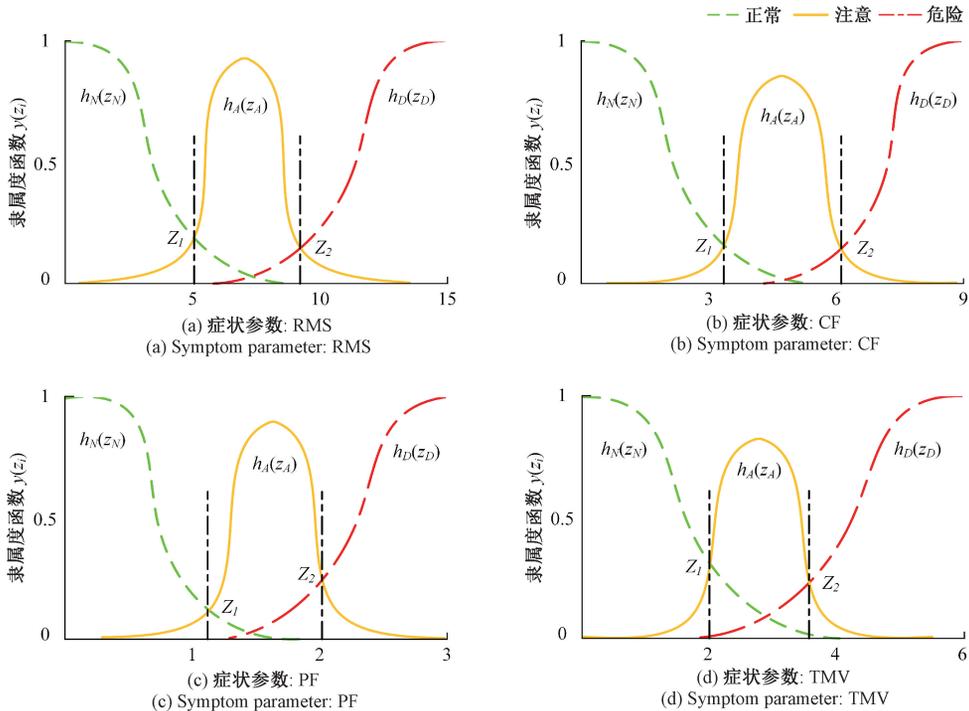


图6 基于4种症状参数构建的评估模型

Fig. 6 The assessment model based on four symptom parameters

2) 健康评估与健康等级评定

根据4种症状参数构建对应的评估模型, 航空柱塞泵当前运行状态(即正常、注意或危险状态)的概率可通过相应的隶属度函数 $y(z_N)$ 、 $y(z_A)$ 和 $y(z_D)$ 来计算。为统一评估结果, 各运行状态的概率被标准化处理。

$$a = \frac{h_N(z_N)}{\sum_i h_i(z_i)}, \quad i = N, A, D \quad (22)$$

$$b = \frac{h_A(z_A)}{\sum_i h_i(z_i)}, \quad i = N, A, D \quad (23)$$

$$c = \frac{h_D(z_D)}{\sum_i h_i(z_i)}, \quad i = N, A, D \quad (24)$$

各样本评估信息被转化为犹豫模糊数 $h = \langle a, b, c \rangle$ 。通过4种评估模型评估航空柱塞泵的运行状态, 评估结果被构建为犹豫模糊评估矩阵, 如表1所示。

根据4种评估模型对航空柱塞泵配油盘磨损故障的诊断准确率, 确定各评估模型的模型证据权重。结果表明, 基于峰值系数的模型 M_2 诊断准确率最高, 基于扭矩平均值的模型 M_4 诊断准确率最低。因此, Best-to-Other 向量 A_B 与 Other-to-Worst 向量 A_W 分别为 $\{3, 1, 7, 9\}$ 和 $\{7, 9, 3, 1\}$ 。因此, 模型证据权重向量 w_i 为

表 1 航空柱塞泵集体犹豫模糊评估矩阵

Table 1 Collective hesitation fuzzy assessment matrix for aerospace piston pumps

运行状态	健康状况		
	配油盘健康	配油盘轻微磨损	配油盘严重磨损
正常	{0.991, 1.000, 0.988, 1.000}	{0.009, 0.018, 0.002, 0.066}	{0.000, 0.000, 0.000, 0.000}
注意	{0.009, 0.000, 0.012, 0.000}	{0.932, 0.974, 0.942, 0.790}	{0.031, 0.033, 0.032, 0.000}
危险	{0.000, 0.000, 0.000, 0.000}	{0.059, 0.008, 0.056, 0.144}	{0.969, 0.967, 0.968, 1.000}

