

引用格式:孙佳文,任鸿翔,杨晓,等. 基于多模态信息融合的船用柴油机数字孪生故障预警方法[J]. 大连海事大学学报,2026,52(1):65-78.

基于多模态信息融合的船用柴油机数字孪生故障预警方法

孙佳文¹,任鸿翔^{*1},杨晓¹,王德龙¹,潘明阳¹,韦德鉴²

(1.大连海事大学 航海学院,辽宁 大连 116026;2.平陆运河集团有限公司,南宁 530000)

摘要:为实现船用柴油机运行状态的精准感知与故障有效预警,提出一种融合机理仿真与传感实测信息的多模态数字孪生方法。该方法通过引入性能退化校正机制构建高保真柴油机热力学仿真模型,设计融合多尺度卷积与注意力机制的特征提取网络,完成两类互补信息的深层特征提取与跨模态融合;以偏差度为预警指标,结合核密度估计实现性能参数阈值自学习,构建具备动态适应能力的故障预警机制。结合9L34DF型双燃料船用柴油机的运行数据,验证了该方法在实际工况下的有效性与适用性。

关键词:船用柴油机;多模态信息融合;性能预测;故障预警;数字孪生

中图分类号:U664.121

文献标志码:A

文章编号:1006-7736(2026)01-0065-14

doi:10.16411/j.cnki.issn1006-7736.2026.01.007

A digital twin-based fault early warning method for marine diesel engines based on multimodal information fusion

SUN Jiawen¹,REN Hongxiang^{*1},YANG Xiao¹,
WANG Delong¹,PAN Mingyang¹,WEI Dejian²

(1.Navigation College, Dalian Maritime University, Dalian 116026, China;

2.Pinglu Canal Group Co., Ltd., Nanning 530000, China)

Abstract:To achieve accurate perception of the operational status and effective fault early warning of marine diesel engines, a multimodal digital twin method integrating mechanism simulation and sensor measurement information was proposed. This method introduced a performance degradation correction mechanism to construct a high-fidelity thermodynamic

simulation model of diesel engines, designed a feature extraction network integrating multi-scale convolution and attention mechanisms, and accomplished deep feature extraction and cross-modal fusion of the two types of complementary information. Taking the deviation degree as the early warning index, the self-learning of performance parameter thresholds was realized combined with kernel density estimation, and a fault early warning mechanism with dynamic adaptability was constructed. The effectiveness and applicability of the proposed method under actual operating conditions were verified based on the operational data of the 9L34DF dual-fuel marine diesel engine.

Key words:marine diesel engine; multimodal information fusion; performance prediction; fault early warning; digital twin

0 引言

智能船舶的发展对船舶动力系统的可靠性提出了更高的要求。作为船舶推进系统的核心装置,船用柴油机长期运行于高温、高压环境,易出现结垢、腐蚀、磨损及部件损坏等性能退化现象与故障问题^[1]。尽管多数船用柴油机在运行过程中已配备在线监测系统,以保障其安全可靠运行,但该类系统多基于固定阈值开展异常预警,在工况变化时适应性较差,易造成潜在故障早期识别的缺失。一旦早期异常进一步发展为严重的系统故障,往往会带来较大的经济损失与安全风险。因此,实现对性能异常的准确、及时预警,以此提升

收稿日期:2025-07-23;修回日期:2025-12-03

基金项目:广西科技重大专项(桂科 AA23062053);广西重点研发计划项目(桂科 AB22080106)

作者简介:孙佳文(1995—),男,博士生;任鸿翔^{*}(1974—),男,博士,教授,博士生导师,E-mail:dmu_rhx@dlmu.edu.cn

船用柴油机的运行可用性,对于降低海上故障风险、减少停机损失具有重要意义。

针对船用柴油机的性能预测与故障预警问题,现有研究方法主要分为机理建模法和数据驱动法两类^[2]。其中,机理建模法以设备的内部运行机理为先验知识,通过构建的物理模型对系统运行状态进行描述与分析^[3]。Wang 等^[4]基于 MATLAB/Simulink 构建了二冲程低速船用柴油机的物理模型,通过模拟多种典型故障工况,辅助船舶推进系统完成故障识别与健康状态评估。得益于模块化仿真策略,该类模型通常具有较好的可解释性^[5]。然而,该类方法的预测准确性在很大程度上依赖于模型本身的精度,当系统结构复杂或边界条件不明时,关键特征的选取和原理的确定将面临较大困难。此外,随着柴油机服役时间的增加,各部件普遍会出现不同程度的性能退化,导致模型难以持续精准地反映其运行状态。因此,模型与实际系统之间的动态失配问题,仍是当前机理建模法面临的关键挑战之一。

随着先进数据采集技术在船舶机械上的普及与应用,数据驱动法在故障检测、异常识别及剩余使用寿命预测等领域得到了广泛研究与应用^[6-7]。该方法具有提取代表性特征与数据挖掘的潜力,且仅依赖系统历史数据,因此在实际工程中具有良好的适用性。王新全等^[8]提出一种融合遗传算法与 BP 神经网络的船用柴油机排气温度预测方法,通过优化模型结构提升了预测精度,验证了数据驱动方法在复杂工况下的有效性。宫文峰等^[9]采用改进的卷积神经网络(CNN)实现了对船舶机械微小故障的快速识别,提升了数据驱动法在弱故障诊断场景下的适应性与准确性。然而,数据驱动法在实际应用中仍存在两方面显著局限性:其一,该方法缺乏对物理机制的挖掘与解析能力,难以从物理层面阐释模型的内部运行机制;其二,受实测数据不平衡、不完整等问题的制约,高质量训练样本的获取面临较大困难,且噪声与冗余信息会对模型泛化性能产生显著干扰。这些局限性在一定程度上制约了该方法的应用效果与可靠性。

为弥补数据驱动法在机理表达与泛化性能方面的不足,数字孪生(DT)作为一种虚实结合的建模理念,近年来被广泛引入复杂装备的状态监测与故障诊断研究中^[10]。数字孪生通过构建与物

理系统对应的高保真虚拟模型,实现物理实体与虚拟空间的动态映射与信息交互,进而在模型精度、可解释性与实时性之间达成平衡^[11]。在船舶动力系统智能运维方面,周宏根等^[12]提出一种面向船用柴油机的整机性能评估方法,基于数字孪生融合多源信息,实现了对运行状态的量化评估。景乾峰等^[13]设计了融合虚拟现实技术的船舶数字孪生框架,完成了多源异构信息的可视化集成,为运维管理提供了智能化支撑。近年来,数字孪生相关研究在模型构建与方法创新方面取得了进一步进展。Hautala 等^[14]以船用中速柴油机为对象,提出一种基于机理建模的控制导向型数字孪生模型,并探索了其在实时仿真与控制应用中的可行性。在此基础上,Jeon 等^[15]利用实测数据对机理模型进行校正,构建了具备可信度保障的数字孪生模型,并应用于柴油机故障识别。Xu 等^[16]提出一种基于预处理融合策略的数字孪生模型,将机理模型与数据驱动的 NARX 网络结合,用于发动机性能参数预测。总体来看,现有研究在数字孪生模型的构建与融合方面已取得显著进展,但在实现高精度传感数据与物理实体的运行机理之间深度有效融合,且同时考虑设备性能退化的影响方面,仍有待进一步研究。

