

# 基于时间序列的柴油机空气系统健康状态评估与预测方法

王永康,文冠华,王彦岩\*,沈照杰,马琮淦,纪兆圻,林波,邵麓铭

哈尔滨工业大学(威海),山东 威海 264200

**摘要:**为解决柴油机空气系统因结构复杂、故障频发、全生命周期数据不足及故障精确表征困难导致的柴油机空气系统健康状态评估难题,为其预测性维护提供支撑,提出一种基于时间序列的柴油机健康状态评估方法,根据单位时间内空气系统健康状态构建初始健康指标,采用自编码器模型对初始指标进行特征加权优化以提高表征精度,按照时间序列结合滑动窗口法对历史健康状态进行平滑处理,构建长短期记忆(long-short term memory, LSTM)网络,预测柴油机空气系统的健康状态。结果表明:设计的基于时间序列的柴油机空气系统健康状态评估方法有效且预测准确度较高,健康状态预测结果与实测结果的均方误差为  $2.11 \times 10^{-5}$ ,均方根误差为 0.004 6,平均绝对误差为 0.003 1,该方法可以为柴油机空气系统预测性维护提供可靠支撑。

**关键词:**柴油机;健康状态评估;健康状态预测;LSTM 网络

**中图分类号:**TK421

**文献标志码:**A

**文章编号:**1673-6397(2025)06-0012-09

**引用格式:**王永康,文冠华,王彦岩,等.基于时间序列的柴油机空气系统健康状态评估与预测方法[J].内燃机与动力装置,2025,42(6):12-20.

WANG Yongkang, WEN Guanhua, WANG Yanyan, et al. Health status assessment and prediction method for a diesel engine air system based on time series [J]. Internal Combustion Engine & Powerplant, 2025, 42 (6):12-20.

## 0 引言

评估柴油机空气系统健康状态并适时进行预测性维护,是降低维护成本、提高柴油机性能的重要发展方向,也是当前柴油机研究领域的热点和难点问题。目前,健康状态评估的方法主要基于物理模型<sup>[1]</sup>、统计模型<sup>[2]</sup>、数据驱动<sup>[3]</sup>。基于物理建模方法需要为特定发动机建立理想模型,存在通用性差的局限<sup>[4]</sup>,因此在实际应用中常采用多模型融合方法对发动机健康状态进行评估<sup>[5]</sup>。

针对健康监测普遍存在的数据采集困难以及数据处理存在模糊等问题,丰世林<sup>[6]</sup>提出了融合层次分析法与 T-S 模糊神经网络的评估模型,实现了对发动机健康状态多指标量化评估;吴学海<sup>[7]</sup>提出了左右型混合高斯隐马尔可夫模型,适配发动机的不可逆退化特性,得到的剩余寿命与健康状态预测结果均与实际运行结果吻合;Javed 等<sup>[8]</sup>提出了增强的多元退化建模方法,实现发动机健康状态的动态评估与剩余寿命的精准估计,通过筛选可预测性特征、两步聚类降噪等方法,解决了发动机动态工况下监测数据噪声大、存在不确定性的问题;García Nieto 等<sup>[9]</sup>针对发动机状态评估中非线性退化过程难处理的问题,提出了粒子群优化融合径向基核函数-支持向量机的混合模型;Aremu 等<sup>[10]</sup>基于相对熵 Weibull-SAX 框

收稿日期:2025-11-13

第一作者简介:王永康(2000—),男,山东德州人,硕士研究生,主要研究方向为柴油机健康管理与故障诊断,E-mail:1059153855@qq.com。

\*通信作者简介:王彦岩(1974—),男,黑龙江齐齐哈尔人,工学博士,副教授,硕士生导师,主要研究方向为车辆健康管理与智能传感器,E-mail:wangyanyan@hit.edu.cn。

架,构建精准健康指标并划分健康阶段,提高了多变量退化数据下发动机状态评估的精细化程度;Che等<sup>[11]</sup>针对发动机状态评估中剩余寿命估计精度不足问题,构建了结合2种深度学习算法的健康管理模型,以深度信念网络进行状态评估与故障分类,以长短期记忆(long-short term memory, LSTM)网络对传感器数据进行时序预测,提高了故障分类精度;曹惠玲等<sup>[12]</sup>针对民航发动机寿命预测中存在的单参数监控不全面、多参数利用率低的问题,提出了基于多参数融合相似的预测方法,突破了单参数局限,采用ReliefF-主成分分析方法将多维度参数融合为健康指数,将多参数信息融合为单指标,精准量化发动机退化程度,为航空发动机健康状态预测提供可靠基准。

健康状态评估是指将分析设备上的高精度传感器采集得到的各项性能参数,通过构建模型或使用其他推理机制预估设备的健康状态和剩余寿命<sup>[13]</sup>。崔晓飞等<sup>[14]</sup>针对发动机热力参数存在互补性但信息传递不确定性的问题,提出了基于贝叶斯信息融合的健康状态评估方法,用性能老化参数 $\theta$ (取值范围为0~1)直观表征老化程度,量化发动机的健康状态。胡金海等<sup>[15]</sup>将发动机的多个工作参数加权融合,以遗传算法优化权重的性能综合指数作为健康状态指标,克服了传统单参数表征健康状态的片面性。Malhotra等<sup>[16]</sup>利用多传感器数据中的健康序列训练LSTM编码器-解码器,将重构误差归一化得到一维健康因子,并据此构建了健康状态曲线。健康状态曲线既可直观反映设备在某个时刻的健康状态,还能体现设备健康状态随工作时间的变化趋势<sup>[17]</sup>。综上,健康状态评估的核心在于分析传感器的检测数据,将多维数据量化为健康状态等指标,得到健康状态曲线并划分健康等级,为设备使用寿命预测与维护决策提供依据。

