

基于振动信号的航空发动机盘轴裂纹 智能预警方法

甘甜¹ 王琮¹ 王栋欢² 丁宝庆³ 梁华¹ 李应红¹

(1. 空军工程大学, 710051, 陕西西安; 2. 动力与能源学院, 西北工业大学, 710072, 陕西西安;
3. 航空发动机研究院, 西安交通大学, 710115, 陕西西安)

摘要: 为实现航空发动机盘轴裂纹的早期预警, 提出基于物理嵌入网络架构的航空发动机裂纹故障预警方法。基于长短期记忆循环神经网络并结合发动机部件级物理拓扑结构, 依据部件对输入参数进行聚类, 搭建物理结构嵌入的神经网络架构。利用5台正常涡扇发动机搭建初始预警模型并进行模型预测性能评估, 结果显示, 模型在发动机 N_1 转速40%~80%区间对振动的预测对称平均绝对百分比误差为6.07%, 模型对发动机振动响应的实时预测可靠。采用滚动式更新策略构建动态预测模型并进行精度验证, 基于振动值得趋势偏差分析, 提前捕获了具有单向性、累积性、不可逆特征的异常特征, 证实该方法的有效预警。该方法在不依赖历史故障数据、不增设额外传感器的条件下, 实现了高精度、可解释、可验证的显著优势, 为航空发动机结构健康监测从事后诊断向事前预警转型提供了可行的技术方案。

关键词: 航空发动机; 振动监测; 智能预警; 裂纹故障; 长短期记忆循环神经网络; 深度学习

中图分类号: V263.6 **文献标志码:** AA

文章编号: 0253-987X(XXXX)XX-0001-22

A Vibration Signal-Based Intelligent Prediction Method for Aero-Engine Disk-Shaft Cracks

GAN Tian¹, WANG Qiong¹, WANG Donghuan², DING Baoqing³, LIANG Hua¹, LI Yinghong¹

(1. Air Force Engineering University, Xi'an, Shaanxi 710051, China;

2. School of energy and power, Northwestern Polytechnical University, Xi'an, Shaanxi
710072, China;

3. Institute of Aero-Engine Research, Xi'an Jiaotong University, Xi'an, Shaanxi 710115,
China)

Abstract: To achieve early warning of disk-shaft cracks in aero-engines, a crack fault warning method based on a physics-embedded network architecture is proposed. A neural network architecture embedded with physical structure is constructed by integrating Long Short-Term Memory (LSTM) recurrent neural networks with the component-level physical topology of the engine, where input parameters are clustered according to engine components. An initial warning model is established using data from five healthy turbofan engines, and its predictive performance is evaluated. The results show that the model achieves a symmetric mean absolute percentage error (sMAPE) of 6.07% for vibration

收稿日期: 2022-01-25。

prediction in the engine N_1 speed range of 40%-80%, demonstrating reliable real-time prediction of engine vibration response. A dynamic prediction model is constructed using a rolling update strategy and validated for accuracy. Based on trend deviation analysis of vibration values, abnormal features characterized by unidirectionality, cumulativity, and irreversibility are captured in advance, confirming the effectiveness of the proposed early warning method. Without relying on historical fault data or additional sensors, this method offers significant advantages in terms of high accuracy, interpretability, and verifiability, providing a feasible technical pathway for transitioning aero-engine structural health monitoring from post-event diagnosis to pre-event warning.

Keywords: Aero-engine; Vibration monitoring; Intelligent early warning; Crack fault; Long short-term memory (LSTM); Deep learning

航空发动机内部结构十分复杂,同时由于高温、高压、高转速的工作环境和材料限制等因素的存在,航空发动机转子在运行过程中可能会产生裂纹故障,导致严重事故^[1]。目前应用在航空发动机上的裂纹检测对象主要是叶片^{[2][3]}和轴承^{[4][5]},因为这两个关键部件出现裂纹的频率非常高,但是盘和轴的裂纹也不可忽视,虽然出现的频率不高,但是盘轴一旦出现裂纹,发动机转子快速飞转,在巨大的离心力作用下,断块会击穿机匣,造成严重的发动机非包容性故障^[6]。因此,研究如何预测裂纹的出现对飞行安全具有重要意义。

当前,针对发动机盘、轴裂纹的监控,主要依赖于一套以周期性检查为主,实时监控为辅的传统技术体系,首先在线振动监测技术^[7],其原理是通过在发动机机匣等关键位置安装振动加速度传感器,持续采集发动机运行中的振动频谱与幅值信号。在理想情况下,转子部件如果出现裂纹、缺陷、故障卡滞等情况,其振动特征会发生变化^[8]。监测系统通常只能设定一个基于历史经验

的固定报警阈值,只有当裂纹扩展到足以引起显著质量不平衡或刚度突变时,才会触发警报。其次,是以无损探伤^[9]技术为代表的定期离线检查,这是当前发现裂纹最直接、最可信的手段。通过离线激振获取结构的模态参数,再利用信息论方法进行损伤定位。然而,这类检查成本高昂且流程繁复,必须让发动机停机、拆解至部件状态。最后是孔探仪检查^[10],作为无损探伤的一种特殊和便捷补充。它的优势在于无需完全拆解即可实现快速目视检查。以上这套体系虽然在保障航空发动机的历史上发挥了关键作用,但难以满足对发动机断轴、盘裂等灾难性故障实现早期、精准、前瞻预警的现代化需求。

近些年来,随着实时同步、高保真的数字化试验技术兴起^[11],也开始应用于航空发动机盘轴裂纹检测和诊断,西安交通大学陈雪峰团队^[12]提出一种基于自组织映射融合稀疏编码的航空发动机涡轮盘裂纹在线检测与定量诊断方法,通过构建高保真仿真模型与实测数据融合,实现了对涡轮盘裂纹的实时监测、

定位与尺寸估计,属于从传统无损检测向智能在线监测过渡的典型技术方案^[13]。目前,人工智能的发展使得AI的故障诊断^[14]与预测方法优势愈加明显^{[15][16]},通过结合大数据和机器学习技术,使得通过模型预测来快速提前识别数据的异常特征,从而使航空发动机安全问题的早期预警成为可能。