多模态学习旨在实现异构信息的联合表达与协同利用^[17]。在数字孪生建模过程中,机理仿真结果反映系统的物理规律,实测传感数据则描述其实际运行特性;二者在生成机制、特征分布与信息维度上存在差异,构成了信息模态的互补关系。通过跨模态特征融合,可在虚实空间之间建立一致关联,从而提升模型在不同工况条件下的适应性与可靠性。

基于上述研究背景,本文提出一种面向船用柴油机的多模态信息融合数字孪生方法。该方法以跨模态特征融合为核心,融合机理仿真与实测传感多源信息,实现虚实数据的协同互补利用;并在此基础上结合偏差度建模与核密度估计方法,完成对关键性能参数的异常检测与预警验证,为船用柴油机的智能运维提供一种可行的思路。

1 数字孪生建模与方法概述

1.1 船用柴油机机理建模与自适应退化校正

本文以某台装配于 LNG 船的瓦锡兰 9L34DF

双燃料中速增压柴油机为原型开展仿真建模。该机型为船舶电力推进系统的发电原动机组,其主要技术参数见表 1。

表 1 瓦锡兰 9L34DF 双燃料柴油机主要参数
Tab.1 Main specifications of Wärtsilä 9L34DF dual-fuel diesel engine

技术参数	规格
气缸数	直列 9 缸
冲程	四冲程
功率/kW	4050
转速/(r·min ⁻¹)	750
缸径/mm	340
活塞行程/mm	400
各缸点火顺序	1-7-4-2-8-6-3-9-5

如图 1 所示,船用柴油机机理模型基于 GT-SUITE 软件的标准元件库搭建。其中,发动机气缸(CYL)内的传热过程与燃烧过程分别采用 Woschni 方程和 Wiebe 函数进行表征,进排气管路的气体流动特性则通过一维仿真方法模拟;涡轮增压器(TC)由压气机与涡轮构成,二者分别布置于环境与空气冷却器(CAC)的连接管路、排气管与排气出口的连接管路中。各组件端口按照流量平衡原理及理想气体状态方程进行链接,实现所有部件的串联耦合建模^[18]。




图 1 基于 GT-SUITE 构建的船用柴油机仿真模型

Fig.1 Marine engine simulation model built by GT-SUITE

船用柴油机部件在长期服役过程中性能退化难以避免,这导致关键参数逐渐偏离基准值,从而降低了机理模型的准确性^[19]。与传统参数辨识方法相比,基于传感器数据的状态估计与修正方法更能适应船舶发动机的复杂工况与缓慢退化特性。为此,本文设计一种融合传感器监测数据与先验模型信息的性能退化自适应校正模块,如图 2 所示。该模块采用 Kullback-Leibler(KL)散度计算柴油机部件性能参数在不同时间段的分布差异。针对某一典型工况 c ,不同时刻参数的特征分布分别记为 $P_c^{(i)}$ 和 $P_c^{(j)}$,二者间的 KL 散度可表示为:

$$D_{KL}(P_c^{(i)} \parallel P_c^{(j)}) = \sum_{x \in X} P_c^{(i)}(x) \ln \frac{P_c^{(i)}(x)}{P_c^{(j)}(x)} \quad (1)$$

该过程经多次迭代计算后,生成可表征柴油机部件状态变化趋势的 KL-D 向量。随后,将 KL-D 向量与当前时刻柴油机的状态信号 S_{real} 共同作为输入,通过 MLP 模型预测各部件的健康因子集合 HI_s 。该过程可以表示为:

$$HI_s = \mathcal{F}_\theta(S_{real}, D_{KL}) \quad (2)$$

式中: $HI_s \in \mathbb{R}^n$, 表示预测得到的 n 个健康指标,每个对应机理模型中的一个关键部件; \mathcal{F}_θ 表示参数为 θ 的 MLP 模型。 HI_s 不仅具备良好的退化趋势敏感性,还具有一定的物理可解释性。最后,根据预测得到的 HI_s 对机理模型中关键部件的建模参数进行修正,以保证模型的长期预测准确性。校正后的机理模型为数字孪生建模与后续的柴油机性能预测奠定了可靠的物理基础。

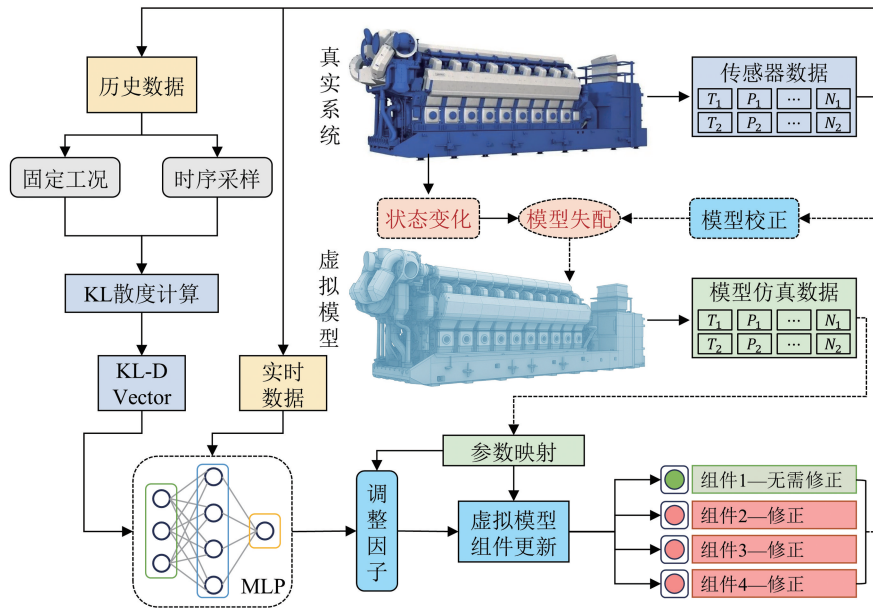


图 2 针对性能退化的机理模型自适应校正模块

Fig.2 Adaptive correction module for performance degradation mechanism model

1.2 注意力增强的多尺度特征融合

针对船用柴油机多通道信号的有效特征提取对实现精准的故障预警具有重要意义。为解决传统 CNN 结构因依赖单尺度卷积核、难以捕获完整特征表征的局限性,本文提出一种注意力增强的多尺度特征融合网络(图 3),以提升数据驱动模型对关键特征的提取性能。该网络包括三个核心模块:首先,通过多尺度卷积核并行提取不同感受野下的特征信息,增强模型对局部与全局模式的感知能力;其次,构建跨层特征融合机制,有效缓解深层网络中潜在的信息损失问题,提升特征表征的完整性;最后,引入基于改进通道注意力机制的特征增强模块,在特征融合结果的基础上进一步建模通道间的依赖关系,并抑制冗余干扰特征的影响。该模型为数字孪生的虚实信息融合及后续故障预警任务提供可靠的数据支撑。

1.2.1 多尺度特征提取与跨层融合

针对船用柴油机的多变量时序数据,经初始卷积处理后,将输入样本依次送入三个堆叠的多尺度卷积模块,以逐步提取并重构其潜在特征。在每个特征提取模块中,采用多个不同尺寸的卷积内核 ($w_1 \neq w_2 \neq w_3$) 来捕捉不同感受野下的故障特征,并对多尺度特征进行融合。这种融合不仅增强了不同尺度卷积之间的共享特征表达,还有效保留了各尺度卷积核提取的差异性信息,