{0.242, 0.600, 0.104, 0.053}。

此外,还采用了 2 个不同的语言术语集 $S = \{s_0, s_1, s_2, s_3, s_4\} = \{\text{非常轻微、轻微、中等、严重、非常严重}\}$ 和

$S' = \{s'_0, s'_1, s'_2, s'_3, s'_4\} = \{\text{非常不可靠、不可靠、普通、可靠、非常可靠}\}$ 用于评估专家描述 3 种运行状态对航空柱塞泵系统行为的影响。4 位专家的语义 Z 数评估结果,如表 2 所示。

表 2 专家提供的各运行状态语义 Z 数风险偏好

Table 2 The semantic Z-number risk preferences provided by experts for each operation state

健康状况	专家 1			专家 2		
	正常	注意	危险	正常	注意	危险
配油盘健康	(A ₁ , B ₄)	(A ₃ , B ₄)	(A ₃ , B ₃)	(A ₀ , B ₄)	(A ₂ , B ₄)	(A ₄ , B ₃)
配油盘轻微磨损	(A ₀ , B ₃)	(A ₂ , B ₃)	(A ₄ , B ₄)	(A ₁ , B ₃)	(A ₃ , B ₄)	(A ₄ , B ₄)
配油盘严重磨损	(A ₁ , B ₄)	(A ₃ , B ₃)	(A ₄ , B ₄)	(A ₀ , B ₄)	(A ₃ , B ₃)	(A ₄ , B ₄)
健康状况	专家 3			专家 4		
	正常	注意	危险	正常	注意	危险
配油盘健康	(A ₀ , B ₄)	(A ₂ , B ₃)	(A ₃ , B ₃)	(A ₀ , B ₄)	(A ₃ , B ₃)	(A ₄ , B ₄)
配油盘轻微磨损	(A ₁ , B ₃)	(A ₂ , B ₃)	(A ₄ , B ₄)	(A ₁ , B ₄)	(A ₂ , B ₄)	(A ₃ , B ₃)
配油盘严重磨损	(A ₁ , B ₄)	(A ₂ , B ₃)	(A ₄ , B ₄)	(A ₀ , B ₃)	(A ₃ , B ₄)	(A ₄ , B ₄)

各评估专家被赋予相同的意见权重,并如式(13)所示对单个语义 Z 数进行融合,如下所示。

$$Z_{ij} = (0.25 \times Z_{ij}^1) \oplus (0.25 \times Z_{ij}^2) \oplus (0.25 \times Z_{ij}^3) \oplus (0.25 \times Z_{ij}^4) \quad (25)$$

集体语义 Z 数评估矩阵被汇总如下。

Z =

	正常	注意	危险
健康	(A ₀ , B _{4.00})	(A _{2.46} , B _{2.98})	(A _{3.43} , B _{3.20})
轻微磨损	(A ₀ , B _{4.00})	(A _{2.22} , B _{3.47})	(A _{3.73} , B _{3.73})
严惩磨损	(A ₀ , B _{4.00})	(A _{2.72} , B _{3.27})	(A _{4.00} , B _{4.00})

然后,正常、注意和危险运行状态的正理想解为 $Z^* = \{(A_1, B_3), (A_3, B_4), (A_4, B_4)\}$, 建立状态风险评估距离矩阵:

$$D = \begin{pmatrix} & \text{正常} & \text{注意} & \text{危险} \\ \text{健康} & 0 & 0.2335 & 0.2713 \\ \text{轻微磨损} & 0 & 0.1561 & 0.0334 \\ \text{严惩磨损} & 0 & 0.1538 & 0 \end{pmatrix}$$

根据状态风险评估距离矩阵推导得出正常、注意和

危险运行状态的状态风险权重为 $\delta = (0.0769, 0.1442, 0.7788)$ 。在工程应用中,高级工程师认为危险状态会降低运行效率,甚至威胁装备的运行安全,所以应赋予较大的状态风险权重,这与所提出方法的分析结果是一致的。