柴油机传感器测量的数据呈显著波动的特征,空气系统健康状态受多维参数非线性耦合作用的影响,且缺乏有效的动态量化指标,导致其健康状态评估难度增大。本文中构建面向国六柴油机空气系统的深度学习健康评估模型,优先基于关键特征参数建立状态分类与健康状态的精准量化指标,动态预测柴油机空气系统的健康状态,并利用实车运行数据对模型的评估性能进行验证。

## 1 健康状态构建

柴油机空气系统结构复杂,运行过程中易出现各类故障。当前单台发动机可获取的有效信息较少,难以支撑全生命周期的健康评估,且空气系统故障对发动机当前健康状态的影响不容忽视。因此,提出一种新型健康状态参数以评价柴油机空气系统健康状态并对其进行优化,健康状态的具体构建流程如图1所示。

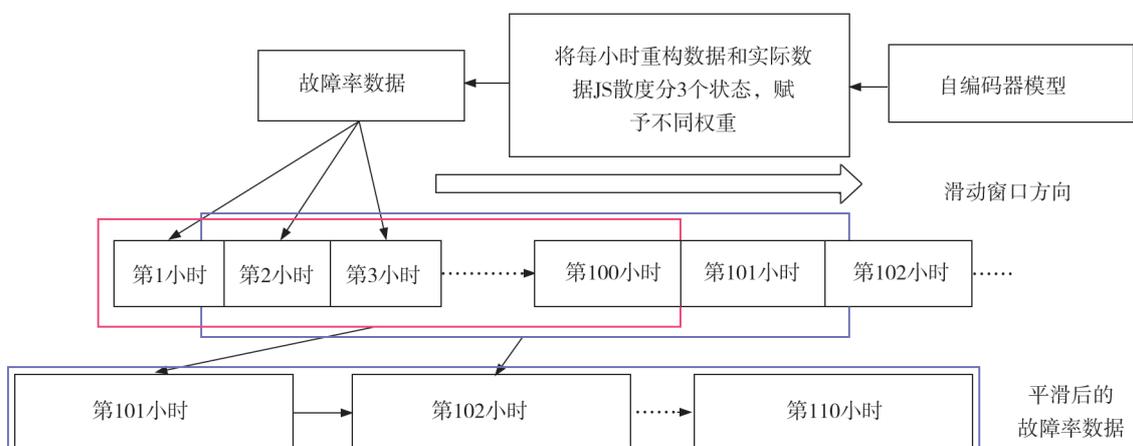


图1 空气系统健康状态构建流程图

### 1.1 初步健康状态计算

将单台发动机的时间序列数据以1 h为周期分组,初步健康状态

$$H_{\text{fr}} = 1 - N_f / N, \quad (1)$$

式中:  $N_f$  为 1 h 内空气系统故障数,  $N$  为数据总数。

### 1.2 健康状态加权修正

基于自编码器对重构误差进行加权处理,以修正设备的健康状态。利用自编码器模型的特征重构能力,将数据划分为健康数据、其他系统故障数据与空气系统故障数据 3 类,为初步健康状态引入加权修正机制。首先,使用健康数据训练自编码器,使模型学习健康数据的内在模式与变量之间的关系;其次,将另外 2 类数据输入已训练的模型,由于故障数据的特征分布偏离健康模式,模型的重构误差显著增大,通过分析 3 类数据的重构误差分布,设置 2 个阈值  $t_1$ 、 $t_2$ ,尽可能清晰地区分 3 类数据;最后,根据数据所属的误差区间,赋予不同的权重因数。3 类数据加权修正后的健康状态分别记为  $H_{\text{sh}}$ 、 $H_{\text{sc}}$ 、 $H_{\text{sf}}$ ,其计算式分别为:

$$H_{\text{sh}} = (H_{\text{fr}} + 1) \varepsilon_1 w_1, \quad (2)$$

$$H_{\text{sc}} = (H_{\text{fr}} + 1) \varepsilon_2 w_2, \quad (3)$$

$$H_{\text{sf}} = (H_{\text{fr}} + 1) \varepsilon_3 w_3, \quad (4)$$

式中:  $w_1$ 、 $w_2$ 、 $w_3$  分别为健康数据、其他系统故障数据、空气系统故障数据的权重因数,  $\varepsilon_1$ 、 $\varepsilon_2$ 、 $\varepsilon_3$  分别为 3 种数据的模型分类准确率。

为了防止  $H_{\text{fr}}$  为 0 导致的权重因数灵敏度下降,在计算中对  $H_{\text{fr}}$  进行加 1 处理,以确保权重调整的有效性。

### 1.3 健康状态平滑处理

为消除健康状态波动并确保其时间连续性,同时反映历史状态对当前状态的影响,基于滑动窗口平滑算法对数据进行处理,最终健康状态

$$H_{1,n} = \left( \sum_{n=100}^n H_{\text{is},n} + 1 \right) / 100, \quad (5)$$

式中  $H_{\text{is},n}$  为第  $n$  小时加权后的健康状态。

## 2 基于自编码器的数据分类

### 2.1 自编码器模型

基于自编码器健康状态加权模型整体框架如图 2 所示,具体流程包含 5 个步骤:1)数据预处理。对健康数据、非空气系统故障数据、空气系统故障数据执行相同的数据预处理。2)数据集构建。利用部分健康数据构建训练集、验证集与测试集。3)模型训练。构建模型并利用其对准备好的数据集逐步完成训练。4)阈值确定。把两类数据以及未参与训练的健康数据输入由步骤 3)得到的模型,然后分别计算重构误差;通过分析 3 类数据重构误差的分离情况,判断能否设定有效的分类阈值,若 3 类数据可区分,则确定最佳阈值;否则调整预处理方法或模型结构后重新训练。5)健康状态加权修正。为