进而提升了模型的准确性与鲁棒性^[20]。上述过程可以表示为:

$$X_{\text{init}} = \text{InitConv}(X) \quad (3)$$

$$X_{w_i}^{(l)} = f\left(W_{w_i}^{(l)} \cdot X_{\text{input}}^{(l)} + b_{w_i}^{(l)}\right) \quad (4)$$

$$h_f^{(l)} = X_{w=1}^{(l)} \oplus X_{w=3}^{(l)} \oplus X_{w=5}^{(l)} \quad (5)$$

式中: X 为初始输入的一维序列数据; X_{init} 为经初始卷积后的输出; $X_{w_i}^{(l)}$ 表示第 l 个多尺度卷积块中,卷积核大小为 w_i 时的输出,其中, $l \in \{1, 2, 3\}$, $X_{\text{input}}^{(1)} = X_{\text{init}}$,对于 $l > 1$,则为上一个多尺度融合块的输出; $f(\cdot)$ 为激活函数; $W_{w_i}^{(l)}$ 表示第 l 个多尺度卷积块中尺寸为 w_i 的卷积核,其输出通道数为64; $b_{w_i}^{(l)}$ 为对应偏置项; $h_f^{(l)}$ 为第 l 个多尺度卷积块中尺度融合后的输出; \oplus 为逐元素相加操作。

为进一步提升模型的特征表达能力,本文设计跨层拼接模块,用于融合不同网络层级的特征信息。不同层级的特征反映了特征从浅层到深层的逐步演化过程,融合多层信息有助于更准确地表征柴油机运行状态的微小变化。如图 3 所示,对多个多尺度特征提取模块的输出完成降维处理后,在通道维度上对其进行拼接,生成融合特征。跨层拼接融合后的输出表示为:

$$H_{\text{fusion}} = \text{Concat}\left(h_f^{(1)}, h_f^{(2)}, h_f^{(3)}\right) \quad (6)$$

式中: $\text{Concat}(\cdot)$ 表示横向拼接操作;通道数为 $32 \times 3 = 96$ 。

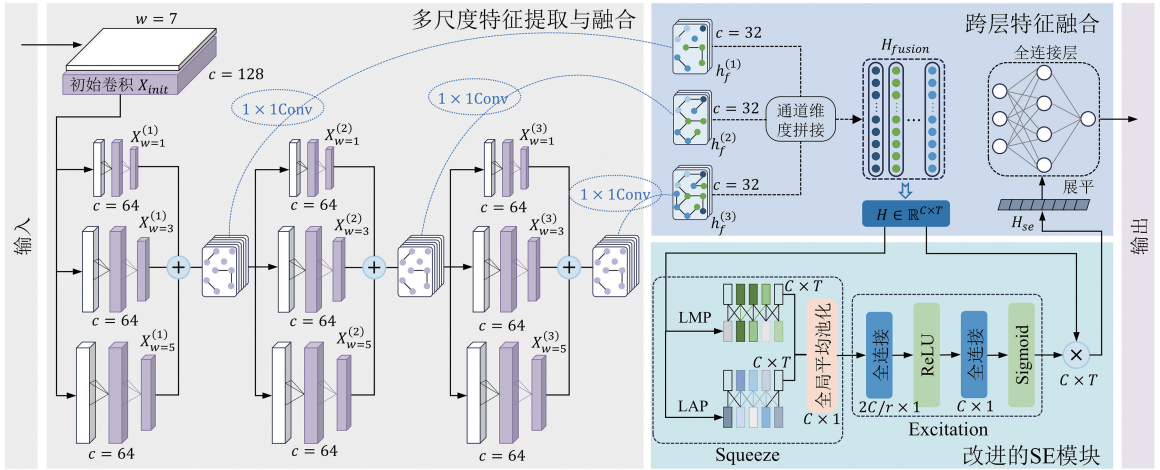


图 3 注意力增强的多尺度特征融合网络

Fig.3 Attention-enhanced multi-scale feature fusion network

1.2.2 基于改进通道注意力的特征增强

尽管多尺度特征提取模块作为骨干网络能够有效捕捉时序特征,但其输出通常为时间维度与通道维度信息的简单叠加,这种统一化的处理方式限制了其在复杂模式识别任务中的性能表现^[21]。在深度学习的特征建模过程中,Squeeze-and-Excitation(SE)模块凭借结构简单、特征增强效果显著的优势,被广泛嵌入各类神经网络中^[22]。然而,SE模块中的全局平均池化(GAP)操作虽在图像等静态场景下效果显著,但其直接应用于船用柴油机的性能预测任务时,存在适应性不足的问题。具体而言,传感器采集的原始数据常呈阶段性与非平稳变化特性^[23],此时全局压缩可能会掩盖时序信号中关键的局部波动特征,从而削弱模型对性能退化模式的感知能力。

为更好地适应数字孪生模型中对特征增强的需求,本文提出一种改进型SE模块。具体而言,在执行GAP操作前,先引入局部最大池化(LMP)操作以提取特征图中各局部区域的极大值,该信息通常可反映时间域或空间域内的重要特征。为进一步抑制噪声干扰,同时引入局部平均池化(LAP)操作,通过对各局部区域内的特征值求取均值,得到更具稳定性的局部特征表征。随后,按照通道维度对上述两种池化结果进行结构化融合,既保留了原始信号中的关键峰值信息,也融入了由平均池化所提供的稳健局部特征,进而实现了更加丰富、全面的特征表征。最后,将融合结果

经GAP操作进一步压缩,实现特征降维并降低计算复杂度,提升模型对全局模式的感知能力。

改进的SE模块结构如图3所示。对于输入特征 $H \in \mathbb{R}^{c \times T}$, 首先,在每个通道上分别进行LMP和LAP操作,其中,池化核大小为 k , 步长为 s , 得到两个压缩特征图:

$$H_{\text{smp}}(c, i) = \max_{t \in W_i} H(c, t) \quad (7)$$

$$H_{\text{sap}}(c, i) = \frac{1}{k} \sum_{t \in W_i} H(c, t) \quad (8)$$

式中: $c \in \{1, 2, \dots, C\}$; $t \in \{1, 2, \dots, T\}$; W_i 表示滑动窗口在时间维度上的第 i 个位置。

随后,对LMP和LAP的输出进行融合并执行GAP操作,将其进一步压缩为通道级向量:

$$z_{\text{smp}}(c) = \frac{1}{L} \sum_{i=1}^L H_{\text{smp}}(c, i) \quad (9)$$

$$z_{\text{sap}}(c) = \frac{1}{L} \sum_{i=1}^L H_{\text{sap}}(c, i) \quad (10)$$

式中: L 为经LMP和LAP操作后的时间步数,由输入长度 T 、窗口大小 k 、步长 s 决定。

最终,将两者拼接形成融合向量:

$$z = [z_{\text{smp}}, z_{\text{sap}}] \in \mathbb{R}^{2C} \quad (11)$$

融合向量 z 依次通过两个全连接层进行非线性变换,得到每个通道的注意力权重:

$$s = \sigma(W_2 \cdot \text{ReLU}(W_1 \cdot z)) \in \mathbb{R}^C \quad (12)$$

式中: $W_1 \in \mathbb{R}^{\frac{2C}{r} \times 2C}$; $W_2 \in \mathbb{R}^{C \times \frac{2C}{r}}$; r 为通道压缩比; $\sigma(\cdot)$ 为Sigmoid激活函数。将通道注意力权