目前发动机参数预测的模型主要包括物理机理模型、数据驱动模型以及混合模型三大类^[17]。物理机理模型基于明确的物理规律^[18],预测结果物理可解释性强,运用数学或仿真的方法来构建物理模型^[19],同时对于高维的非线性转子系统,还需要引入模型的降维方法^[20],但是物理机理建模过程复杂、成本高昂。数据驱动则是完全从历史数据中学习统计规律与模式^[21],能够识别发动机转子复杂的非线性关联^[22],但是难以提供预测的物理可解释性,同时对训练数据的规模和质量要求高。而混合模型^[23]理论上既能保持物理模型的可解释性与外推稳健性,又能具备数据模型处理复杂性和自适应性的优势^[24],但是如何实现物理与数据的深度、有机融合是核心挑战。

无论是纯数据驱动,还是混合模型,都需要结合历史数据和深度学习算法,深度学习作为机器学习领域的一个分支,由于对处理具有非线性且高维度特征的数据有良好的拟合和降维效果^[25],包括卷积神经网络(Convolutional Neural Networks, CNN)

^[26]、循环神经网络(Recurrent Neural Networks, RNN)^[27],以及RNN的变体——长短期记忆网络(Long and Short-Term Memory, LSTM)^[28]等深度学习方法已经广泛应用于航空发动机关键部件的故障诊断领域^[29]。在航空发动机轴承故障预测上^[30],针对轴承振动信号兼具时序依赖与局部冲击的特性,设计了改进门控循环单元(Gap Gated Recurrent Unit Network, GGRU)与一维卷积神经网络(One-Dimensional Convolutional Neural Network, 1DCNN)的并行架构,以同时深度挖掘信号中的长程序序关联与局部空间特征,同时动态地利用新工况数据的统计量来调整网络中的批量归一化层参数。针对航空发动机转子故障诊断方法中面临的样本不足和特征微弱的问题^[31],通过多层长短期记忆网络建立非线性转子结构的元模型,实现转子动响应的预测,扩充数据集。

目前,大多数研究使用的方法还是纯数据驱动,添加的物理约束多为损失函数上的物理约束,通过对神经网络进行改进构建监测模型,对于轴承^[32]、叶片^[33]等一些关键部件的针对性分析是有效的。但是针对盘、轴一类的大型复杂部件,因为相关联部件太多,除了需要更多维度的数据之外,还需要引入发动机物理先验知识,构建发动机整机振动监测模型,因此,从神经网络的搭建开始就要考虑发动机部件的结构特征和气路特征。此外,考虑到LSTM在航空发动机数据驱动的深度学习中广泛应

用^[34]，且模型精度可靠^{[35][36]}。本文基于LSTM并融合发动机物理拓扑结构，将发动机结构特征和气路流向特征融入网络结构，采用数据与架构驱动方法构建高精度航空发动机盘轴裂纹异常监测模型，本研究主要贡献如下：

(1) 提出了一种面向振动故障诊断的物理嵌入时序网络建模架构。结合“物理知识融入智能网络”的思想，强调依靠明确的物理知识设计网络架构，以提升模型可解释性并降低数据需求。本文首次针对机匣振动预测问题，依据发动机部件结构与气路流向特征设计了并行Bi-LSTM子网络架构，实现了振动响应机理与网络拓扑的显式映射。

(2) 利用5台正常发动机使用架次运行参数，在 N_1 转速40%-80%的核心监测区间内开展模型训练与测试。5次独立试验结果显示，模型自测对称平均绝对百分比误差（Symmetric Mean Absolute Percentage Error, sMAPE）均值为5.32%，预测sMAPE均值为6.07%，误差分布统计显示，95%的预测点百分比误差低于20%，98.8%低于30%，验证了本方法在振动预测任务中的显著精度优势与强泛化能力。

(3) 在100架次连续使用案例中，构建了自适应跟踪发动机性能衰退的动态健康基线模型。针对航空发动机全生命周期内因叶片磨损、效率下降等自然衰退过程导致的振动特性缓慢漂移问题，本文提出采用滚动式训练更新策略，确保模型始终学习发动机当前健康

状态下的振动响应规律。

(4) 提出一种基于预测异常偏离及趋势特征的裂纹先兆实时识别与评估方法，首次通过数据预训练得方式实现提前的结构损伤预警，并经孔探直接验证。在预测结果中，提炼出裂纹损伤区别于正常工况波动的数据特性。

1 方法设计

本方法的基本原理是获取航空发动机最近历史架次的使用数据并进行离线分析，并获取历史架次各个时刻的发动机工作状态以及对应的环境参数和状态参数，同时通过振动传感器获取发动机振动参数，构建环境参数和状态参数与振动参数之间映射关系。利用历史架次发动机数据进行模型训练，得到航空发动机实时振动预测模型，然后将最近一个架次的发动机参数输入到模型进行预测，通过对比模型预测数据与振动传感器采集数据差异，在下一个使用架次之前提前识别裂纹先兆。方法流程如图1所示。

1.1 数据预处理

为验证所提方法的可行性和准确性，案例研究使用了双转子涡扇发动机的实际运行数据。裂纹故障经第101架次飞行前的地面孔探检查，发动机对应的低压转子轴上发现了可见裂纹。经后续分解检查与断口分析确认，该裂纹为多源疲劳裂纹，向进气边方向扩展，扩展区呈现细密疲劳条带。该裂纹类型与

航空发动机盘轴典型失效模式一致, 盘轴一旦出现裂纹, 在高速旋转离心力作

用下, 断块可能击穿机匣, 造成严重的非包容性故障。




图1 方法流程简化示意图

Fig.1 Simplified illustration of method process

获取发动机历史架次的工作参数并聚类, 通过传感器获取历史架次单台发动机与振动相关的工作参数, 包括环境参数与状态参数, 然后根据航空发动机部件结构与工作系统, 对环境参数与状态参数特征按照发动机部件和系统进行聚类。工作参数包括环境参数和状态参数, 环境参数包括: 发动机进口总温 T_0 、进口总压 P_0 ; 状态参数包括: 发动机低压压气机换算转速 N_1 , 发动机高压压气机换算转速 N_2 , 风扇进口导叶角度 α_1 、高压压气机进口导叶角度 α_2 、高压压气机进口总温 $T_{2.5}$ 、高压压气机出口总压 P_3 、油门角度 PLA 、涡轮出口总压 P_5 、涡轮出口总温 T_5 、尾喷管喉部直径 D_8 。