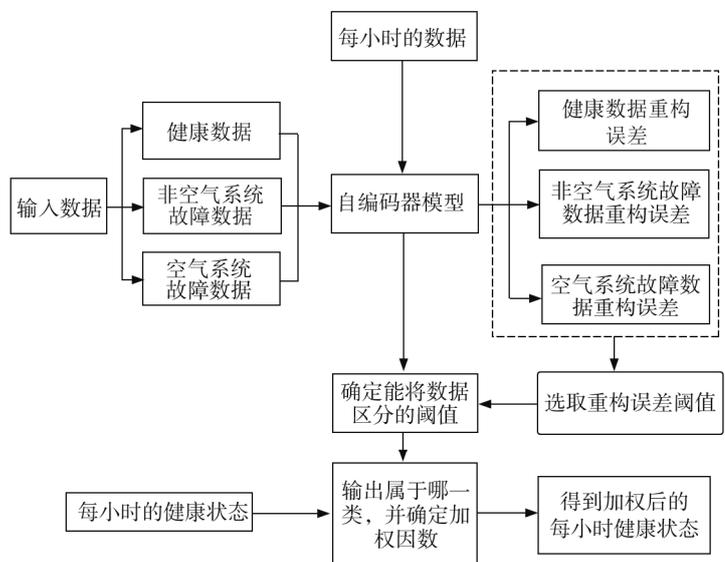


图 2 健康状态加权模型框架

避免初步健康状态为 0 导致的加权失效,先将其进行加 1 处理,然后根据模型判定的数据类型,按照式

(2)~(4)调整权重。

参照既有研究经验并经试验验证,本文中自编码器模型的超参数设置如表1所示。

表1 自编码器模型的超参数

激活函数	模型层数	节点数	学习率	批大小	训练次数	优化算法
Tanh/Relu	7	8-13-5-2-5-13-8	0.001	16	300	Adam

## 2.2 重构误差求解

为量化自编码器对原始数据的重构效果,在健康数据与2类故障数据的重构误差计算中,采用欧氏距离、曼哈顿距离、切比雪夫距离<sup>[18]</sup>、余弦距离<sup>[19]</sup>作为关键的对比与度量准则。

2个 $m$ 维变量 $x = (x_1, x_2, \dots, x_m)$ 、 $y = (y_1, y_2, \dots, y_m)$ 之间的闵可夫斯基距离

$$d_M(x, y) = (|x - y|^p)^{1/p}, \quad (6)$$

式中: $p$ 为常数。 $p=1$ , $d_M$ 为曼哈顿距离; $p=2$ , $d_M$ 为欧氏距离; $p=\infty$ , $d_M$ 为切比雪夫距离。

余弦距离 $d_{\cos(x,y)}$ 用于度量2个向量在空间方向上的相似程度,计算式为:

$$d_{\cos(x,y)} = \frac{x \cdot y}{|x| \cdot |y|} = \frac{\sum_{i=1}^m x_i y_i}{\sqrt{\sum_{i=1}^m x_i^2} \sqrt{\sum_{i=1}^m y_i^2}}。 \quad (7)$$

KL散度<sup>[20]</sup>用于衡量概率分布的距离,若有两个概率分布 $P(x)$ 、 $Q(x)$ ,KL散度

$$D_{KL}(P \parallel Q) = \sum P(x) \log \frac{P(x)}{Q(x)}。 \quad (8)$$

由于KL散度不满足对称性,即 $D_{KL}(P \parallel Q) \neq D_{KL}(Q \parallel P)$ ,在其基础上进行改进得到JS散度。

JS散度

$$D_{JS}(P \parallel Q) = \frac{1}{2} D_{KL}(P \parallel M) + \frac{1}{2} D_{KL}(Q \parallel M), \quad (9)$$

式中: $M$ 为 $P$ 、 $Q$ 的均值, $M = \frac{1}{2}(P + Q)$ 。

采用Tanh函数为激活函数,分别计算重构数据和原数据之间的上述距离以评估重构误差,输入数据对应标签如表2所示。

表2 输入数据对应标签

输入数据类型	对应标签	输入数据类型	对应标签
健康数据	健康	EGR流量过高	故障4
其他系统故障	其他系统故障	节气门响应慢	故障5
EGR闭环监控故障	故障1	增压压力过高	故障6
节气门闭环监控故障	故障2	增压压力过低	故障7
近期中冷后效率低	故障3	EGR冷却器效率低	故障8

为了系统评估自编码器模型对不同状态参数的重构效果,将经过健康数据训练的模型应用于包括健康数据与各类故障数据在内的完整数据集,并在此基础上计算欧氏距离、曼哈顿距离、切比雪夫距离、余弦距离和JS散度,分析比较输入数据与重构数据的差异,结果如图3所示。由图3可知:虽然欧氏距离、曼哈顿距离、切比雪夫距离这3类几何度量方法能够在一定程度上区分健康数据与故障数据,但对不同故障类型的判别能力有限;基于信息论概念的JS散度不仅能够有效区分健康与故障状态,还能精准划分不同故障类型。由于JS散度在细粒度分类方面优势显著,本文中将其作为后续数据分类与分析的核心度量方法。