重向量 \mathbf{s} 扩展至与原输入特征相同的形状, 并与 H 进行逐通道相乘, 实现通道级重标定, 进而得到最终的输出特征 H_{se} 。

$$H_{se}(c, t) = \mathbf{s}(c) \cdot H(c, t) \quad (13)$$

改进的 SE 模块通过引入局部池化操作, 强化了通道对局部显著特征的感知能力, 有助于提升融合阶段对关键信息的保留效果。

1.3 基于偏差度建模的故障预警

为解决传统方法中固定阈值易引发误报、漏报的问题, 本文基于数字孪生模型预测值与传感器实测值的偏差, 构建偏差度指标作为预警特征, 并采用核密度估计方法实现阈值的自适应学习。该方法的具体流程如算法 1 所示。

算法 1: 偏差度驱动的故障预警方法

输入: 传感器实测序列 $P_{mea}(t)$, 模型预测序列 $P_{pre}(t)$, 健康数

据集 D_{health} , 置信水平 $1-\alpha$, 连续超阈值次数 K

输出: 故障预警状态指示量 S_w

方法:

1: for 每个关键监测参数 p do

2: 从 D_{health} 中提取样本序列

3: 计算偏差度:

$$r_p(t) = \frac{|P_{mea,p}(t) - P_{pre,p}(t)|}{(P_{p,max} - P_{p,min})/2} \times 100\%$$

4: 基于高斯核函数建立核密度估计模型:

$$f_p(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - r_{p,i}}{h}\right)$$

5: 根据置信水平 $1-\alpha$, 计算偏差度阈值 r_p^* , 满足:

$$P(r_p \leq r_p^*) = 1 - \alpha$$

6: end for

7: 初始化 $S_w = 0$, 并令每个参数的连续计数 $c_p = 0$

8: for 每一时间点 t do

9: for 每个参数 p do

10: 计算实时偏差度 $r_p(t)$

11: if $r_p(t) > r_p^*$ then

12: $c_p \leftarrow c_p + 1$

13: else

14: $c_p \leftarrow 0$

15: end if

16: end for

17: if 存在任一参数, 满足 $c_p > K$ then

18: $S_w = 1$ (触发异常预警)

19: else

20: $S_w = 0$ (系统正常)

21: end if

22: end for

23: return S_w

首先, 对于船用柴油机每一个关键监测参数, 定义其实测值 $P_{mea}(t)$ 与模型预测值 $P_{pre}(t)$ 在时间点 t 的归一化偏差度 $r(t)$:

$$r(t) = \frac{|P_{mea}(t) - P_{pre}(t)|}{(P_{max} - P_{min})/2} \times 100\% \quad (14)$$

式中: P_{max} 和 P_{min} 分别为该参数在当前或相似运行工况下模型预测值的最大值与最小值, 可通过对正常状态下的大量预测结果进行统计得到。偏差度 $r(t)$ 用于量化实测值相对正常状态的偏离程度, 其数值越大, 表明该参数偏离正常状态的程度越高。

其次, 为有效进行故障预警, 基于核密度估计的自学习方法对偏差度阈值进行建模。在健康状态数据中, 假设偏差度样本为 $\{r_1, r_2, \dots, r_n\}$, 其核密度估计函数可表示为:

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - r_i}{h}\right) \quad (15)$$

式中: $K(\cdot)$ 为核函数, 需满足概率密度函数的性质。本文选择高斯核函数, 其表达式如下:

$$K(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \quad (16)$$

在核密度估计中, 带宽 h 的选取对估计结果的平滑性具有决定性作用。本文采用 Silverman 经验法则计算初始带宽, 其计算公式如下:

$$h_0 = 0.9 \min\left(\hat{\sigma}, \frac{IQR}{1.34}\right) n^{-1/5} \quad (17)$$

式中: $\hat{\sigma}$ 、IQR 分别为健康样本偏差度的标准差与四分位距; n 为样本数。为避免过度平滑或欠平滑, 最终带宽限定在 $[0.8h_0, 1.2h_0]$ 范围内, 并对每个关键参数分别进行估计。

在获得估计密度函数后, 根据设定的置信水平 $1 - \alpha$, 得到对应的偏差度阈值 r^* , 其表达式为:

$$P(r \leq r^*) = 1 - \alpha \quad (18)$$

式中: $P(x)$ 为样本落在该区间内的概率; r^* 为在置信水平 $1 - \alpha$ 时的边界值, 即报警阈值。

最后, 在柴油机运行过程中, 根据传感器实测数据与数字孪生模型提供的健康预测值, 通过式 (14) 计算各监测参数的偏差度 r , 并将其与基于核密度估计方法得到的阈值 r^* 进行对比。当监

测数据与模型预测值的偏差度持续超出设定阈值时,即可判定对应监测参数存在异常趋势,进而触发异常预警。

1.4 基于多模态信息融合的数字孪生预警框架

为实现船用柴油机运行状态的准确感知,本文构建了基于多模态信息融合的数字孪生预警方法,其整体框架如图 4 所示。首先,基于 GT-SUITE 平台建立船用柴油机机理模型,并利用 KL 散度方法实现性能退化的自适应校正,旨在为后

续数字孪生建模提供可靠的物理基准数据。其次,设计一种注意力增强的多尺度卷积网络,从机理仿真与实测传感两类信息中提取特征,并在统一高维空间进行跨模态融合,以增强对关键特征的提取与表征能力。最后,以融合后的预测输出为基准,计算各参数的偏差度,并利用核密度估计来学习并确定异常偏差阈值,进而实现对船用柴油机运行状态的准确感知与故障的有效预警。