通过数据采集模块获取最近历史架次单台发动机的工作参数, 构建时间序列, 根据航空发动机部件结构与工作流程按照 (T_0) 、 (P_0, α_1) 、 (α_2, P_3) 、 $(T_{2.5})$ 、 (N_2) 、 (N_1) 、 (P_5, T_5) 、 (PLA) 、 (D_8) 进行参数聚类, 聚类的

数目为超参数序列长度 (Sequence length), 等于9。

1.2 神经网络架构搭建

神经网络架构的建立实质就是依托发动机物理知识规律, 对数据关联性进行了限制, 形成数字化网络架构。在网络里内嵌航空发动机物理规律的限制, 能够快速地从聚类参数中选取代表部件/系统特性的参数, 大幅度减少了对无效数据的训练, 可以大幅度节省计算资源。

根据航空发动机运行结构, 神经网络架构被分为三层: 物理信息输入层、状态耦合层、参数映射层, 整体架构如图2所示。通过将整个发动机物理结构分割成若干个小的子域, 形成发动机部件、系统计算子域并独立求解, 通过气流流经发动机主流顺序的策略将各个子域的解整合起来。整个网络架构层与层之间为单向连接, 通过物理信息的干预而限定网络层数与网络层作用, 以限制

在表示学习过程中抽象特征的内容。




图2 物理内嵌网络架构原理框图

Fig. 2 Structure of physics-embedded neural network

数字化网络架构中的物理信息输入层结构为由9个并行的Bi-LSTM子网络构成，每个子网络对应一个聚类参数组，也就是一个发动机部件/系统，如图3所示。每个子网络输入参数为接收对应聚类参数组的时序数据，参数设置为每个子网络的Bi-LSTM单元数由该聚类参数组中参数数量决定，设置为参数数量的2倍，最小不少于4。聚类1（单参数）设4个单元。隐藏状态维度统一设置为64维，以保证后续层输入一致。输出为每个子网络最后一个时间步的隐藏状态，维度为64维。

耦合层采用的神经网络结构与物理信息输入层保持一致，即单层Bi-LSTM，其输入参数来自物理信息输入层的输出参数，这样不仅强化了序列数

据中内部参数间的关联性，同时其结构也受到所述物理信息输入层输出维度的约束。耦合层的输出连结映射层。耦合层结构为由单层Bi-LSTM构成，接收物理信息输入层所有子网络输出的拼接向量。输入为9个子网络的输出，共 $9 \times 64 = 576$ 维，按顺序拼接为一个576维向量。耦合层参数设置为Bi-LSTM单元数设为128，隐藏状态维度为128维。输出为最后一个时间步的隐藏状态（128维），用于表征部件间的耦合关系。

参数映射层由全连接层构成，用于建立所述耦合层的输出与目标特征之间的非线性映射关系。结构为由全连接层构成，将耦合层的输出映射到目标振动参数B。参数映射层的层次设计：第一

层全连接层: 128 维输入, 64 维输出, 激活函数为 ReLU; 第二层全连接层为 64 维输入, 32 维输出, 激活函数为 ReLU; 输出层为 32 维输入, n 维输出

(n 为振动参数分量个数), 激活函数为线性激活函数 Linear (回归任务)。输出: 振动参数 B 的预测值, 维度为 n 。




图3 发动机数字化网络架构

Fig.3 Architecture of digital twin model for dual-rotor turbfan engines

2 模型训练与评价指标

2.1 特征处理

为有效提升了模型对振动特征的学习效率与预测信噪比, 聚焦于裂纹故障异常且信号相对清晰的工况段, 需要过滤高转速下强烈的背景振动噪声, 由于振动的随机性受到高转速的影响显著。因此, 利用 N_1 转速范围 40%~80%, 过滤掉高转速引起的振动随机性以及低转速的不敏感性, 利用这些数据来进行模型的训练可以大幅度提高模型预测的精度。

为加速训练模型的收敛, 归一化处理初筛后的工作参数。归一化的方法是

某一时刻的数据原始值 X_i 减去原始数据中的最小值 X_{min} , 然后在除以该时刻数据原始值 X_i 减去原始数据中的最大值 X_{max} , 得到各组数据的相对值 R 。

物理信息输入层获得参数输入后, 提取特征, 传递给耦合层, 依据聚类顺序进行循环, 超参数序列长度 (Sequence length) 为迭代次数, 即按照物理信息输入层的结构顺序将特征矩阵输入至耦合网络层。物理信息输入层中的双向长短期记忆循环神经网络 (Bi-LSTM) 的网络单元数量与聚类的数目一致, 网络单元序列长度为聚类参数数目之和, 其特征维度固定为 1。

2.2 模型训练

使用 Keras 进行模型创建及代码实现。选择某台发动机数据作为研究对象,筛选出实际有效的数据文件并按照使用架次顺序排列。按照时序滑动窗口划分样本,滑动窗口的长度由发动机参数的采样频率决定,大小为采样频率 $\times H$, H 为经验值,设置为2,训练算法为 (Root Mean Square Propagation, RMSProp), 模型训练的损失函数选用均方误差 (Mean Square Error, MSE) 表示:

$$MSE = \frac{1}{m} \sum_i (y(x_i) - f(x_i))^2 \quad (1)$$

其中, m 表示单次模型训练输入的参数样本的总数, $y(x)$ 是目标振动的时间序列数据, $f(x)$ 是模型训练过程中输出的振动参数时间序列数据。初始学习率设置为0.001, 单次训练次数设置为150, 得到振动实时预测模型。所有训练均使用 Python3.7 编程语言进行。训练的主要配置为两颗 X86 系列处理器, 每个 CPU 核心数大于20, 主频 2.4GHz, 256GB (32GB $\times$ 8) DDR4 EEC 内存, 8 块 Nvidia Tesla V100 32GB GPU 卡。

2.3 评价指标

参数映射层输出为振动参数 B , 其表征的物理结构为振动传感器, 参数特征表示为:

$$Y = \{Y_1, Y_2, \dots, Y_i, \dots, Y_n\} = \{(y_1, 1), (y_2, 1), \dots, (y_n, 1)\} \quad (2)$$