随后,将模型评估信息和模型证据权重结合,利用 HFWA 算子整合集体犹豫模糊评估矩阵,计算出不同健康状况下的健康指标,如表 3 所示。

表 3 各失效模式下犹豫模糊评估向量与健康指标

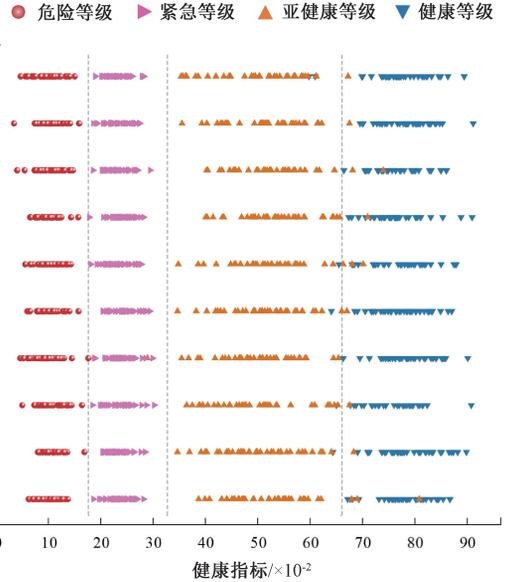
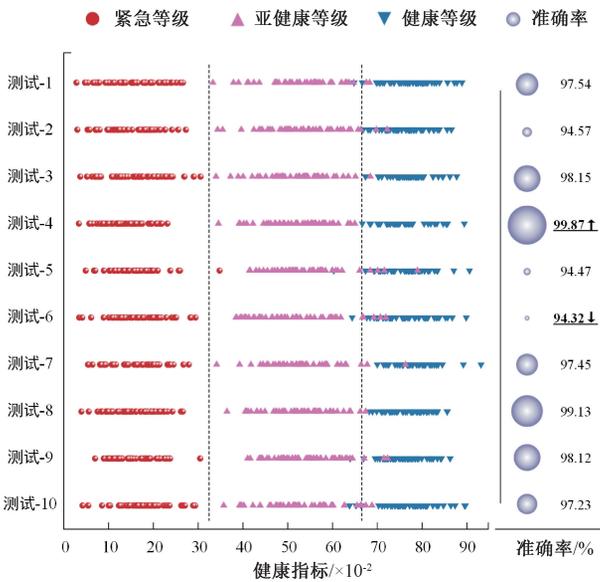
Table 3 Hesitant fuzzy assessment vector and health indicators for each fault pattern

失效模式	评估向量	健康指标
配油盘健康	(0.996, 0.034, 0)	0.7124
配油盘轻微磨损	(0.017, 0.950, 0.033)	0.6316
配油盘严重磨损	(0, 0.031, 0.968)	0.0682

通过多功能 k-means 聚类评定航空柱塞泵健康

等级并在此基础上展开运维决策,如图7所示,图中虚线表示聚类决策边界。当聚类簇数 k 设为3时,航空柱塞泵的健康指标被划分为健康、亚健康 and 紧急3个等级,并将聚类结果与实际健康状态等级标签

(即健康、轻微磨损和严重磨损)进行对比,验证所提方法的准确性。每种健康状况下有50个样本,并进行10次重复试验以消除样本选择对健康评估结果的影响。



(a) 聚类簇数 k 设为3时的聚类结果
(a) Clustering results when the number of clusters k is 3

(b) 聚类簇数 k 设为4时的聚类结果
(b) Clustering results when the number of clusters k is 4

图7 健康等级评定结果

Fig. 7 The identification results of health degree

如图7(a)所示,平均聚类精度为97.09%,最高精度可达99.87%。因此,可看出当聚类簇数 k 设置与健康状态等级数相等时,样本的聚类结果与实际失效标签基本一致,只有少数样本在健康等级和亚健康等级之间被错误地划分。

当聚类簇数 k 值大于3时(本文设置为4),航空柱塞泵的健康指标被分至4个等级。每个健康状况有38个样本,进行了10次重复试验,聚类结果如图7(b)所示。

根据上述健康等级评定结果,从维护级别和维护手段2个方面给出运行维护建议^[33]:

- 1) 健康等级:采用基层级运维方案,持续监测装备运行状态,暂不采取维护行动;
- 2) 亚健康等级:采用基层级维修方案,根据健康评估结果在较短时间完成简单的维修工作。例如,在配油盘轻微磨损时添加润滑油;
- 3) 紧急等级:采用中继级维修方案,相比基层级维修拥有更熟练的维护工程师和更丰富的保障设备与备件,以承担基层级所不能完成的维修工作。例如,航空柱塞泵停机,维修车间更换故障配油盘;
- 4) 危险等级:采用基地级维修方案,可承担装备备件