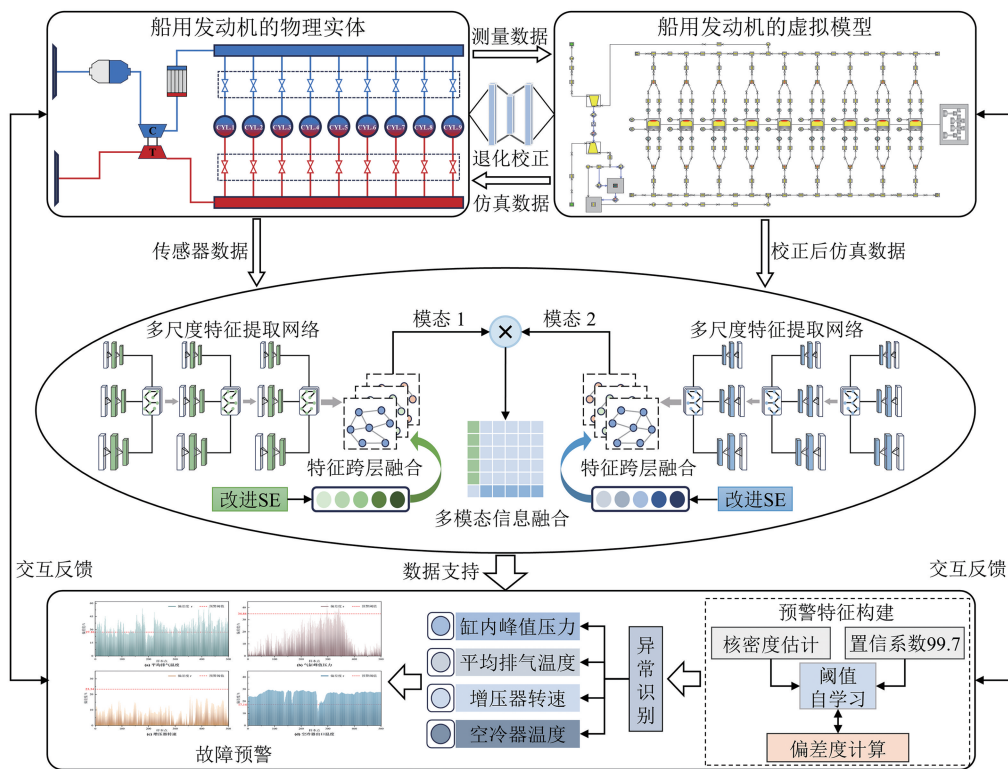


图 4 基于多模态信息融合的数字孪生预警框架

Fig.4 Multimodal information fusion-based digital twin warning framework

2 实验

2.1 实验数据与预处理

为验证所提方法的预测精度与预警有效性,本文基于离线数据集开展实验研究,选取若干关键性能参数作为模型的输入与预测对象。这些参数涵盖了柴油机重要部件的局部状态信息(如温度与压力),以及反映整机运行特性的全局性能指标,具体参数见表 2。实测数据由传感器以 1 Hz 的采样频率获取,即每秒采集一次完整的状态信息。仿真数据则由基于 GT-SUITE 平台构建的高保真机理模型生成,其仿真步长设置为 0.01 s。

表 2 柴油机关键性能参数及其定义

Tab.2 Key performance parameters of diesel engines and their definitions

参数符号	定义	参数符号	定义
P_e	有效功率	p_m	气缸峰值压力
p_{bme}	平均有效压力	t_{ac}	平均排气温度
N_{tc}	增压器转速	t_{cac}	空冷器出口温度
t_{to}	涡轮出口温度	p_{cac}	空冷器出口压力

为确保模型输入数据的质量,对原始传感器数据进行降噪处理。本文采用软硬阈值折中的小波去噪方法,选取 5 层小波分解,并选用 sym8 小波基函数对各项特征数据进行滤波处理,进而在

保留关键信息的同时有效抑制噪声干扰。

此外,为避免不同特征的量纲差异对模型训练造成干扰,本文对两个模态的数据分别进行标准化处理。采用 Min-Max 归一化方法将数据线性映射至 $[0, 1]$ 区间,其计算公式如下:


$$x'_i = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (19)$$

式中: x_i 、 x'_i 分别为归一化前、后的数据值; $x_{i,\max}$ 、 $x_{i,\min}$ 分别为该特征在样本数据中的最大值、最小值。

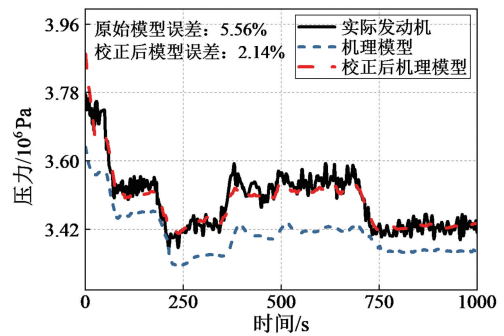
2.2 性能退化自适应校正验证

本节旨在验证所提出的自适应退化校正模块对提升仿真模型精度的有效性。该模型依据一维气体动力学与热力学原理构建。为实现对运行状态退化过程的动态建模,校正模块以 KL 散度衡量仿真输出与传感器实测数据之间的分布差异,并据此动态调整机理模型关键参数,实现对性能变化的自适应跟踪与修正。


图 5 为模型校正前后关键参数的仿真结果对比。由图 5 可知,经自适应退化校正后,模型的整体仿真误差显著降低,尤其是气缸峰值压力 (p_m) (图 5(b)),其平均绝对百分比误差 (MAPE) 由 5.56% 降至 2.14%。此外,在典型运行工况下,校正后模型的增压器转速 (N_{tc})、空冷器出口温度 (t_{cac})、平均排气温度 (t_{ae}) MAPE 分别降低 21.76%、35.59% 和 54.36%。



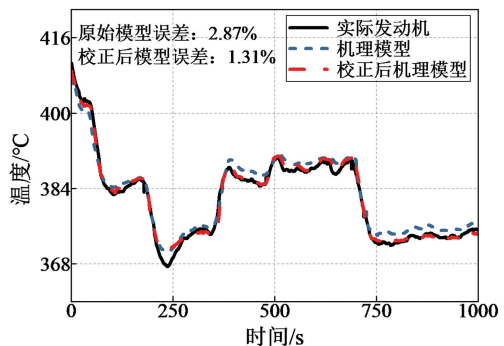
(a) 增压器转速



(b) 气缸峰值压力



(c) 空冷器出口温度



(d) 平均排气温度

图 5 模型校正前后关键参数的仿真结果对比
Fig.5 Comparison of simulation results of key parameters before and after model calibration

表 3 为校正后模型在发动机不同负载下,模拟值与测量值的对比。由表 3 可知,在所有负载工况下,各参数平均值的相对误差均控制在 4% 以内,表明校正后的机理模型能够满足工程要求的精度模拟实际发动机的运行特性。上述结果表明,本文提出的自适应退化校正模块有效降低了船用柴油机部件长期运行过程中因状态变化引起的系统性误差,为数字孪生建模过程中的多模态信息融合提供了可靠的物理基准。

表 3 发动机不同负载下模拟值与测量值的对比

Tab.3 Comparison of simulated and measured values of the engine under different loads


负载/%	测量值/ 模拟值	p_{bme} /Pa	P_e /kW	TC		CYL		CAC	
				N_{tc} /(r·min ⁻¹)	t_{to} /°C	p_m /Pa	t_{ae} /°C	t_{cac} /°C	p_{cac} /Pa
100	测量值	1 996 000	4050.00	21 300	412	11 290 000	531	46	184 000
	模拟值	2 015 000	4059.42	21 556	408.62	11 437 000	530.54	46.70	187 000
	误差/%	0.95	0.23	1.20	-0.82	1.30	-0.09	1.52	1.63
75	测量值	1 685 000	3038.00	17 770	402	10 034 000	528	42	173 000
	模拟值	1 744 000	3080.53	18 053	396.73	9 863 000	531.22	42.51	177 000
	误差/%	3.50	1.40	1.59	-1.31	-1.70	0.61	1.21	2.31
50	测量值	1 213 000	2025.00	15 070	385	8 410 000	501	38	119 000
	模拟值	1 242 000	2066.53	15 326	390.62	8 243 000	505.50	37.63	123 000
	误差/%	2.39	2.05	1.70	1.46	-2.14	0.90	-0.97	3.36
25	测量值	557 000	1013.00	10 590	343	5 073 000	412	29	58 000
	模拟值	575 000	1042.07	10 420	352.23	4 969 000	416.70	28.70	60 000
	误差/%	3.23	2.87	-1.61	2.69	-2.05	1.14	-1.03	3.45

2.3 多模态融合的预测性能对比分析


完成虚实一致性校正后,进一步比较基于单一模态与多模态融合方法在关键性能参数趋势预测中的表现。以平均排气温度为预测目标,结合 MAE、RMSE、MAPE 及 95% 置信区间等指标,对预测结果进行定量对比分析。其中,基于单一模态的方法采用本文提出的注意力增强多尺度卷积网络,模型输入仅包括不同负载工况下采集的传感器实测数据,包括 N_{tc} 、 t_{to} 、 p_m ; 多模态融合方法在此基础上,进一步引入 t_{ae} 的仿真数据,与传感器实测数据联合输入模型以实现信息融合。同时,本文考虑了传感器测量的不确定性,为机理模型的仿真数据加入噪声注入处理,使其更贴合实际工况。在保持两种模型结构一致的前提下,每个工况的实验数据集包含 5000 个样本,时间窗长度设为 10,训练集与测试集按照 7:3 的比例划分。