其中, n 表示由传感器采集的振动参数

分量个数。

在振动预测模型中, 使用平均绝对误差 (Mean Absolute Error, MAE)、对称平均绝对百分比误差 (Symmetric Mean Absolute Percentage Error, sMAPE)、最大百分比误差 (Max Error) 等评估模型的预测精度和性能。MAE 衡量预测值与实际值之间的绝对差均值, 对异常值不敏感, 更能反映平均误差水平; MAPE 以百分比形式表示误差, 便于跨数据集比较, 对零值或接近零的实际值敏感, 适用于需要百分比误差评估的场景, 但是 MAPE 在真实振动值接近或为零时会出现的分母过小或无法计算的问题, sMAPE 则有效避免了这种问题, 更具稳健性; 最大百分比误差衡量预测值与实际值之间的最大偏差, 适用于需要关注最坏情况的场景。各误差公式如下:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (3)$$

$$MAPE = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \quad (4)$$

$$sMAPE = \frac{200\%}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{|y_i| + |\hat{y}_i|} \quad (4)$$

$$MaxError = \max \left(\left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \right) \times 100\% \quad (5)$$

式中, y_i 表示真实值; $\hat{y}_i$ 表示预测值; m 表示样本数量。上述三种误差越小, 表明模型对发动机的数字化仿真模拟精度和鲁棒性越高。本文采用以上三种误差形式对模型性能进行评价。

3 结果与讨论

3.1 模型预测性能整体评估

为全面评估本文所构建的物理结构嵌入双向长短期记忆神经网络振动预测模型的性能,分别进行了自测与预测。自测的目的是为了检验模型对已学习工况规律的拟合能力;预测则用于评估模型对全新工况的泛化能力与工程实用价值。选取了5台正常的发动机进行模型的训练和测试,在单台发动机选取5个初始架次作为训练样本,单台发动机总计训练样本总数超过40000的条件下,并选取第5个架次作为自测架次,相邻

的第6个架次作为预测架次,模型的自测和预测的评价指标结果如图4所示。对于发动机振动值B而言,5次自测的sMAPE平均值为5.32%,预测的sMAPE平均值为6.07%, N_1 在40%-80%转速范围内,5次的预测结果都比自测结果高,自测与预测误差的微小差异(仅仅0.75个百分点)验证了模型具备优秀的泛化能力,表明物理结构嵌入设计能够有效防止了过拟合,模型学习到的是普适的振动产生机理,而非单纯记忆训练数据。同时,预测误差没有大幅飙升,验证了模型的稳定性。




图4 特定转速条件下模型对振动的自测和预测结果误差

Fig.4 Model self-testing and prediction errors for vibration at fixed rotor speeds

模型在全部测试数据上对振动的自测和预测sMAPE结果如图5所示,对于发动机振动值B而言,当测试范围扩展至全转速区间时,模型sMAPE的平均水平显著上升至43.61%(自测)和46.74%(预测)。这一现象主要源于低

转速区间($N_1=0-40\%$)振动信号信噪比极低的客观事实。在该区间,实测振动幅值已接近传感器本底噪声水平,信号中不可预测的随机成分占主导。模型输出的微弱趋势性预测虽然绝对误差很小,但因分母过小而导致相对误差被显

著放大,其次,发动机振动信号自身包含较强的随机噪声成分,这部分不可由工况参数决定的波动被计入预测误差。

这恰恰证明模型行为的合理性,它学习并输出了基于物理规律的振动趋势,而非尝试拟合不可预测的随机噪声。




图5 全转速条件下模型对振动的自测和预测结果误差

Fig.5 Model self-testing and prediction errors for vibration across the full speed range

图6给出了5次自测和预测最大百分比误差(Max Error)统计结果。在5次独立训练中,模型在核心工作区间($N_1=40\%-80\%$)的最大百分比误差表现出一定的波动性,自测最大误差分布于37.10%至53.16%之间,平均值为45.80%;预测最大误差分布于46.23%至61.67%之间,平均值为53.35%。同时发现这些最大误差点均为孤立的样本点,每次试验中仅出现于极少数特殊工况。

为更精细地评估PE-BiLSTM模型的预测可靠性,本文选取了五次训练中最大百分比误差最大的模型,也就是第二个训练测试次的预测架次的误差进行分析,对其在下一个架次的2799个连续采样点进行了误差统计,分布结果如

图7所示。发现:模型的预测误差高度集中于低值区间。约81.9%的预测点(2295个)其百分比误差低于10%;高达94.9%的预测点(2655个)误差控制在20%以内。误差超过30%的预测点仅占总数的0.9%(25个),而最终导致最大百分比误差的极值点(60%-65%区间)仅有2个,占比0.07%。结合模型在核心区间的平均误差水平(自测 sMAPE=5.32%, 预测 sMAPE=6.07%)可知,最大百分比误差与平均误差之间存在数量级差异,进一步印证了极值误差的孤立性,而非系统性偏差。在绝大部分平稳及主要工作工况下,模型预测与实测值高度吻合。高百分比误差并非普遍现象,而是由极少数特定工况所引发,从工程应用视角看,健康监测系统

关注的是振动水平显著变化的趋势与异常。该模型在发动机低压转速为 40%-80% 工作区间, 超过 95% 的工况下提

供了误差低于 20% 的高保真预测, 完全能够为裂纹等故障的先兆识别构建一条稳定、可靠的健康振动基线。




图6 特定转速条件下模型对振动的自测和预测最大结果误差

Fig.6 Maximum model self-testing and prediction errors for vibration at specific rotor speeds




图7 第2个训练测试次的预测架次误差分布

Fig.7 Error distribution of the predicted flight in the second training-testing run

模型在测试数据集上的最大百分比误差较高, 为了找到这种较大误差的来源, 进一步给出了模型下一个架次振动的连续振动信号的预测结果与实测数据

的对比曲线 (平滑后), 如图8所示, 模型预测的振动时序曲线 (蓝色) 与传感器实测信号 (黑色) 在变化趋势与动态量级上均表现出高度一致性。整体上

看,这种高度的一致性,说明模型成功 规律。
捕捉了振动随发动机状态变化的物理




图8 第5测试次模型预测振动值与真实值变化趋势(平滑后)

Fig.8 Variation trends of predicted and actual vibration values in the fifth test run (smoothed)

通过对时间序列的预测对比分析,发现误差主要来源有以下三个方面:

一是油路影响,具体和油门杆参数PLA相关,如图9(a)所示,总的来说,油门杆和振动水平从趋势上属于强相关,这也是复合物理规律的。当油门杆平稳时,预测值和实测值误差非常小,但是当出现突跳波动,此时预测值和实测值确实会出现一定程度的偏差,如图9(b)所示。其对应的物理机理和燃烧室的化学反应相关,当油门杆瞬间发生突跳,会导致燃烧室瞬间富油,引起燃烧不稳定,燃烧又属于非定常流动问题,其引起的发动机振动必然存在较强的不确定性和非线性特征,导致对瞬变过程的预测产生了较大误差,但是这种预测偏离在油门杆稳定后,又迅速恢复到较低的误差水平。

二是气路影响,具体和发动机总温、总压传感器参数相关,图10(a)和

图10(b)给出了 T_0 和 $T_{2.5}$ 对预测误差的影响,气路的影响主要来自于外部环境的变化,但是对发动机振动而言,外部环境的变化是间接的,因为发动机内部的工况更加复杂,所以主要影响因素还是发动机内流,如图10所示, $T_{2.5}$ 的影响明显大于 T_0 。

气路影响的核心是非定常气动激励和流固耦合。振动的主要激励源来自于非定常气动力。在瞬态过程中,流量、攻角、增压比等气动参数剧烈变化,导致叶片负荷、分离涡、叶尖泄露涡尺度 and 位置等发生非定常快速重构。尤其在瞬态工况下,气动参数的剧烈变化会产生复杂的、可能未被训练数据充分覆盖的非定常载荷,模型很难外推。

三是结构影响,具体和发动机转速相关,在发动机加减速过程中,转子系统可能会快速穿越多个临界转速区,振动响应会经历放大、相位突变等复杂动

力学行为。当前模型的时间序列记忆可能不足以精确模拟这种“穿越共振”的物理过程。图 11 给出了 N_1 转速对预测误差的影响, 由图 11(a) 可知, 转速的任何变化应几乎实时地反映在发动机振动信号上, 这使得转速与振动之间具备最明确的时序因果关系。但是在局部的瞬态变化过程中, 振动真实值和发动机转速几乎呈现一致的变化关系, 而振动的预测值却出现了一定程度的滞后, 如图 11(b) 所示。这归因于本模型在输入层对所有参数进行平等处理, 并未对转

速这一物理上占主导作用的变量赋予任何先验的注意力权重或结构上的建模优势。因此, 在转速快速变化的瞬态过程中, 尽管模型通过 Bi-LSTM 的记忆机制学习到了长期的依赖关系, 但仍可能未充分捕捉其即时、突变的强影响特性, 从而在响应速度和变化梯度上产生细微的延迟。这种延迟与气路、液路等其他存在物理惯性或传输滞后的参数所引发的误差在现象上混合, 共同构成了瞬态阶段的主要预测偏差。




图9 第5测试次PLA对模型预测振动误差的影响, (b)为(a)中红色方框的局部放大

Fig.9 Effect of PLA on model prediction errors for vibration in the fifth test run; (b) is an enlarged view of the red box in (a)

为客观评估PE-Bi-LSTM模型的预测性能, 我们选取了三种具有代表性的

基线模型: 标准 LSTM、双向 GRU (Bi-GRU) 以及多层感知机 (MLP)。

所有模型均采用第2个训练测试次的数据集以及相同的超参数配置,在发动机核心工作区间 $N_1=40\%-80\%$ 上进行振动预测任务,结果如表所示。




图10 第5测试次 T_0 和 $T_{2.5}$ 对模型预测振动误差的影响,(c)为(b)中红色方框的局部放大


Fig.10 Effect of T_0 and $T_{2.5}$ on model prediction errors for vibration in the fifth test run; (c) is an enlarged view of the red box in (b)

从表中参数可知,四种模型中,MLP模型的预测误差最大,最大百分比误差高达128.32%。说明忽略时间序列依赖性的全连接网络捕捉振动随发动


机工况变化的动态规律并不理想。LSTM模型由于具有门控记忆机制,其性能显著优于MLP,验证了时序建模在振动预测中的必要性。Bi-GRU模型

在参数量相近的情况下取得了比单纯的 LSTM 更高的精度,因为双向结构能够同时利用过去与未来的时序信息,体现了一定的优越性。PE-BiLSTM 模型在所有评价指标上优势明显,与 Bi-GRU 相比,无论是 sMAPE 还是最大百分比

误差,均有所降低。物理聚类的输入层使模型能够分别学习不同部件的特征,避免了不相关参数间的干扰,并行 Bi-LSTM 子网络与状态耦合层的分层设计,更符合发动机气路与机械振动传递的物理机理。



(a) 整体趋势



(b) 局部放大

图 11 第 5 测试次 N_1 对模型预测振动误差的影响, (b) 为 (a) 中红色方框的局部放大

Fig. 11 Effect of N_1 on model prediction errors for vibration in the fifth test run; (b) is an enlarged view of the red box in (a)

表 1 不同模型在核心工作区间 ($N_1=40\%-80\%$) 的振动预测误差对比

Table 5 Performance comparison of different models for vibration prediction in the core speed range ($N_1=40\%-80\%$)

模型	sMAPE(%)	MaxError(%)	训练时间(s/epoch)
MLP	12.38%	128.32%	0.08
LSTM	9.73%	100.83%	0.12
Bi-GRU	7.98%	87.61%	0.11
物理架构融合模型	6.07%	63.42%	0.12

3.2 裂纹故障预测验证与分析

在完成对PE-Bi-LSTM振动预测模型的构建与精度验证基础上,进一步探讨该模型在航空发动机结构监测中的核心应用:基于预测残差异常的裂纹故障先兆识别。本文提出一种基于振动的航空发动机盘轴裂纹故障先兆的快速智能识别方法:利用训练完备的PE-Bi-LSTM模型,针对当前使用架次前1个架次,将对应的发动机参数(环境、状态参数)输入至本架构的振动监测模型,模拟前1个架次在当前同工况、同控制下的实时性能表现,对比分析模型振动参数的输出结果和传感器实测数据的偏离是否为误差可接受的范围,一旦

出现较大程度的残差,则说明发动机出现了振动异常,相应的给出在下一个架次前安排针对性检查的决策和建议。

基于上述方法,针对某一个架次后孔探检测出的裂纹故障的发动机进行历史架次验证并分析,共选取前100个连续的历史架次,为确保模型始终学习航空发动机在正常状态下的振动特性,并使其对结构健康状态的变化具有明确的指示性,本研究采用序贯建模与验证方法,在涵盖100个连续使用架次的数据序列中,每5个架次为一个训练组,对相邻的第6个架次进行预测,从前往后进行滚动式的训练和预测,如图12所示。