制造、整体检修等任务。例如,将航空柱塞泵送回维修基地检查,评估装备需要维修或是整体报废,若采取维修方案,制备并更换备件,并对维修后的装备进行全面保养。

3.3 结果讨论

1) 敏感性分析

为了研究模型证据权重和状态风险权重对健康评估结果的影响,本节将进行权重敏感性分析。当聚类簇数 k 设为3时,提出的评估方法输出15个样本(S.1~S.15)在不同权重组合下的聚类结果。权重组合1(G.1)代表原始模型证据权重和状态风险权重的组合,其他权重组合(G.2~G.4)代表在可能取值范围内的不同模型证据权重与状态风险权重的组合,具体如下。

- G. 1: $w_{RMS} = 0.242, w_{CF} = 0.6, w_{TR} = 0.104, w_{TMV} = 0.053$
 $\delta_N = 0.07, \delta_A = 0.14, \delta_D = 0.78$
- G. 2: $w_{RMS} = 0.40, w_{CF} = 0.20, w_{TR} = 0.20, w_{TMV} = 0.20$
 $\delta_N = 0.50, \delta_A = 0.25, \delta_D = 0.25$
- G. 3: $w_{RMS} = 0.20, w_{CF} = 0.40, w_{TR} = 0.20, w_{TMV} = 0.20$
 $\delta_N = 0.25, \delta_A = 0.50, \delta_D = 0.25$

G. 4: $w_{RMS} = 0.20$, $w_{CF} = 0.20$, $w_{TR} = 0.20$, $w_{TMV} = 0.40$

$\delta_N = 0.25$, $\delta_A = 0.25$, $\delta_D = 0.50$

在图 8 中,15 个样本的聚类结果随着模型证据权重和状态风险权重的变化而波动。在 G3 中,当注意状

态的状态风险权重较高时,S. 4 被判定为亚健康等级。相反,其他 3 种组合中它被划分至健的健康等级容易被误判,其聚类结果对模型证据权重和状态风险权重的变化很敏感。4 种权重组合下的聚类精度也有很大的差异。

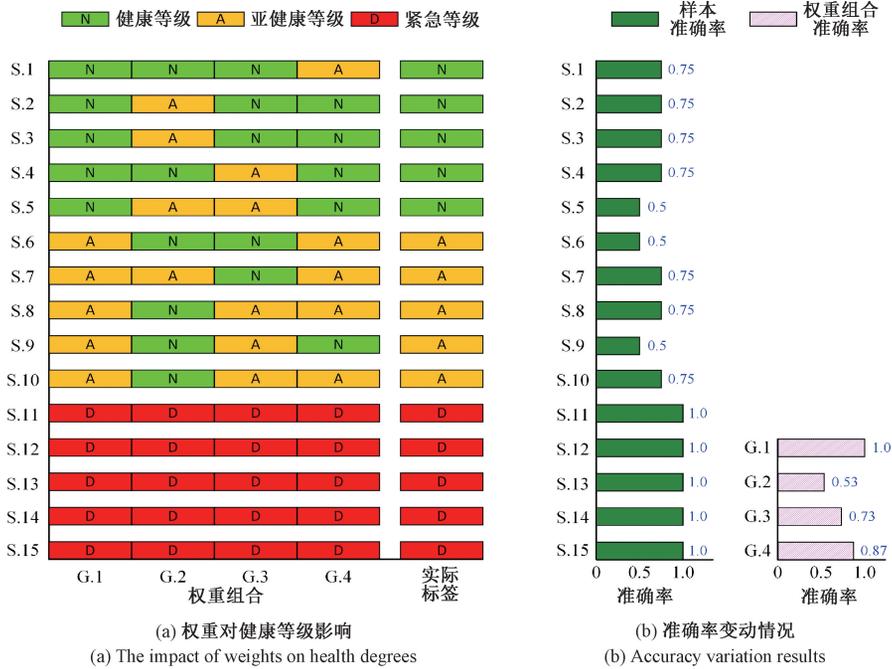


图 8 各权重组合下的敏感性分析结果

Fig. 8 Sensitivity analysis results under different weight combinations

因此,敏感性分析表明,模型证据权重和状态风险权重对样本的健康评估结果有着显著影响。因此,视情而定地给出模型证据权重和状态风险权重十分重要,可在不同应用场景中准确地反映装备的健康状况。

2) 对比分析

引入多种对比方法,验证所提出健康评估方法的优越性。这些对比方法可被分为两类:一类是基于单一症状参数的评估方法,包括基于均方根的评估方法、基于峰值系数的评估方法、基于压力脉动的评估方法和基于扭矩均值的评估方法。另一种是替换决策模型方法,如把 BWM(best worst method) 和 TOPSIS 决策模型替换成 DEMATEL (decision making trial and evaluation laboratory)^[16]、SWARA^[34](stepwise weight assessment ratio analysis) 和 Entropy^[35],用于确定模型证据权重与状态风险权重。