图 6(a) 为多模态与单模态方法在船用柴油机低负载工况下,对平均排气温度的预测值与实测值的对比。整体趋势表明,多模态融合方法具有更强的拟合能力和更高的预测精度。图 6(b) 为两种方法的误差值变化。结果表明,单一模态方法的误差波动幅度较大,多模态融合方法的预测误差始终稳定在 ± 1 °C 范围内,表现出更好的稳定性。

为验证基于多模态信息融合的数字孪生模型的跨工况预测性能,本文进一步对比了两种方法在不同负载工况下的预测效果。图 7 为两种方法在 10%~15%、20%~40% 和 60%~65% 三种典型



(a) 预测结果对比



(b) 误差值对比

图 6 多模态与单模态方法在平均排气温度预测中的对比
Fig.6 Comparison of multimodal and unimodal methods in the prediction of average exhaust temperature

负载工况下,多个性能指标的对比。由图 7 可知,多模态融合方法在所有负载工况下均优于单一模态方法,表现为更低的误差和更高的稳定性,尤其在 20%~40% 负载工况下,多模态信息融合的数字孪生模型具有明显优势,验证了其在不同负载工况下的稳健性和跨工况的泛化能力。

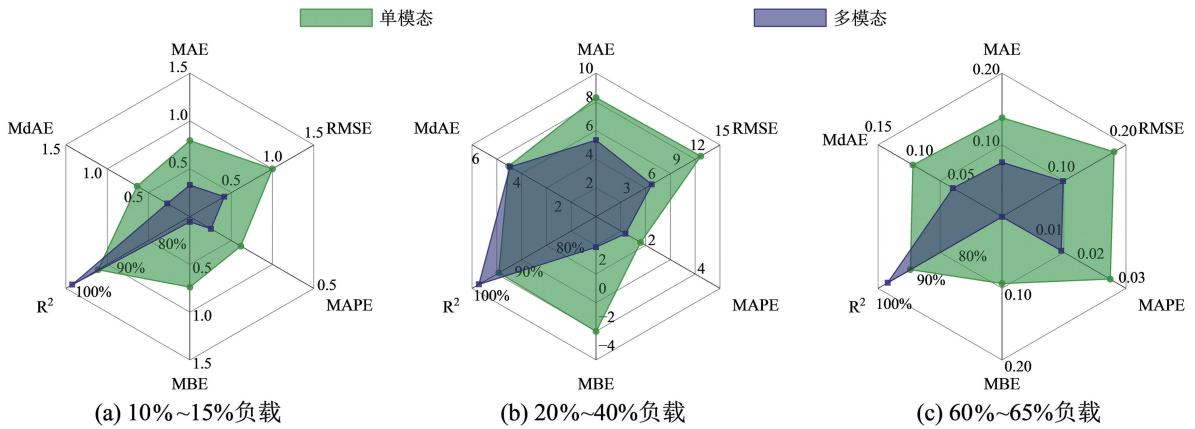


图 7 不同负载工况下, 单模态与多模态方法预测性能的对比

Fig.7 Comparison of prediction performance between unimodal and multimodal methods under different loads

表 4 为不同负载工况下, MAE、RMSE 和 MAPE 指标的均值及 95% 置信区间的统计结果。其中, 在 10%~15% 负载条件下, 多模态融合方法的 MAE 为 0.330, 相比基于单一模态的 0.794, 误差减少了 0.464。在 20%~40% 负载条件下, 差异更为明显, MAE 差值为 2.975, RMSE 差值为 5.916。高负载工况下, 二者预测结果的差异虽较

小, 但多模态融合方法仍表现更优。

上述结果表明, 融合仿真数据与实测数据所构建的多模态数字孪生模型在性能参数预测中具有显著优势, 且在不同负载工况下均表现出良好的跨工况泛化能力, 为后续的故障预警与状态评估提供了可靠的数据基础。

表 4 不同负载工况下, MAE、RMSE 和 MAPE 的均值及 95% 置信区间统计结果

Tab.4 Mean values and 95% confidence intervals of MAE, RMSE, and MAPE under different loads

负载/%	误差指标	单模态		多模态		差值 Δ
		均值	±95% CI	均值	±95% CI	
10~15	MAE	0.794	0.778~0.810	0.330	0.322~0.338	↓0.464
	RMSE	0.999	0.985~1.013	0.417	0.408~0.428	↓0.582
	MAPE	0.205	0.201~0.209	0.085	0.083~0.087	↓0.120
20~40	MAE	8.300	7.945~8.667	5.325	5.215~5.443	↓2.975
	RMSE	12.658	12.158~13.142	6.742	6.620~6.864	↓5.916
	MAPE	1.797	1.726~1.870	1.188	1.163~1.214	↓0.609
60~65	MAE	0.138	0.135~0.141	0.076	0.074~0.077	↓0.062
	RMSE	0.181	0.177~0.185	0.099	0.096~0.101	↓0.082
	MAPE	0.026	0.026~0.027	0.014	0.014~0.015	↓0.012

2.4 数字孪生驱动的故障预警方法验证

本节旨在验证所提方法在船用柴油机故障预警中的有效性, 并在多负载工况下进一步评估阈值判定的适用性与应用潜力。选取平均排气温度 (t_{ac})、气缸峰值压力 (p_m)、增压器转速 (N_{tc}) 与空冷器出口温度 (t_{cac}) 四个关键参数作为性能预警对象。基于正常工况下采集的传感器实测值与数字孪生模型的预测值来计算各参数的偏差度 r , 并利用核密度估计方法实现阈值的自适应学习。

为保证阈值建模的代表性与普适性, 本文在多个典型负载工况下选取健康数据作为建模样本, 结果如图 8 所示。选取的样本数据置信水平为 99.7%, t_{ac} 、 p_m 、 N_{tc} 和 t_{cac} 的阈值分别为 27.16%、34.84%、23.34% 和 17.14%。这些阈值能够有效区分参数的正常波动与异常偏离, 为故障预警提供了可靠的判定依据。