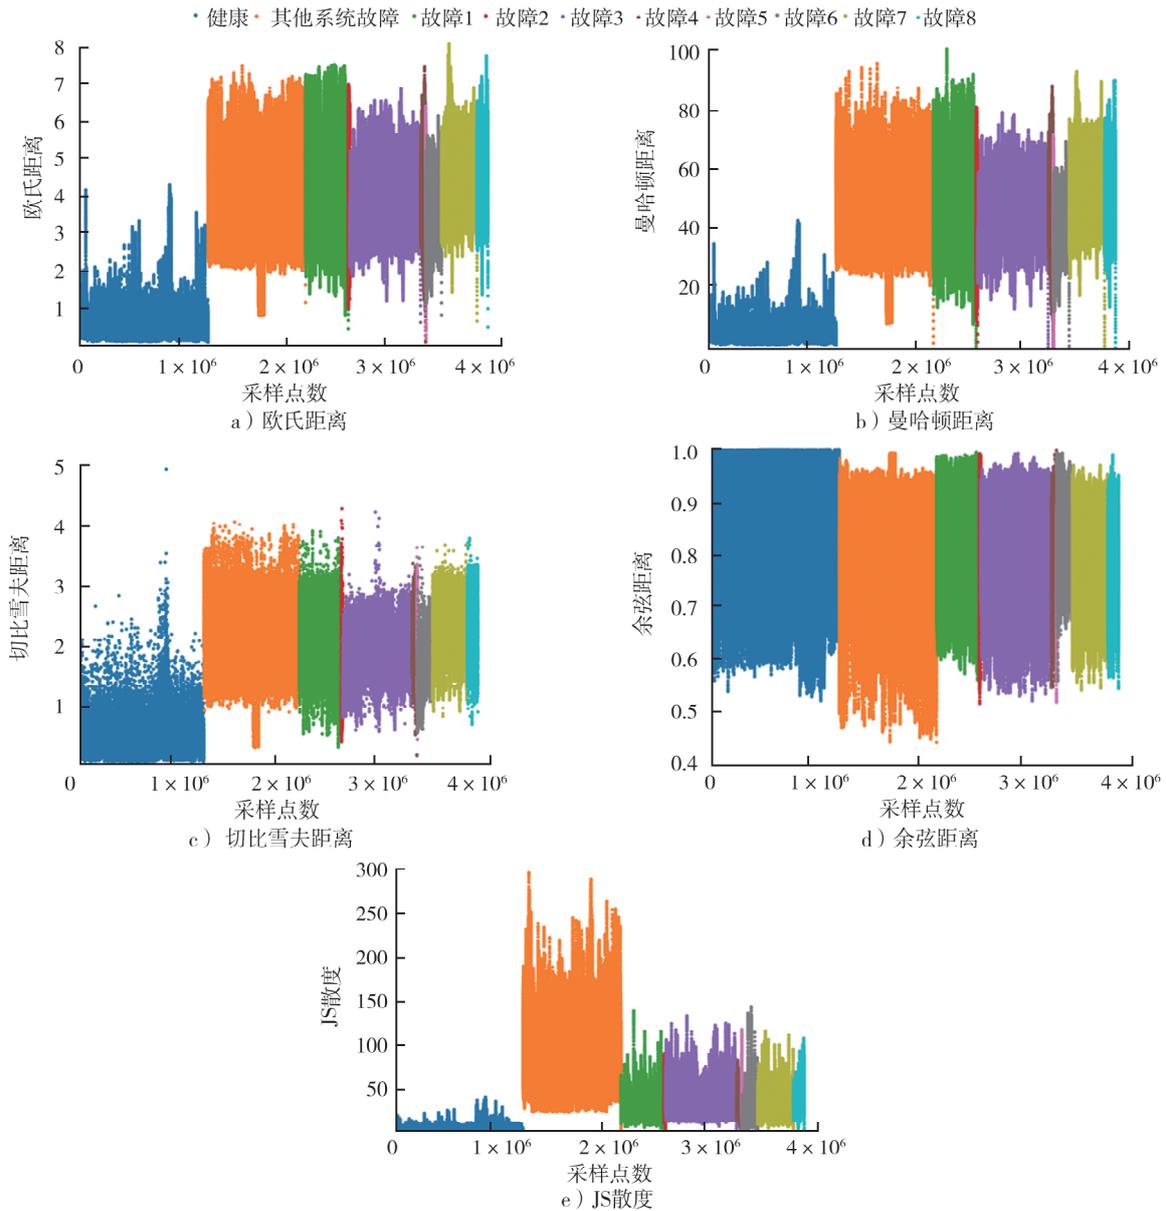


图3 不同度量方法分析的输入数据与重构数据对比

### 2.3 数据分类

在激活函数选用 Tanh 的基础上,为使误判率最小化,按顺序确定区分类别数据的阈值  $t_1$ 、 $t_2$ ,分类规则定义为:当  $D_{JS} < t_1$  时,判定为健康数据;当  $t_1 \leq D_{JS} \leq t_2$  时,判定为空气系统故障数据;当  $t_2 < D_{JS}$  时,判定为其他系统故障数据。 $t_1$ 、 $t_2$  选择示意图如图 4 所示。由图 4 可知: $t_1$  在 0~10 之间, $t_2$  在 40~50 之间。

根据 JS 散度分别绘制健康数据、空气系统故障、其他系统故障被误判的比例曲线,如图 5 所示。由图 5a)可知:随  $t_1$  增大,健康数据、空气系统故障误判率曲线呈相反的变化趋势,曲线在  $t_1$  为 7.73 时相交,此时健康数据和空气系统故障数据的误判率相等,均为 1.6%。由图 5b)可知:随着  $t_2$  增大,空气系统故障及