3 种健康状况下的航空柱塞泵实验数据被用于对比分析,每种健康状况随机抽取 50 个样本,并进行两次重复试验以避免结果的偶然性。每种健康状况下样本的平均健康指标,如表 4 所示。聚类簇数 k 设置为 3,健康指

标被划分至健康、亚健康和紧急 3 种等级。将聚类结果与实际健康状态等级标签对比计算聚类准确率。由 $k=3$ 时的聚类模型决策边界可知,当健康状态为健康时,健康指标大于 0.67 即被判定正确,识别结果标记为“○”;反之,则标记为“×”。同样,健康指标为 0.32~0.67 和 0~0.32 的配油盘轻微磨损和严重磨损分别标记为“○”,详细的评估结果如表 4 所示。

基于均方根和峰值系数的评估方法可以准确判定大多数样本的健康等级,但其聚类准确率仍然低于所提出的方法^[36-39]。基于扭矩平均值的评估方法只能正确判定少量样本的健康等级,远远无法满足工业应用的要求^[40]。通过对比分析可知,集成 4 种症状参数的评估模型可全面反映航空柱塞泵的健康状况,证实了多模型多状态融合的人机协同评估方法的优越性^[41]。另一方面,通过 SWARA、DEMATEL 和 Entropy 决策模型确定权重并进行健康评估结果并不理想。相较于上述决策模型,采用语义 Z 数环境下的 TOPSIS 方法评估的状态风险权重可放大不同运行状态对系统行为的影响差异,特别是两种相邻运行状态。

表4 航空柱塞泵的原始健康状况、健康指标、聚类精度以及各健康状况下的勘误表

Table 4 Raw health conditions, health indicators, clustering accuracy, and errors associated with each health condition of aerospace piston pump

对比方法	原始健康状况,健康指标,相应的勘误符号											聚类 准确率/%	
	健康		配油盘轻微磨损				配油盘严重磨损						
	试验-1	试验-2	试验-1	试验-2	试验-1	试验-2	试验-1	试验-2					
提出的方法	0.734	○	0.749	○	0.635	○	0.617	○	0.076	○	0.173	○	97.13
RMS方法	0.718	○	0.651	×	0.618	○	0.593	○	0.072	○	0.154	○	85.25
CF方法	0.698	○	0.734	○	0.641	○	0.694	×	0.089	○	0.115	○	89.57
PF方法	0.634	×	0.652	×	0.698	×	0.703	×	0.065	○	0.164	○	48.78
TMV方法	0.708	○	0.653	×	0.612	○	0.694	×	0.126	○	0.147	○	69.53
DEMATEL[16]	0.751	○	0.641	×	0.705	×	0.753	×	0.152	○	0.067	○	58.47
SWARA[34]	0.654	×	0.712	○	0.735	×	0.686	×	0.115	○	0.023	○	56.54
Entropy[35]	0.635	×	0.706	○	0.687	×	0.613	○	0.165	○	0.089	○	73.68

4 结 论

为了全面准确地评估机械装备的健康状态,本文提出了一种基于模糊残差收缩网络与人机协同的机械装备健康评估方法,通过搭建航空柱塞泵实验平台对所提出方法的有效性进行了验证,主要结论如下。

1) 提出了一种新的模糊残差收缩网络,构建了基于多症状参数的评估模型,精准构建了装备状态隶属度函数。

2) 采用BWM方法和语义Z数环境下的TOPSIS方法确定模型证据权重和状态风险权重。基于专家评估意见判断不同应用场景下各症状参数模型的优先级,并在考虑各运行状态对航空柱塞泵行为的影响差异,从而获得视情而定的健康评估结果。

3) 多功能k-means聚类可客观判定航空柱塞泵健康等级,根据健康等级划分结果提供层次化的运行维护建议,有效提升健康评估方法的适用性。

相比传统的健康评估方法,本文提出的方法取得了一定的突破,但也存在着一定的问题。后续研究可探索不同的权重决策框架,如邀请多位首席专家和助理专家,协作评估模型证据和状态风险权重,以获取更加可靠的权重评估结果。还可以研究航空柱塞泵剩余使用寿命预测技术,从剩余使用寿命的角度判断航空柱塞泵当前的健康状态。此外,为验证所提出方法的泛化性,将开展变工况下航空柱塞泵配油盘故障模拟实验。

参考文献

[1] 陈作懿,邓超,吴军,等. 基于收缩自注意关系网络的机械装备故障智能检测与定位方法[J]. 中国科学:

技术科学,2023,53(7): 1214-1228.