图12 滚动式训练监测方法

Fig.12 Rolling training and monitoring method

这种滚动式训练保证了模型训练集的纯净性。在每一次预测中,模型所学习的映射关系完全来自于其预测时刻之前的正常历史架次。这意味着模型所建立的输入-输出关系,始终是发动机在无故障状态下的物理行为表征,如果出现异常偏离,则可进行数据隔离,避免训练污染导致漏报风险。其次,航空发动机在长期服役过程中,即使未发生突

发性裂纹故障,其性能也必然衰退,例如压气机叶片磨损、涡轮效率降低等。这种渐变过程会导致在相同使用工况下,发动机的振动特性发生缓慢的偏移。

图13给出了部分历史架次的训练预测结果,为了更好的对比,本文对模型输出的原始预测曲线进行了适度的平滑处理,横坐标依然为工作时的采样时


间序列,纵坐标则为振动信号。由于空间有限,同时方便展示,选择部分架次内的无量纲结果作为代表。图 13(a)为对第 25 架次至 29 架次进行训练后的模型对第 30 架次的预测结果,预测曲线和真实信号在时序范围内呈现高度的吻合,虽然有一定的残差,基本属于误差允许的范围,无明显趋势性偏离,表明发动机在该阶段处于结构健康状态,模型所构建的健康振动基线具备良好的保真度与稳定性。图 13(b)为对第 49 架次至 53 架次进行训练后的模型对第 54 架次的预测结果,此时滚动训练策略已稳定运行多轮,模型每次训练均基于最近 5 个正常架次的数据,其建立的振动基线已与发动机当前真实状态高度吻合。

图 13(c)为对第 73 架次至 77 架次进行训练后的模型对第 78 架次的预测结果,此架次中,预测曲线与实测信号的误差更小,无明显正向或负向系统性偏离。除以上三个架次外,其他架次的滚动训练预测结果基本和实测结果一致,全程预测精度较高,这表明随着训练窗口的持续滚动,模型已充分适应发动机的振动特性。此外,少数时刻出现的瞬时微小偏离均呈现快速自回归特征,无论是预测值短暂高于还是低于实测值,其偏差持续时间极短,通常在短期内自行恢复至基线水平,从未形成持续性的趋势性偏离。这一现象与结构健康状态下的振动响应机理高度吻合,在无不可逆损伤的情况下,任何由工况波动、控制微调或外部扰动引起的瞬时偏差,都


会因系统自身的动力学稳定性而迅速收敛至平衡状态。裂纹损伤的本质恰恰在于其不可逆性:一旦结构完整性被破坏,由此引发的刚度下降、阻尼改变或碰摩加剧将产生持续累积的振动响应偏移,这种偏移不会自行恢复,反而会随裂纹扩展而逐步放大。

然而,在第 100 架次的预测结果中,如图 13(d)所示,前半程预测与实测仍保持良好一致性,但自后半程采样时间序列 10000 开始,实测振动值出现持续、显著地高于模型预测值的系统性偏离,振动幅值逐步扩大且不再回归基线水平,并且呈现明确的上升趋势性特征。这种单向偏离模式与裂纹损伤的不可逆物理本质高度吻合,一旦结构完整性被破坏,由此引发的刚度退化、应力集中及微碰摩加剧将产生持续累积的振动响应偏移,而非可恢复的瞬态波动。在无损伤的结构系统中,任何由工况波动引发的瞬时振动增幅,都会因系统阻尼而迅速衰减至稳态;而裂纹一旦萌生,其引发的动力学特性改变是永久性的、不可逆的,无法通过工况调节或系统自平衡予以消除。


在第 101 架次的地面孔探检查中,盘轴部位发现可见裂纹,直接证实了第 100 架次所观测到的残差异常确为裂纹先兆的工程表现。上述结果表明,本文基于 PE-Bi-LSTM 数字化基线所构建的预测残差监测方法,能够在裂纹被孔探发现前一个完整架次内实现有效的早期预警,具备显著的工程应用价值。




(a) 第30架次预测结果



(b) 第54架次预测结果



(c) 第78架次预测结果



(d) 第100架次预测结果

图13 部分架次无量纲振动预测值与真实值对比

Fig. 13 Comparison of normalized vibration predictions and actual values for selected flights

4 结论

开展了基于振动信号的航空发动机盘轴裂纹智能预警方法研究,结合基于物理结果嵌入约束的双向长短期记忆神经网络,在此基础上,提出了一种预测信号异常偏离及趋势分析的滚动式故障预警方法。通过对连续100个使用架次实测数据的系统验证,得出以下结论:

(1) 在 N_1 转速40%~80%的核心监测区间内,模型5次独立训练的自测sMAPE均值为5.32%,预测sMAPE均值为6.07%,误差分布统计显示,该模型在发动机低压转速为40%~80%工作区间,超过95%的工况下提供了误差低于20%的高保真预测。

(2) 误差溯源分析揭示了气路、液路与结构动力学三大物理路径对预测偏差的不同影响机制。气路非定常流动引发的瞬态激励因宏观参数观测受限而难以被模型完整表征;液路控制指令至作动响应的物理执行延迟导致模型输入与振动响应存在时间失配;结构误差则源于振动在固体介质中的传播响应最为迅捷,未来的模型优化可考虑通过引入参数注意力机制或物理引导的加权输入,以更符合物理规律的方式强化转速等关键参数的贡献,从而进一步提升瞬态预测精度。

(3) 通过对比健康阶段与故障阶段的残差演化模式,本文提炼出裂纹损伤区别于正常工况波动的三重判据。单向性:实测值持续高于预测值而不回落;累积性:残差幅值随时间渐进放大;不