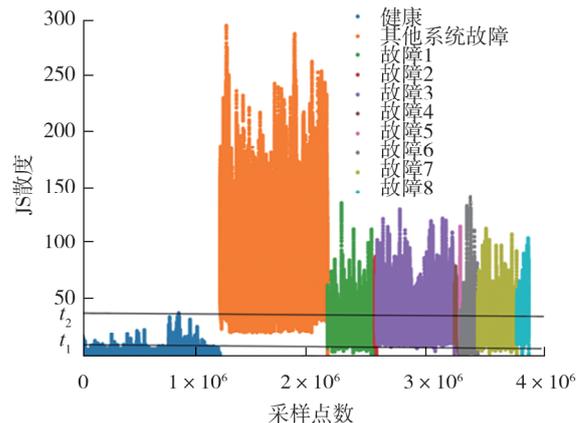


图4  $t_1$ 、 $t_2$  示意图

其他系统故障误判率曲线呈相反变化趋势,当  $t_2$  增大到 42.04 时,2 条曲线相交,此时空气系统故障和其他系统故障的误判率均为 7.5%。因此确定  $t_1$  为 7.73、 $t_2$  为 42.04。

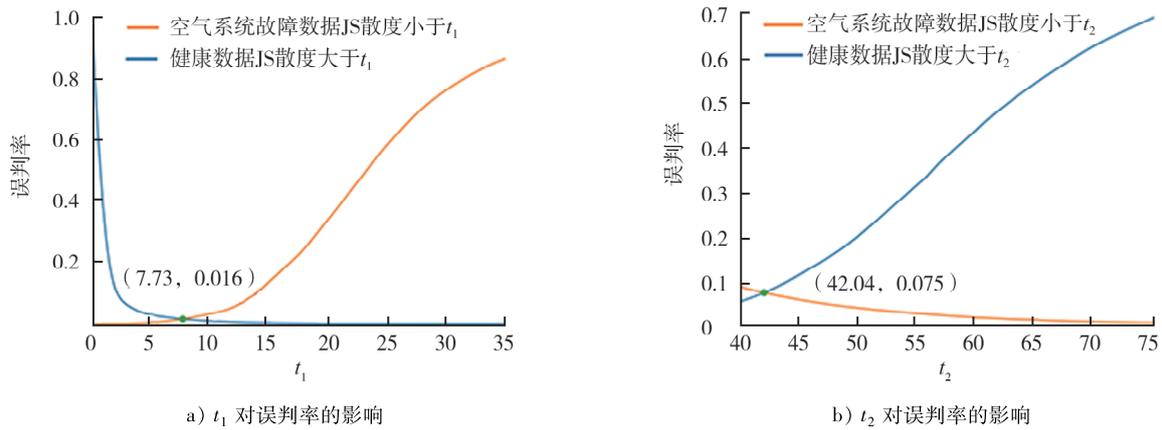


图5  $t_1$  和  $t_2$  对误判率的影响

$t_1 = 7.73$ 、 $t_2 = 42.04$  时计算输入数据的分类准确率:健康数据的判断准确率为 98.4%,其他系统故障的判断准确率为 92.5%,空气系统故障的判断准确率为 90.9%。3 类数据的准确率均超过 90%,说明以  $t_1 = 7.73$ 、 $t_2 = 42.04$  作为分类阈值能有效区分健康数据、其他系统故障与空气系统故障。

不同激活函数的分类性能存在差异。为取得更好的效果,测试 Relu 函数作为激活函数时的分类性能,采用 Relu 函数为激活函数时的 JS 散度对比如图 6 所示,误判率曲线随  $t_1$ 、 $t_2$  的变化关系如图 7 所示。由图 7 可知:当激活函数为 Relu 时其他系统故障数据和空气系统故障数据的误判率随  $t_1$ 、 $t_2$  的变化趋势和激活函数为 Tanh 时的基本相同。由图 7b) 可知:2 条误判率曲线交点所对应的误判率高达约 20%。与使用 Tanh 函数(交点误判率为 1.6%)的结果相比,Relu 函数的分类性能显著下降。因此,Tanh 更适合用作本文中的激活函数。