CHEN Z Y, DENG CH, WU J, et al. Shrinkage transformer relation network for intelligent fault detection of industrial robot mechanical equipment[J]. Scientia Sinica Technologica, 2023;53(7): 1214-1228.

[2] ZHANG SH H, SUN ZH ZH, WANG M, et al. Deep fuzzy echo state networks for machinery fault diagnosis[J]. IEEE Transactions on Fuzzy Systems, 2020, 28(7): 1205-1218.

[3] RIBEIRO JUNIOR R F, DE ALMEIDA F A, GOMES G F. Fault classification in three-phase motors based on vibration signal analysis and artificial neural networks[J]. Neural Computing and Applications, 2020, 32(18): 15171-15189.

[4] AMEYAW D A, ROTHE S, SÖFFKER D. A novel feature-based probability of detection assessment and fusion approach for reliability evaluation of vibration-based diagnosis systems[J]. Structural Health Monitoring, 2020, 19(3): 649-660.

[5] SILVA-ROMERO J J, TELLEZ-ANGUIANO A D C, ANZUREZ-MARIN J, et al. Fuzzy FDI system for flyback converters[J]. IEEE Transactions on Fuzzy Systems, 2021, 29(10): 2859-2868.

[6] REY R, COBANO J A, CORZETTO M, et al. A novel robot co-worker system for paint factories without the need of existing robotic infrastructure[J]. Robotics and Computer-Integrated Manufacturing, 2021, 70(9): 102122.

- [7] ZHOU H L, LIU ZH Y, YANG X W, et al. Motor torque fault diagnosis for four wheel independent motor-drive vehicle based on unscented kalman filter[J]. IEEE Transactions on Vehicular Technology, 2018, 67 (3): 1969-1976.
- [8] OH Y, KIM Y, NA K, et al. A deep transferable motion-adaptive fault detection method for industrial robots using a residual-convolutional neural network[J]. ISA Transactions, 2022, 128: 521-534.
- [9] KANG J S, FANG H, HAO Y F, et al. A closed-loop evaluation method for industrial robot performance driven by health data[J]. IEEE/ASME Transactions on Mechatronics, 2023, 28(2): 726-736.
- [10] ALI M Z, SHABBIR M N S K, LIANG X D, et al. Machine learning-based fault diagnosis for single-and multi-faults in induction motors using measured stator currents and vibration signals[J]. IEEE Transactions on Industry Applications, 2019, 55(3): 2378-2391.
- [11] MAO Y, ZUO SH G, CAO J N. Effects of rotor position error on longitudinal vibration of electric wheel system in in-wheel PMSM driven vehicle[J]. IEEE/ASME Transactions on Mechatronics, 2018, 23 (3): 1314-1325.
- [12] XIAO H, ZENG H L, JIANG W, et al. HMM-TCN-based health assessment and state prediction for robot mechanical axis[J]. International Journal of Intelligent Systems, 2022, 37(12): 10476-10494.
- [13] IZAGIRRE U, ANDONEGUI I, ECIOLAZA L, et al. Towards manufacturing robotics accuracy degradation assessment: A vision-based data-driven implementation[J]. Robotics and Computer-Integrated Manufacturing, 2021, 67: 102029.
- [14] JIANG W X, WANG H H, LIU G J, et al. A novel method for mechanical fault diagnosis of underwater pump motors based on power flow theory[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:9700217.
- [15] JIANG W X, WU J, ZHU H P, et al. Paired ensemble and group knowledge measurement for health evaluation of wind turbine gearbox under compound fault scenarios[J]. Journal of Manufacturing Systems, 2023, 70: 382-394.
- [16] HAFEZALKOTOB A, HAFEZALKOTOB A, LIAO H CH, et al. An overview of MULTIMOORA for multi-criteria decision-making: Theory, developments, applications, and challenges [J]. Information Fusion, 2019, 51: 145-177.
- [17] KHAN M J, ALI M I, KUMAM P, et al. Improved generalized dissimilarity measure-based VIKOR method for pythagorean fuzzy sets [J]. International Journal of Intelligent Systems, 2022, 37(3): 1807-1845.
- [18] 马英海, 周林, 王亮. 基于劣化度的装备健康状态评估模型[J]. 火力与指挥控制, 2014, 39(10): 66-69.
- MA Y H, ZHOU L, WANG L. Deterioration-based equipment health state assessment model[J]. Firepower and Command and Control, 2014, 39(10):66-69.
- [19] 俞翔, 杜刚, 何其伟. 武器装备完好性评价方法研究[J]. 中国工程科学, 2015, 32(4): 76-82.
- YU X, DU G, HE Q W. Research on the method of evaluating the integrity of weapons and equipment [J]. Chinese Academy of Engineering Sciences, 2015, 32(4): 76-82.
- [20] DUAN CH Y, CHEN X Q, SHI H, et al. A new model for failure mode and effects analysis based on K-means clustering within hesitant linguistic environment [J]. IEEE Transactions on Engineering Management, 2022, 69(5): 1837-1847.
- [21] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [J]. 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016, 7(1): 770-778.
- [22] MA S, CHU F L, HAN Q K. Deep residual learning with demodulated time-frequency features for fault diagnosis of planetary gearbox under nonstationary running conditions[J]. Mechanical Systems and Signal Processing, 2019, 127: 190-201.
- [23] ZHAO M H, ZHONG SH SH, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16 (7): 4681-4690.
- [24] WANG W, ISMAIL F, GOLNARAGHI F, et al. A neuro-fuzzy approach to gear system monitoring [J]. IEEE Transactions on Fuzzy Systems, 2004, 12 (5): 710-723.
- [25] HAFEZALKOTOB A, HAFEZALKOTOB A, et al. A novel approach for combination of individual and group