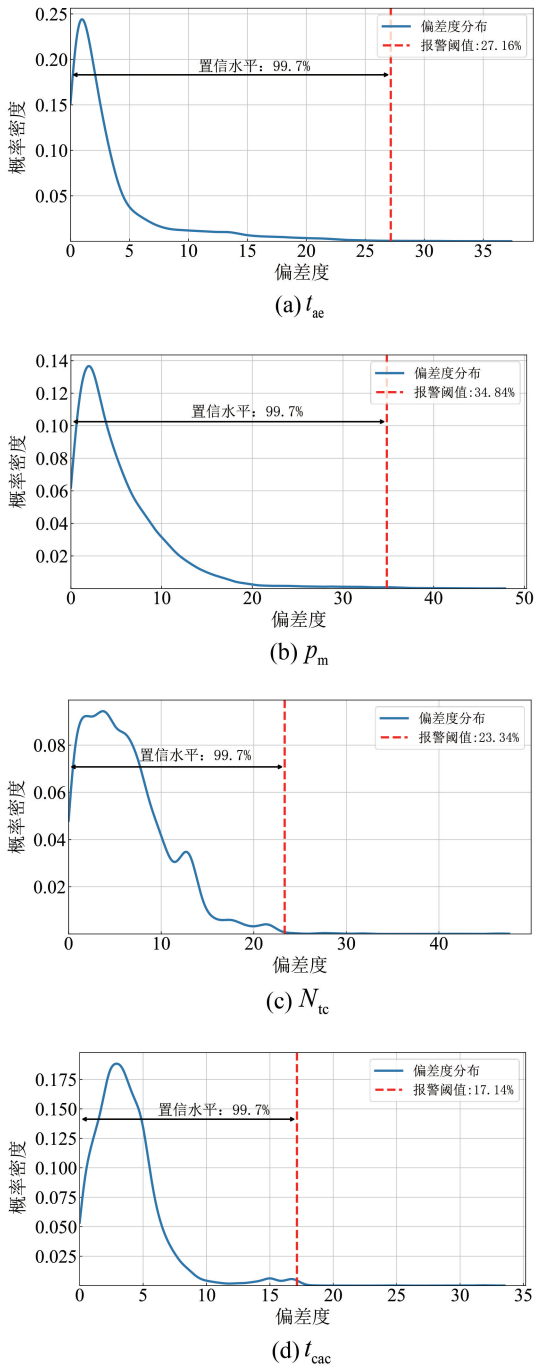


图 8 基于核密度估计的各参数偏差度阈值自学习结果
Fig.8 Self-learning of deviation degree thresholds for each parameter based on kernel density estimation

基于核密度估计确定的阈值,采集船用柴油机正常运行状态下的传感器数据,计算各参数的偏差度并与该阈值进行对比,分析结果如图 9 所示。由图 9 可知,所有参数的偏差度均稳定在各自的报警阈值内,因此,判断柴油机的性能状态正常,这与实际情况相符。这一结果表明,本文提出

的故障预警方法能够有效区分各参数在正常状态下的波动,避免故障误报的发生。

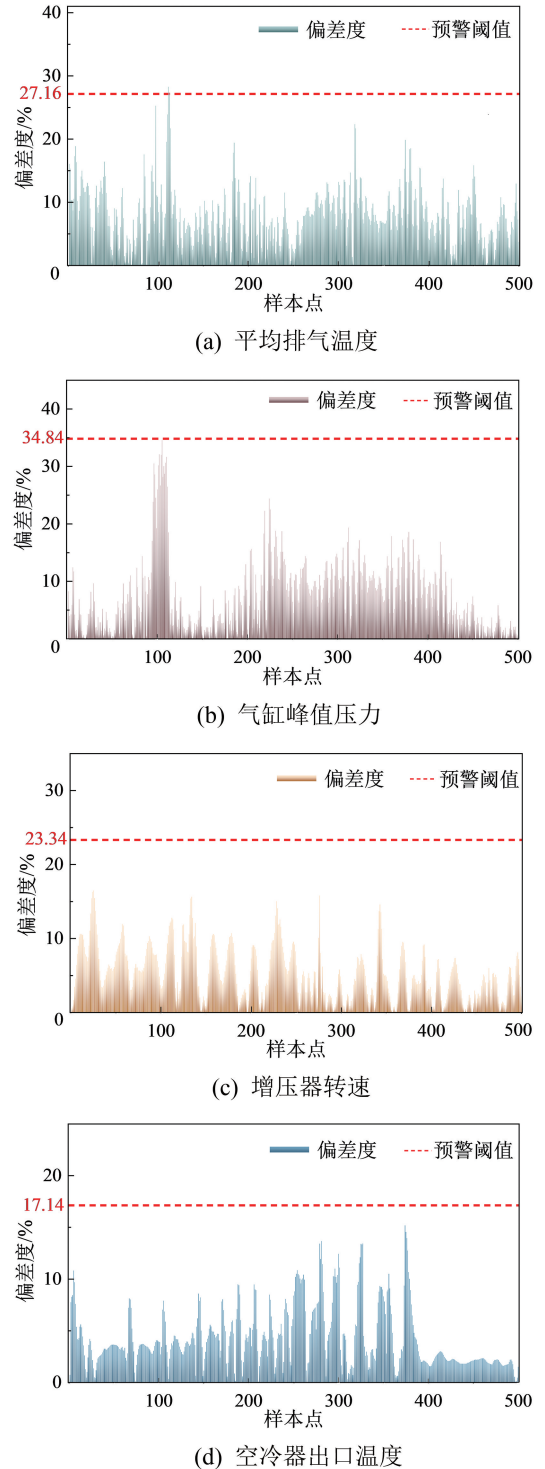



图 9 正常工况下各关键参数的偏差度分析结果
Fig.9 Deviation degree analysis of key parameters under normal conditions

受安全风险、隐私保护及运维成本等因素制约,真实故障数据的获取难度极大。为此,本文基

于前述校正后的机理模型模拟船用柴油机空冷器效率下降这一常见故障,以进一步验证所提故障预警方法在异常工况下的有效性^[24]。该方法在工程层面具备一定的合理性与可推广性:仿真模型已基于实测数据完成健康状态下的校准,能够较为准确地复现发动机的运行特性;且当故障未改变发动机基本的燃烧与传热机理时,在健康状态下构建的燃烧、传热及其他子模型仍然适用,由此保证基于该模型生成的故障数据与真实工况具有较高的一致性和物理可解释性^[16]。为此,本文通过调整机理模型中空冷器组件的传热效率进行故障设定。图 10 为空冷器效率下降故障工况下,各参数偏差度随样本点的变化趋势。由图 10



(d) 空冷器出口温度


图 10 空冷器效率下降故障下各参数的偏差度分析结果

Fig.10 Deviation degree analysis of parameters under charge air cooler efficiency degradation fault


可知,三项参数的偏差度均出现明显变化,其中,空冷器出口温度与平均排气温度的偏差度均超过各自的报警阈值,表现出显著的故障特征;气缸峰值压力的偏差度虽然有所增加,但总体仍低于报警阈值,表明该参数受该类故障的影响相对较小。

为进一步验证异常预警方法在不同运行条件下的适用性,本文将实验范围扩展至如图 11 所示的三类典型负载工况,并分别对船用柴油机四个关键性能参数的偏差度进行对比分析。结果表明,所构建的阈值在不同负载工况下均能有效区分正常与异常。在敏感指标上,异常样本的偏差度稳定高于阈值,而正常样本的偏差度均低于阈值,未出现误报现象。


上述结果表明,本文提出的基于数字孪生的核密度估计阈值自学习预警方法,能够准确识别船用柴油机关键参数在正常与异常工况下的变化特征,表现出良好的跨工况适应性与稳定性。




(a) 平均排气温度



(b) 气缸峰值压力



(c) 增压器转速



(a) 平均排气温度




图 11 不同负载工况下关键性能参数的偏差度对比结果

Fig.11 Deviation degree comparison of key performance parameters under different load conditions