可逆性: 偏离一经形成即不向基线收敛。通过案例验证, 本文方法能够在裂纹被常规检测手段提前实现有效预警。

参考文献

- [1] 陈予恕, 张华彪. 航空发动机整机动力学研究进展与展望[J]. 航空学报, 2011, 32(08): 1371-1391.
CHEN Yushu, ZHANG Huabiao. Review and prospect on the research of dynamic of complete aero-engine systems[J]. Acta Aeronautica et Astronautica Sinica, 2011, 32(8): 1371-1391 (in Chinses).
- [2] 乔百杰, 周凯, 伏宇, 等. 航空发动机叶片叶端定时综述: 测量、监测、诊断与评估[J/OL]. 航空动力学报, (2025-9-29) [2026-01-19]. <https://doi.org/10.13224/j.cnki.jasp.20250250>
QIAO Baijie, ZHOU Kai, FU Yu, et al, Review of aero-engine blade tip timing: measurement, monitoring, diagnosis, and evaluation[J/OL]. Journal of Aerospace Power, (2025-9-29) [2026-01-19]. <https://doi.org/10.13224/j.cnki.jasp.20250250> (in Chinses).
- [3] 黄松岭, 彭丽莎, 孙洪宇, 等. 航空发动机叶片缺陷无损检测与在线监测技术综述[J]. 测控技术, 2023, 42(05): 1-11.
HUANG Songlin, PENG Lisha, SUN Hongyu, et al. Review of Nondestructive Testing and Online Monitoring Technology for Aero-Engine Blade Defects[J]. Measurement & Control Technology, 2023, 42(5): 1-11 (in Chinses).
- [4] 胡明辉, 高金吉, 江志农, 等. 航空发动机振动监测与故障诊断技术研究进展[J]. 航空学报, 2024, 45(4): 7-35.
HU Minghui, GAO Jinji, JIANG Zhinong, et al. Research progress on vibration monitoring and fault diagnosis for aero-engine
- toring and fault diagnosis for aero-engine [J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(4): 7-35 (in Chinses).
- [5] 沙云东, 赵俊豪, 栾孝驰, 等. 基于阈值参数判决筛选的航空发动机主轴承故障特征提取方法[J]. 航空动力学报, 2025, 40(3): 284-295.
SHA Yundong, ZHAO Junhao, LUAN Xiaochi, et al. Aircraft engine main bearing fault feature extraction method based on threshold parameter decision screening [J]. Journal of Aerospace Power, 2025, 40(3): 284-295 (in Chinese).
- [6] 曹明, 黄金泉, 周健, 等. 民用航空发动机故障诊断与健康管理现状、挑战与机遇 I: 气路、机械和FADEC系统故障诊断与预测[J]. 航空学报, 2022, 43(9): 9-41+2.
CAO Ming, HUANG Jinquan, ZHOU Ji-ang, et al. Current status, challenges and opportunities of civil aero-engine diagnostics & health management I: Diagnosis and prognosis of engine gas path, mechanical and FADEC[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(9): 9-41+2. (in Chinese).
- [7] 周俊, 刘峻华, 杨涛, 等. 航空发动机在线振动监测系统的开发[J]. 计算机测量与控制, 2015, 23(11): 3599-3602.
ZHOU Jun, LIU Junhua, YANG Tao, et al. Development of aero-engine online vibration monitoring system[J]. Computer Measurement & Control, 2015, 23(11): 3599-3602 (in Chinese).
- [8] JIN Yulin, LIU Zhiwen, YANG Yang, et al. Nonlinear vibrations of a dual-rotor-bearing-coupling misalignment system with blade-casing rubbing[J]. Journal of Sound and Vibration, 2021, 497: 115498.

- [9] 臧云飞, 张海兵, 朱龙翔, 等. 原位静态无损检测技术在航空装备中的应用[J]. 无损探伤, 2024, 48(04): 1-5.
ZANG Yunfei, ZHANG Haibing, ZHU Longxiang, et al. Application of In-situ Static Non-destructive Testing Technology in Aviation Equipment[J]. Nondestructive Testing Technology, 2024, 48(04): 1-5 (in Chinese).
- [10] 胡静, 徐拓. 基于孔探技术的航空发动机常见损伤及案例分析[J]. 装备制造技术, 2017, 11: 183-185.
HU Jing, XU Tuo. The Common Damage and Case Analysis of Aero Engine Based on Borescope Technology[J]. Equipment Manufacturing Technology, 2017, 11: 183-185 (in Chinese).
- [11] 孙培禄, 刘馨, 张耿, 等. 数字孪生驱动的机电设备远程运维方法[J]. 西安交通大学学报, 2025, 59(8): 20-31.
SUN Peilu, LIU Xin, ZHANG Gen, et al. Digital Twin-Driven Remote Operation and Maintenance Method for Electromechanical Equipment[J]. Journal of Xi'an Jiaotong University, 2025, 59(8): 20-31 (in Chinese).
- [12] 曹宏瑞, 苏帅鸣, 付洋, 等. 数字孪生驱动的航空发动机涡轮盘裂纹检测与诊断方法: ZL2019107041471[P]. 2020-08-18.
CAO Hongrui, SU Shuaimin, FU Yang, et al. Digital Twin-Driven Crack Detection and Diagnosis Method for Aircraft Engine Turbine Disks: ZL2019107041471[P]. 2020-08-18 (in Chinese).
- [13] 曹明, 王鹏, 左洪福, 等. 民用航空发动机故障诊断与健康管理的现状、挑战与机遇 II: 地面综合诊断、寿命管理和智能维护维修决策[J]. 航空学报, 2022, 43(9): 625574.
CAO Ming, WANG Peng, ZUO Hongfu, et al. Current status, challenges and opportunities of civil aero-engine diagnostics & health management II: Comprehensive off-board diagnosis, life management and intelligent condition based MRO[J]. ACTA AERONAUTICAET ASTRONAUTICA SINICA, 2022, 43(9): 625574 (in Chinese).
- [14] 郭畅, 赵志斌, 张兴武, 等. 因果启发的深度域泛化旋转机械故障诊断[J]. 振动. 测试与诊断, 2025, 45(01): 154-160.
GUO Chang, ZHAO Zhibin, ZHANG Xingwu, et al. Causality Inspired Deep Domain Generalization for Rotating Machinery Fault Diagnosis[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(1): 154-160 (in Chinese).
- [15] ZHAO Yongping, HUANG Gong, HU Qiankun, et al. Soft extreme learning machine for fault detection of aircraft engine [J]. Aerospace Science and Technology, 2019, 91(0): 70-81.
- [16] XI Pengpeng, ZHAO Yongping, WANG Peixiao, et al. Least squares support vector machine for class imbalance learning and their applications to fault detection of aircraft engine[j]. Aerospace Science and Technology, 2018, 84(0): 56-74.
- [17] 王栋欢, 金海, 万东凯, 等. 基于性能数字孪生的航空发动机性能衰退实时监测与评估方法[J/OL]. 航空学报. [2026-02-13] [2026-03-19]. <https://link.cnki.net/urlid/11.1929.v.20250918.1420.016>
WANG Donghuan, JIN Tao, WAN Dongkai, et al. Real-Time Monitoring and Evaluation Method for Aero-Engine Performance Degradation Based on Performance Digital Twin[J/OL]. Acta