- decisions based on fuzzy best-worst method[J]. *Applied Soft Computing Journal*, 2017, 59: 316-325.
- [26] HUANG J, XU D H, LIU H CH, et al. A new model for failure mode and effect analysis integrating linguistic Z-numbers and projection method[J]. *IEEE Transactions on Fuzzy Systems*, 2021, 29(3): 530-538.
- [27] DREHER N R, DE ALMEIDA I O, STORTI G C, et al. Feature analysis by k-means clustering for damage assessment in rotating machinery with rolling bearings[J]. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2022, 44(8): 330-343.
- [28] WANG B, WANG G W, WANG Y W, et al. A K-means clustering method with feature learning for unbalanced vehicle fault diagnosis[J]. *Smart and Resilient Transportation*, 2021, 3(2): 162-176.
- [29] XIA SH Y, PENG D W, MENG D Y, et al. Ball k-means: Fast adaptive clustering with no bounds[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(1): 87-99.
- [30] LIU Q, LIU H T, XIAO J L, et al. Open-architecture of CNC system and mirror milling technology for a 5-axis hybrid robot[J]. *Robotics and Computer-Integrated Manufacturing*, 2023, 81: 102504.
- [31] RAVIOLA A, GUIDA R, DE MARTIN A, et al. Effects of temperature and mounting configuration on the dynamic parameters identification of industrial robots[J]. *Robotics*, 2021, 10(3): 10030083.
- [32] BILANCIA P, MONARI L, RAFFAELI R, et al. Accurate transmission performance evaluation of servo-mechanisms for robots[J]. *Robotics and Computer-Integrated Manufacturing*, 2022, 78: 102400.
- [33] AIVALIOTIS P, ARKOULI Z, GEORGOULIAS K, et al. Degradation curves integration in physics-based models: Towards the predictive maintenance of industrial robots[J]. *Robotics and Computer-Integrated Manufacturing*, 2021, 71: 102177.
- [34] GHENAI C, ALBAWAB M, BETTAYEB M, et al. Sustainability indicators for renewable energy systems using multi-criteria decision-making model and extended SWARA/ARAS hybrid method[J]. *Renewable Energy*, 2020, 146: 580-597.
- [35] ZHANG Y, DONG X D, YIN F F, et al. Tree-coding-aided adaptive-cross-entropy algorithm for hybrid precoding with low-resolution analog phase shifters[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(6): 6807-6812.
- [36] 乔卉卉, 赵二贤, 郝如江, 等. 基于注意力机制与多源信息融合的变工况轴承故障诊断[J/OL]. *仪器仪表学报*, 1-11[2024-11-05].
- QIAN H H, ZHAN ER X, HAO R J, et al. Attention mechanism and multi-source information fusion-based method for bearing fault diagnosis under variable operating conditions[J/OL]. *Chinese Journal of Scientific Instrument*, 1-11[2024-11-05].
- [37] 万书亭, 郭胡森, 豆龙江, 等. 基于电流-振动信号联合特征的高压断路器故障诊断方法[J/OL]. *电子测量技术*, 1-8[2024-11-05].
- WAN SH T, GUO H S, DOU L J, et al. Fault diagnosis method of high voltage circuit breaker based on the combined characteristics of current and vibration signal[J/OL]. *Electronic Measurement Technology*, 1-8[2024-11-05].
- [38] 卢浩龙, 朱彦敏. 基于多尺度图 Transformer 的滚动轴承故障诊断[J]. *国外电子测量技术*, 2023, 42(12): 186-194.
- LU H L, ZHU Y M. Fault diagnosis of rolling bearing based on multi-scale graph transformer[J]. *Foreign Electronic Measurement Technology*, 2023, 42(12): 186-194.
- [39] 路飞宇, 佟庆彬, 姜学东, 等. 一种基于条件度量迁移学习的机械故障诊断可解释方法[J]. *仪器仪表学报*, 2024, 45(7): 250-262.
- LU F Y, TONG Q B, JIANG X D, et al. Interpretable method for mechanical fault diagnosis based on condition metric transfer learning[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(7): 250-262.
- [40] 王超, 田波, 李子睿, 等. 基于自注意力子域自适应对抗网络的轴承故障诊断方法[J]. *中国舰船研究*, 2023, 18(5): 260-268.
- WANG CH, TIAN B, LI Z R, et al. Self-attention and subdomain adaptive adversarial network for bearing fault diagnosis under varying operation conditions[J]. *Chinese Journal of Ship Research*, 2023, 18(5): 260-268.
- [41] 王晓琪, 吴轲, 赵观辉, 等. 基于全局注意力残差收缩网络的柱塞泵故障诊断方法[J/OL]. *中国舰船研究*, 1-8[2024-11-05].