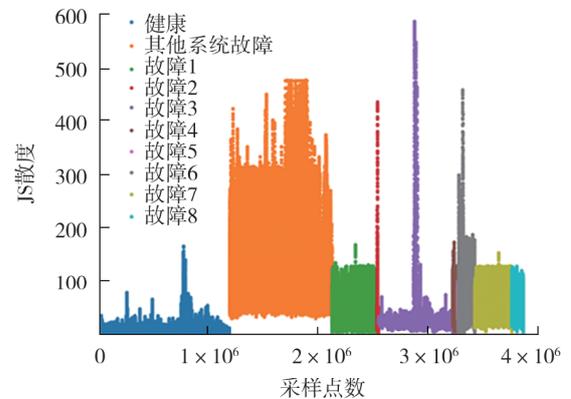


图6 采用 Relu 为激活函数时的 JS 散度对比

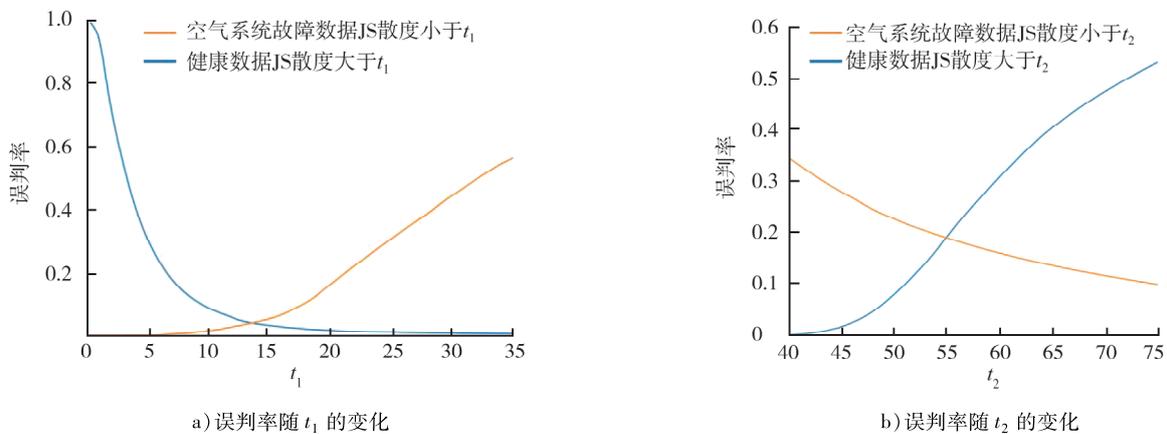


图7 采用 Relu 时三类数据的误判率随  $t_1$  和  $t_2$  的变化

### 2.4 数据平滑

采用滑动窗口平均法进行平滑处理,其中窗口设为 100 h,健康状态定义为当前 1 h 及前 99 h 健康状态的平均值。

### 3 基于 LSTM 网络的空气系统健康状态预测

#### 3.1 数据来源及数据预处理

某配备国六柴油机的车辆传感器采集的数据通过 4G 网络以 1 Hz 的频率传输至服务器,采集的运行数据主要包括两种类型:1)8 台柴油机的连续运行信息,采集时间约 1 a,每台柴油车的行程为 15 万~25 万 km,形成包含 206 个维度、约 1.2 亿条记录的数据集;2)约 7 700 万条故障分类数据,分为健康数据、非空气系统传感器故障数据,以及包含 8 种常见故障的空气系统故障数据。

数据预处理流程包括缺失数据处理、异常数据去除以及数据归一化<sup>[21]</sup>。从原始数据中筛选与空气系统健康状态有关的参数,包括废气再循环(exhaust gas recirculation,EGR)率、EGR 阀开度、发动机转速、节气门开度、进气压力、过量空气系数、发动机输出转矩、增压进气温度。舍弃缺失数据后,得到完备的数据集,按照界定规则识别并剔除异常数据。

样本数据与其均值的差和标准差的比

$$X_p = \frac{X - X_{\text{mean}}}{X_{\text{std}}}, \quad (10)$$

式中: $X$  为一组数据样本, $X = [X_1, X_2, \dots, X_N]$ ;  $X_{\text{mean}}$ 、 $X_{\text{std}}$  分别为样本的均值和标准差。

若  $X_p$  中任一数据大于等于 3,则认为  $X_p$  是异常数据。

采用最小值-最大值归一化对原始的数据进行线性变换,将其映射到  $[0, 1]$  区间,得到最终的预处理输入数据

$$X_{\text{norm}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}), \quad (11)$$

式中: $X_{\text{min}}$  为样本数据的最小值, $X_{\text{max}}$  为样本数据的最大值<sup>[22]</sup>。

利用当前时刻的输入特征,估计未来时刻的健康状态,预测模型的输入为每小时的健康状态及 8 个关键参数组成的 9 维数据,反映发动机空气系统的综合状态。

#### 3.2 LSTM 网络模型搭建与优化

根据设定的预测步长,LSTM 预测模型分为单步预测和多步预测两种模式<sup>[23]</sup>。本文中选用单步预测方法,以历史连续的 10 个时间步的数据为基础,预测未来相邻时刻的健康状态。为客观衡量模型的预测效果,选取均方误差  $E_{\text{MS}}$ 、均方根误差  $E_{\text{RMS}}$ 、平均绝对误差  $E_{\text{MA}}$  作为性能评价指标。当  $E_{\text{MS}}$  较小时,能够提供直观的误差量化评估; $E_{\text{MA}}$  直接反映预测结果与实际值之间的平均偏差幅度。

$E_{\text{MS}}$ 、 $E_{\text{RMS}}$ 、 $E_{\text{MA}}$  的计算式分别为:

$$E_{\text{MS}} = \frac{1}{n_T} \sum_{j=1}^{n_T} (y_j - \hat{y}_j)^2, \quad (12)$$

$$E_{\text{RMS}} = \sqrt{\frac{1}{n_T} \sum_{j=1}^{n_T} (y_j - \hat{y}_j)^2}, \quad (13)$$

$$E_{\text{MA}} = \frac{1}{n_T} \sum_{j=1}^{n_T} |y_j - \hat{y}_j|, \quad (14)$$

式中: $n_T$  为数据总量, $y_j$  与  $\hat{y}_j$  分别为第  $j$  个样本的真实值与模型预测值。

模型的优化目标是尽可能降低预测误差,LSTM 网络关键参数如表 3 所示。

表 3 模型参数

神经元节点数 $u_{\text{inis}}$	批大小	训练次数	损失函数	优化算法	输入数据维度	输出数据维度
1, 5, 25, 50, 75, 100, 125	16	300	$E_{\text{MS}}$	Adam	(10, 9)	(1, 1)

不同神经元节点数下的误差对比结果如表4所示。由表4可知: $u_{\text{mits}} = 50$ 时, $E_{\text{MS}}$ 、 $E_{\text{RMS}}$ 均最小,此配置下 $E_{\text{MA}}$ 虽非全局最低(仅略高于 $u_{\text{mits}} = 125$ 时),但与最低值时的差异不显著。故选取 $u_{\text{mits}} = 50$ 为最终参数。