- Aeronautica et Astronautica Sinica, [2026-02-13] [2026-03-19]. <https://link.cnki.net/urlid/11.1929.v.20250918.1420.016> (in Chinese).
- [18] BI Junxi, GE Xinyu, HU Zenglin, et al. Research on crack propagation of aircraft engine blades based on multi-physics field coupling and modal frequencies[J]. International Journal of Reliability and Safety. 2024, 18(2): 103-120.
- [19] GAO Peng, CHEN Yushu, HOU Lei. Non-linear thermal behaviors of the inter-shaft bearing in a dual-rotor system subjected to the dynamic load[J]. Nonlinear Dynamics, 2020, 101: 191-209.
- [20] LU Kuan, JIN Yulin, HUANG Panfeng, et al. The applications of POD method in dual rotor-bearing systems with coupling misalignment[J]. Mechanical Systems and Signal Processing. 2020, 150(0): 107236-107236.
- [21] KIM Sangjo, KIM Kuisoon, SON Changmin. Transient system simulation for an aircraft engine using a data-driven model [J]. Energy, 2020, 196: 117046.
- [22] YU Pingchao, WANG Cun, HOU Li, et al. Dynamic characteristics of an aeroengine dual-rotor system with inter-shaft rub-impact[J]. Mechanical Systems Signal Processing, 2022, 166: 108475.
- [23] CHAO M A, C Kulkarni, KAI G, et al. Hybrid Deep Fault Detection and Isolation: Combining Deep Neural Networks and System Performance Models[J]. International Journal of Prognostics and Health Management, 2020, 10: 1-19.
- [24] HUANG Yufeng, JUN Tao, ZHAO Junyi, et al. Graph structure embedded with physical constraints-based information fusion network for interpretable fault diagnosis of aero-engine[J]. Energy, 2023, 283: 129120.
- [25] 刘梓琰, 吴毅伟, 王冠, 等. 数据驱动的液体火箭发动机健康监测算法研究[J]. 西安交通大学学报, 2024, 58(4): 182-191.
- LIU Z Y, WU Y W, WANG G, et al. Data-Driven Research on Health Monitoring Algorithms for the Liquid Rocket Engine[J]. Journal of Xi'an Jiaotong University, 2024, 58(4): 182-191 (in Chinese).
- [26] 张立智, 徐卫晓, 井陆阳, 等. 基于EMD-SVD和CNN的旋转机械故障诊断[J]. 振动测试与诊断, 2020, 40(6): 1063-1070.
- ZHANG Lizhi, XU Weixiao, JING Luyang, et al. Fault diagnosis of rotating machinery based on EMD-SVD and CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(6): 1063-1070 (in Chinese).
- [27] LIU Han, ZHOU Jianzhong, ZHENG Yang, et al. Fault diagnosis of rolling bearings with recurrent neural network-based autoencoders[J]. ISA transactions, 2018, 77: 167-178.
- [28] ZHANG Ruiyang, ZHAO Chen, SU Chen, et al. Deep long short-term memory networks for nonlinear structural seismic response prediction[J]. Computers Structures, 2019, 220: 55-68.
- [29] 张赟, 林学森, 王琳, 等. 采用监督局部切空间排列算法的航空发动机磨损故障诊断[J]. 西安交通大学学报, 2020, 54(4): 179-185.
- ZHANG Yun, LIN Xuesen, WANG Lin, et al. Aero-Engine Wear Fault Diagnosis with Supervised Locally Tangent Space Alignment[J]. Journal of Xi'an Jiaotong University, 2020, 54(4): 179-185 (in

- Chinses).
- [30] 孙俪榕. 基于振动数据的滚动轴承故障诊断与健康状态评估研究[D]. 北京: 北京交通大学, 2024: 25-27.
- SUN L R. Research on Fault Diagnosis and Health State Assessment for Rolling Bearings Based on Vibration Data[D]. Beijing: Beijing jiaotong university, 2024: 25-27 (in Chinese).
- [31] 徐勇杰. 基于深度学习的航空发动机转子故障诊断[D]. 南京: 南京林业大学, 2023: 15-22.
- XU Y J. Aeroengine rotor fault diagnosis based on deep learning[D]. Nanjing: Nanjing Forestry University, 2023: 15-22 (in Chinese).
- [32] 陶唐飞, 周文洁, 况佳臣, 等. 融合多小波分解的深度卷积神经网络轴承故障诊断方法[J]. 西安交通大学学报, 2024, 58(5): 31-41.
- TAO Tangfei, ZHOU Wenjie, KUANG Jia-chen, et al. Bearing Fault Diagnosis Method of Deep Convolutional Neural Network Based on Multiwavelet Decomposition[J]. Journal of Xi' an Jiaotong University, 2024, 58(5): 31-41 (in Chinses).
- [33] 黄鑫, 张小栋, 张英杰, 等. 基于三维叶尖间隙的叶片裂纹动力响应特征分析与诊断方法[J]. 航空动力学报, 2022, 37(09): 1923-1935.
- HUANG Xin, ZHANG Xiaodong, ZHANG Yingjie, et al. Dynamical response feature analysis based on 3-dimensional blade tip clearance and diagnosis method for blade crack[J]. Journal of Aerospace Power, 2022, 37(09): 1923-1935 (in Chinses).
- [34] DE P I, REIJNS A, MITICI M. Alarm-based predictive maintenance scheduling for aircraft engines with imperfect Remaining Useful Life prognostics[J]. Reliability Engineering & System Safety, 2022, 221: 108341.
- [35] DE P I, MITICI M. Developing health indicators and RUL prognostics for systems with few failure instances and varying operating conditions using a LSTM autoencoder[J]. Engineering Applications of Artificial Intelligence, 2023, 117: 105582.
- [36] HUANG Yufeng, XIONG Juntao, SUN Gan, et al. A prognostic and health management framework for aero-engines based on a dynamic probability model and LSTM network[J]. Aerospace, 2022, 9 (6): 316.