WANG X Q, WU K, ZHAO G H, et al. Fault diagnosis of piston pump based on global attention residual shrinkage network [J/OL]. Chinese Journal of Ship Research, 1-8[2024-11-05].

作者简介



江伟雄, 2018 年获得武汉轻工大学学士学位, 2021 年获得中国海洋大学硕士学位, 目前正在攻读华中科技大学船舶与海洋工程专业博士学位, 主要研究方向为基于多源信号的先进设备智能故障诊断与健康评估技术。

E-mail: jiangweixiong@hust.edu.cn

Jiang Weixiong received his B. Sc. degree from Wuhan Polytechnic University, in 2018, and received his M. Sc. degree from Ocean University of China, in 2021. He is currently pursuing the Ph. D. degree in Naval Architecture and Ocean Engineering from Huazhong University of Science and Technology. His major is naval architecture and ocean engineering, and his present research works are intelligent fault diagnosis technology of advanced equipment using multisource signals.



王吉, 分别于 2018 年和 2020 年获得华中科技大学轮机工程学士学位和硕士学位, 现为工业和信息化部电子第五研究所可靠性工程师, 主要研究方向为机电设备故障诊断与健康评估。

E-mail: 522566754@qq.com

Wang Ji received a B. Sc. degree in Marine Engineering from Huazhong University of Science and Technology in 2018 and M. Sc. degree in the same field in 2020. He is currently working as a reliability engineer at the Fifth Institute of Electronics under the Ministry of Industry and Information Technology. His primary research focus is on fault diagnosis and

health management of electromechanical equipment.



吴军(通信作者), 2001 年获得湖北工学院学士学位, 分别于 2004 年和 2008 年获得华中科技大学机械工程硕士和博士学位, 现为华中科技大学船舶与海洋工程学院教授, 主要研究方向为装备健康监测, 故障诊断与寿命预测。

E-mail: wuj@hust.edu.cn

Wu Jun (Corresponding author) received his B. Sc. degree from Hubei University of Technology, in 2001, and received his M. Sc. and Ph. D. degrees in mechanical engineering from Huazhong University of Science and Technology (HUST), in 2004 and 2008, respectively. He is currently a full professor of School of Naval Architecture and Ocean Engineering at HUST. His research interests include equipment health monitoring, fault diagnosis and remaining useful life prediction.



朱海平, 1998 年获兰州理工大学学士学位, 2001 年和 2005 年分别获武汉华中科技大学机械工程硕士和博士学位。他的研究兴趣包括制造系统建模与优化、可靠性分析与维护决策、智能制造与数字化车间应用。

E-mail: haipzhu@hust.edu.cn

Zhu Haiping received the B. Sc. degree from the Lanzhou University of Technology, Lanzhou, China, in 1998, and the M. Sc. and Ph. D. degrees in mechanical engineering from the Huazhong University of Science and Technology (HUST), Wuhan, China, in 2001 and 2005, respectively. He is currently a full professor with the School of Mechanical Science and Engineering. His research interests include modeling and optimization of manufacturing system, reliability analysis and maintenance decisions, and intelligent manufacturing and digital workshop applications.