表4 不同神经元节点数下的误差对比

$u_{\text{mits}}$	$E_{\text{MS}}$	$E_{\text{RMS}}$	$E_{\text{MA}}$	$u_{\text{mits}}$	$E_{\text{MS}}$	$E_{\text{RMS}}$	$E_{\text{MA}}$
1	$3.72 \times 10^{-4}$	0.019 2	0.010 1	75	$5.25 \times 10^{-5}$	0.007 2	0.004 5
5	$1.64 \times 10^{-4}$	0.012 8	0.008 4	100	$6.14 \times 10^{-5}$	0.007 8	0.004 6
25	$1.21 \times 10^{-4}$	0.011 0	0.007 1	125	$5.85 \times 10^{-5}$	0.007 6	0.003 6
50	$4.20 \times 10^{-5}$	0.006 4	0.003 4	150	$8.92 \times 10^{-5}$	0.009 4	0.005 4

## 4 健康状态评估

为实现柴油机空气系统健康状态的动态评估与预测,采用基于时间序列的滚动预测机制,将8台发动机全生命周期监测数据按设备独立划分为训练集(6台)与测试集(2台),确保模型学习不同工况的共性特征,同时验证模型跨设备泛化能力。

在模型构建阶段,以前10 h的健康状态序列作为输入,通过滑动窗口生成时序样本集,输出第11小时的健康状态预测值。LSTM网络采用单层结构, $u_{\text{mits}} = 50$ ,模型训练采用Adam优化器,损失函数选用均方误差,批处理大小为16,训练迭代300次后收敛。

训练集和测试集的预测结果与真实结果对比如图8所示。由图8可知:模型输出的训练集预测结果与真实健康状态在长期趋势、短期波动等维度均高度一致,表明模型具有较好的对历史数据特征的提取与记忆能力;针对测试集中的2台发动机进行滚动单步预测时,在健康状态骤降与阶跃突变等复杂工况下,模型仍能精准跟踪实际轨迹,表明模型对未知工况数据具有良好的泛化能力;测试集 $E_{\text{MS}} = 2.11 \times 10^{-5}$ , $E_{\text{RMS}} = 0.004 6$ , $E_{\text{MA}} = 0.003 1$ ,验证了时序特征加权优化与深度学习结合的优越性。该评估体系通过量化健康状态的演变规律,为柴油机空气系统的故障预警与维护决策提供了可靠依据。

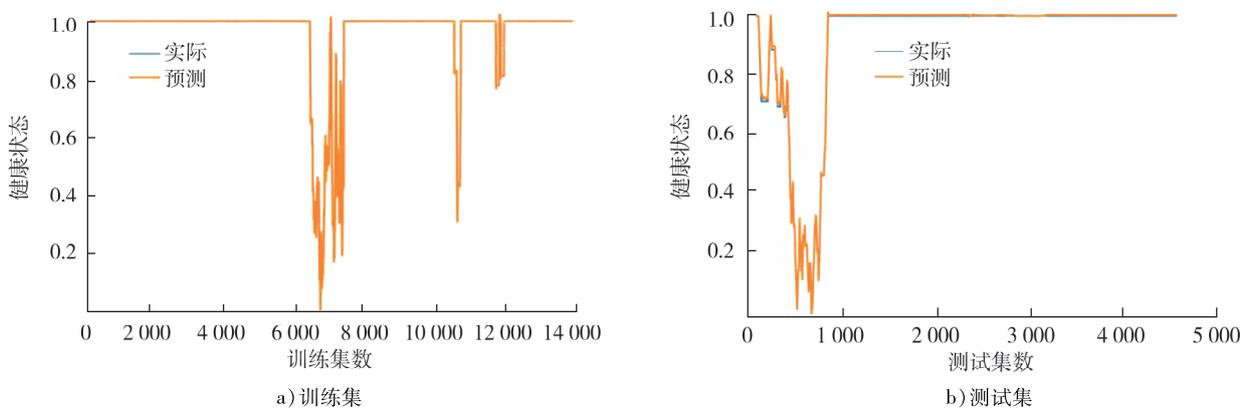


图8 训练集和测试集的预测结果与真实结果对比

## 5 结论

为解决柴油机空气系统健康状态评估难题,提出了一种基于自编码器和LSTM网络融合的柴油机空气系统健康状态评估与预测方法,并对模型进行优化,选择了8台发动机全生命周期监测数据验证其有效性。

1)以加权优化的健康状态参数作为柴油机空气系统健康评价指标,通过计算原始数据与通过自编码器

重构数据之间的重构误差实现数据分类,计算加权健康状态表征空气系统健康状态,准确高效,可信度高。

2)采用JS散度作为重构误差的核心度量指标,与闵可夫斯基距离(欧氏距离、曼哈顿距离、切比雪夫距离)、余弦距离相比,JS散度在量化原始数据与重构数据的概率分布差异方面更具优势。

3)基于LSTM网络的验证结果表明,当神经元节点数设为50时,模型的误差最小;该模型在训练集与测试集上均表现出优异的预测性能,健康状态预测结果与实际高度一致,其均方误差、均方根误差、平均绝对误差分别为 $2.11 \times 10^{-5}$ 、0.004 6、0.003 1,验证了本文研究方法的实用性与准确性。