3 结 语

为探索适用于船用柴油机状态监测与故障预警的可行方法,本文提出一种融合机理仿真信息与传感实测信息的多模态数字孪生方法。通过构

建高保真机理模型并引入性能退化校正机制,为数字孪生建模提供了可信的物理基础。基于注意力增强的多尺度卷积网络,从仿真与实测数据中提取深层信息,构建稳定的数据基础,进而在特征层实现跨模态信息融合。在此基础上,本文构建了基于偏差度建模与核密度估计的故障预警方法,并针对关键性能参数开展了阈值自学习与异常检出的验证实验。实验结果表明,所提方法在正常与异常工况下均表现出较好的判别能力,可为船用柴油机的智能运维提供支持。同时,考虑到方法在实际运维中的应用需求,本文所构建的数据驱动模型在结构上仅包含多尺度一维卷积与轻量注意力模块,其推理过程具备良好的并行特性,从理论层面验证了准实时计算的可行性。此外,模型训练与阈值学习的离线阶段可在岸端环境完成,船载系统仅需执行推理与判别操作,为该方法的后续工程化部署提供了可行思路。

参考文献 (References):

- [1] LI Y B, GUO Z W, LI Z X, et al. Instantaneous angular speed-based fault diagnosis of multicylinder marine diesel engine using intrinsic multiscale dispersion entropy [J]. IEEE Sensors Journal, 2023, 23(9): 9523-9535.
- [2] XU C Y, LI W Y, ZHAO Y. A novel fused narx-driven digital twin model for aeroengine gas path parameter prediction [J]. IEEE Transactions on Industrial Informatics, 2024, 20(4): 6280-6288.
- [3] 甘辉兵. LNG 船推进系统建模与仿真研究 [D]. 大连: 大连海事大学, 2012.
GAN H B. Modeling and simulation of LNG carrier propulsion system [D]. Dalian: Dalian Maritime University, 2012. (in Chinese)
- [4] WANG R H, CHEN H, GUAN C, et al. Research on the fault monitoring method of marine diesel engines based on the manifold learning and isolation forest [J]. Applied Ocean Research, 2021, 112: 102681.
- [5] MILIOULIS K, BOLBOT V, THEOTOKATOS G. Model-based safety analysis and design enhancement of a marine LNG fuel feeding system [J]. Journal of Marine Science and Engineering, 2021, 9(1): 69.
- [6] 陈冬梅, 赵思恒, 魏承印, 等. 船舶柴油机状态监测及预测性维护研究及应用 [J]. 中国机械工程, 2022, 33(10): 1162-1168.
CHEN D M, ZHAO S H, WEI C Y, et al. Research and

- applications of condition monitoring and predictive maintenance of marine diesel engines[J]. *China Mechanical Engineering*, 2022, 33(10): 1162-1168. (in Chinese)
- [7] QIN Y, ZHANG T S, QIAN Q, et al. Large model for rotating machine fault diagnosis based on a dense connection network with depthwise separable convolution[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1-12.
- [8] 王新全, 孙培廷, 邹永久, 等. 基于 GA-BP 模型的船舶柴油机排气温度趋势预测[J]. *大连海事大学学报*, 2015, 41(3): 73-76.
WANG X Q, SUN P T, ZOU Y J, et al. Prediction of marine main engine exhaust temperature changing trend based on GA-BP model[J]. *Journal of Dalian Maritime University*, 2015, 41(3): 73-76. (in Chinese)
- [9] 宫文峰, 陈辉, WANG D W. 基于深度学习的船舶机械微小故障快速诊断方法[J]. *计算机集成制造系统*, 2022, 28(9): 2852-2864.
GONG W F, CHEN H, WANG D W. Fast diagnosis method of incipient fault of marine machinery based on deep learning[J]. *Computer Integrated Manufacturing Systems*, 2022, 28(9): 2852-2864. (in Chinese)
- [10] 陶飞, 刘蔚然, 张萌, 等. 数字孪生五维模型及十大领域应用[J]. *计算机集成制造系统*, 2019, 25(1): 1-18.
TAO F, LIU W R, ZHANG M, et al. Five-dimension digital twin model and its ten applications[J]. *Computer Integrated Manufacturing Systems*, 2019, 25(1): 1-18. (in Chinese)
- [11] TSITSILONIS K M, THEOTOKATOS G, PATIL C, et al. Health assessment framework of marine engines enabled by digital twins[J]. *International Journal of Engine Research*, 2023, 24(7): 3264-3281.
- [12] 周宏根, 魏凯, 窦振寰, 等. 基于数字孪生的船用柴油机整机性能评估方法[J]. *船舶工程*, 2022, 44(5): 82-89.
ZHOU H G, WEI K, DOU Z H, et al. Digital twin-based performance evaluation method for marine diesel engines[J]. *Ship Engineering*, 2022, 44(5): 82-89. (in Chinese)
- [13] 景乾峰, 神和龙, 尹勇. 一种基于虚拟现实系统的船舶数字孪生框架[J]. *北京交通大学学报*, 2020, 44(5): 117-124.
JING Q F, SHEN H L, YIN Y. A ship digital twin framework based on virtual reality system[J]. *Journal of Beijing Jiaotong University*, 2020, 44(5): 117-124. (in Chinese)
- [14] HAUTALA S, MIKULSKI M, SÖDERÄNG E, et al. Toward a digital twin of a mid-speed marine engine: from detailed 1D engine model to real-time implementation on a target platform[J]. *International Journal of Engine Research*, 2023, 24(12): 4553-4571.
- [15] JEON J, THEOTOKATOS G. A framework to assure the trustworthiness of physical model-based digital twins for marine engines[J]. *Journal of Marine Science and Engineering*, 2024, 12(4): 595.
- [16] XU X A, LIN Y, YE C. Fault diagnosis of marine machinery via an intelligent data-driven framework[J]. *Ocean Engineering*, 2023, 289: 116302.
- [17] 邢致恺, 何怡刚, 姚其新. 基于多模态信息融合的变压器在线故障诊断方法[J]. *电子测量与仪器学报*, 2024, 38(9): 95-103.
XING Z K, HE Y G, YAO Q X. Transformer online fault diagnosis method based on multi-modal information fusion[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(9): 95-103. (in Chinese)
- [18] THEOTOKATOS G, STOUMPOS S, BOLBOT V, et al. Simulation-based investigation of a marine dual-fuel engine[J]. *Journal of Marine Engineering & Technology*, 2020, 19(Sup.1): 5-16.
- [19] ZHANG J K, WANG Z T, LI S Y, et al. A digital twin approach for gas turbine performance based on deep multi-model fusion[J]. *Applied Thermal Engineering*, 2024, 246: 122954.
- [20] DONG Y T, JIANG H K, WU Z H, et al. Digital twin-assisted multiscale residual-self-attention feature fusion network for hypersonic flight vehicle fault diagnosis[J]. *Reliability Engineering & System Safety*, 2023, 235: 109253.
- [21] TIAN H X, YANG L Z, JU B T. Spatial correlation and temporal attention-based LSTM for remaining useful life prediction of turbofan engine[J]. *Measurement*, 2023, 214: 112816.
- [22] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(8): 2011-2023.
- [23] 董建伟, 曾鸿, 刘鑫龙, 等. 基于 DBN-SVR 的船舶主机排烟温度基线模型[J]. *大连海事大学学报*, 2022, 48(2): 101-109.
DONG J W, ZENG H, LIU X L, et al. Exhaust gas temperature baseline model of main engine based on DBN-SVR[J]. *Journal of Dalian Maritime University*, 2022, 48(2): 101-109. (in Chinese)
- [24] 王泷德. 基于改进极限学习机的船舶发动机故障诊断研究[D]. 大连: 大连海事大学, 2023.
WANG L D. Research on fault diagnosis of marine engine based on improved extreme learning machine[J]. Dalian: Dalian Maritime University, 2023. (in Chinese)