#### 参考文献:

- [1] 周林,赵杰,冯广飞.装备故障预测与健康管理工作[M].北京:国防工业出版社,2015.
- [2] 吴波.健康状态评估方法及应用研究[J].计算机测量与控制,2009,17(12):2345-2347.
- [3] 周俊.数据驱动的航空发动机剩余使用寿命预测方法研究[D].南京:南京航空航天大学,2017.
- [4] HANACHI H, MECHEFSKE C, LIU J, et al. Performance-based gas turbine health monitoring, diagnostics, and prognostics: a survey[J]. IEEE Transactions on Reliability, 2018, 67(3):1340-1363.
- [5] 曹惠玲,梁佳旺,崔科璐.基于健康指数相似的航空发动机剩余寿命预测[J].科学技术与工程,2020,20(1):361-366.
- [6] 丰世林.民航飞机健康维修管理评估系统设计仿真[J].计算机仿真,2017,34(10):31-35.
- [7] 吴学海.航空发动机的剩余寿命预测与健康状态评估[D].成都:电子科技大学,2014.
- [8] 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.
- [9] GARCÍA NIETO P J, GARCÍA-GONZALO E, SÁNCHEZ LASHERAS F, et al. Hybrid PSO-SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability[J]. Reliability Engineering & System Safety, 2015, 138: 219-231.
- [10] AREMU O O, HYLAND-WOOD D, MCAREE P R. A relative entropy Weibull-SAX framework for health indices construction and health stage division in degradation modeling of multivariate time series asset data[J]. Advanced Engineering Informatics, 2019, 40: 121-134.
- [11] CHE C C, WANG H W, FU Q, et al. Combining multiple deep learning algorithms for prognostic and health management of aircraft[J]. Aerospace Science and Technology, 2019, 94: 105423.
- [12] 曹惠玲,崔科璐,梁佳旺.基于多参数融合相似的民航发动机寿命预测[J].中国机械工程,2020,31(7):781-787.
- [13] 梁伟阁,张钢,王健,等.复杂机械设备健康状态预测方法研究综述[J].兵器装备工程学报,2022,43(7):67-77.
- [14] 崔晓飞,蒋科艺,王永华.基于贝叶斯信息融合的航空发动机健康状态评估方法研究[J].燃气涡轮试验与研究,2009,22(4):39-42.
- [15] 胡金海,谢寿生,骆广琦,等.基于支持向量机方法的发动机性能趋势预测[J].推进技术,2005,26(3):260-264.
- [16] MALHOTRA P, TV V, RAMAKRISHNAN A, et al. Multi-sensor prognostics using an unsupervised health index based on LSTM encoder-decoder[C/OL]//Proceedings of 1st ACM SIGKDD Workshop on Machine Learning for Prognostics and Health Management. (2016-08-22)[2024-10-12]. <https://arxiv.org/abs/1608.06154>.
- [17] LIU K B, GEBRAEEL N Z, SHI J J. A data-level fusion model for developing composite health indices for degradation modeling and prognostic analysis[J]. IEEE Transactions on Automation Science and Engineering, 2013, 10(3):652-664.
- [18] 严淑芹,王伟.基于机器学习的FDR MoC6试验数据分析方法[J].民用飞机设计与研究,2023(4):14-21.
- [19] 杨潇谊,吴建德,马军.基于散布熵和余弦欧氏距离的滚动轴承性能退化评估方法[J].电子测量与仪器学报,2020,34(7):15-24.
- [20] 杨锡运,吕徽,王灿,等.基于滑动窗口-KL散度和改进堆叠自编码的轴承故障诊断[J].机床与液压,2021,49(17):179-184.
- [21] 王彦岩,文冠华,佘庆涛,等.柴油发动机空气系统健康评估方法:CN 114856811B[P].2023-04-07.
- [22] 杨宁,魏伟,胡航语,等.基于图神经网络的高温树脂材料预测模型[J].功能高分子学报,2021,34(6):54-56.
- [23] 文冠华.柴油机空气系统健康状态评估和预测[D].威海:哈尔滨工业大学,2022.

(下转第33页)

cranes and improve energy efficiency, considering the cost of power batteries and the irreplaceable typical advantages of diesel engines in safety and reliability, a hybrid power scheme for offshore platform cranes is proposed, which monitored the state of charge (SOC) of batteries and the dynamic load of the crane, the collaborative control strategy is designed, and the simulation verification under the typical working conditions of the crane is carried out. The results show that the fuel consumption and CO<sub>2</sub> emission of the heavy duty diesel engine driven by the diesel engine-lithium battery hybrid system are significantly reduced. After 8 h typical operation cycle, the fuel consumption of the traditional diesel engine crane and the hybrid crane are 141.0 kg and 120.2 kg, with the CO<sub>2</sub> emissions are 435.7 kg and 371.3 kg, respectively, both the fuel consumption and CO<sub>2</sub> emissions are reduced by 14.8%.

**Keywords:** offshore platform crane; hybrid power system; energy management; energy conservation and emission reduction

(责任编辑:刘丽君)

(上接第20页)

## Health status assessment and prediction method for a diesel engine air system based on time series

WANG Yongkang, WEN Guanhua, WANG Yanyan<sup>\*</sup>, SHEN Zhaojie, MA Conggan,  
JI Zhaoqi, LIN Bo, SHAO Luming

School of Automotive Engineering, Harbin Institute of Technology (Weihai), Weihai 264200, China

**Abstract:** To address the challenge of health status assessment for diesel engine air systems, when considering their complex structure, high fault frequency, insufficient full-life-cycle data, and difficulties in accurate fault characterization, and to provide support for predictive maintenance, a time-series-based health status assessment method for diesel engines is proposed. Initial health indicators are constructed according to the health status of the air system per unit time. An autoencoder model is adopted to perform feature weighting optimization on the initial indicators for improved characterization accuracy. Combined with the sliding window method, time-series analysis is applied to smooth historical health status data. Finally, a long short-term memory (LSTM) network is established to predict the health status of the diesel engine air system. The results demonstrate that the designed time-series-based assessment method is effective with high prediction accuracy. The mean squared error (MSE) between the predicted and measured results of health status is  $2.11 \times 10^{-5}$ , the root mean squared error (RMSE) is 0.004 6, and the mean absolute error (MAE) is 0.003 1. This method can provide reliable support for the predictive maintenance of diesel engine air systems.

**Keywords:** diesel engine; health status assessment; health status prediction; LSTM network

(责任编辑:刘丽君)