

采用多尺度 Mamba 架构的装备剩余寿命预测方法

田从宝¹, 王兆强^{1,2}, 胡昌华¹, 樊红东¹, 郑子扬¹, 孔祥玉¹

(1. 火箭军工程大学智控实验室, 710025, 西安;

2. 浙江大学流体动力基础件与机电系统全国重点实验室, 310058, 杭州)

摘要: 针对现有基于 Mamba 模型的装备剩余寿命预测方法中存在的卷积核单一固定、局部时序特征捕捉能力不足的问题,提出了一种采用多尺度 Mamba 架构的剩余寿命预测方法。该方法构建了多尺度 Mamba 与门控循环单元并行网络:多尺度 Mamba 通过多尺度卷积层与结构化状态空间模型协同作用,捕捉装备长期退化趋势;门控循环单元借助门控机制提取短时动态特征,实现了长短期特征互补。设计互补特征动态融合模块,通过动态门控生成权重对上述两类特征加权融合,有效抑制冗余信息并强化关键特征。利用全连接层完成退化特征映射与剩余寿命预测。在美国航空航天局的航空发动机数据集上验证,结果表明:所提方法的均方根误差优于主流模型,评分函数较最优基线模型降低 22%~73%;运行效率较最新的基于 Mamba 模型的方法提升 57.5%。所提多尺度 Mamba 架构为装备剩余寿命预测提供了一种兼具精度与效率的可行方案。

关键词: 剩余寿命预测;Mamba 模型;门控循环单元;多尺度卷积层;互补特征动态融合

中图分类号: TH17 **文献标志码:** A

DOI: 10.7652/xjtuxb202605015 **文章编号:** 0253-987X(2026)05-0153-11

Equipment Remaining Useful Life Prediction Method Using Multi-Scale Mamba Architecture

TIAN Congbao¹, WANG Zhaoqiang^{1,2}, HU Changhua¹, FAN Hongdong¹,
ZHENG Ziyang¹, KONG Xiangyu¹

(1. Laboratory of Intelligent Control, Rocket Force University of Engineering, Xi'an 710025, China; 2. State Key Laboratory of Fluid Power Components and Mechatronic Systems, Zhejiang University, Hangzhou 310058, China)

Abstract: To address the issues of fixed single convolution kernels and insufficient local temporal feature extraction in existing Mamba-based equipment remaining useful life (RUL) prediction methods, a novel RUL prediction approach based on a multi-scale Mamba architecture is proposed. A parallel network combining multi-scale Mamba and gated recurrent units (GRUs) was constructed. The multi-scale Mamba captures long-term degradation trends through the synergistic interaction of multi-scale convolutional layers and structured state-space models, while the GRUs extract short-term dynamic features via gating mechanisms, achieving complementary long-and short-term feature representation. A module for dynamic fusion of complementary features was designed to perform weighted fusion of these two types of features through dynamic gating weights, effectively suppressing redundant information and enhancing key features. Fully connected layers were then employed to map degradation features and predict RUL. Validation on the NASA's aircraft

收稿日期: 2025-06-20。 作者简介: 田从宝(2001—),男,硕士生;王兆强(通信作者),男,副教授,硕士生导师。 基金项目: 国家自然科学基金资助项目(62573424);陕西省自然科学基金基础研究计划资助项目(2025JC-QYXQ-038);流体动力基础件与机电系统全国重点实验室开放基金资助项目(GZKF-202430)。

网络出版时间: 2026-01-05

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20260104.1616.012>

engine dataset demonstrates that the proposed method achieves superior root mean square error compared to mainstream models, with the scoring function reduced by 22%—73% compared to the best baseline model. Additionally, it improves computational efficiency by 57.5% over the latest Mamba-based methods.

Keywords: remaining useful life prediction; Mamba model; gated recurrent unit; multiscale convolutional layer; dynamic fusion of complementary features

随着装备服役时间的增加,由于疲劳磨损、腐蚀、蠕变等原因,装备的性能不可避免地发生退化,装备一旦发生故障,常会造成巨大的人员和财产损失,尤其是在核电、航空航天、武器装备、高速列车等对可靠性、安全性要求较高的领域。作为保障装备安全可靠运行、降低故障发生率和维修保障成本的重要手段,故障预测与健康管理(PHM)技术已成为工业和学术界的研究热点^[1-4]。PHM技术大致可划分为剩余寿命(RUL)预测和健康管理两个环节,其中RUL预测可为装备健康管理提供基础,因此RUL预测被认为是PHM技术得以有效实施的关键^[5-6]。

当前装备RUL预测方法主要分为基于物理模型和数据驱动两类^[7-8]。基于物理模型的方法^[9]通过建立热力学方程、蠕变方程等机理模型描述性能退化,进而对装备RUL进行预测,依赖于对装备机理模型的准确构建,然而在实际中,受限于认知水平,通常难以准确建立复杂装备的机理数学模型。数据驱动方法可利用测量得到的反映装备健康状态的传感器数据构建装备RUL的统计学或机器学习模型,已成为装备RUL预测领域的主流方法^[10],又可进一步划分为统计数据驱动方法^[11-12]、传统机器学习方法^[13]和深度学习(DL)方法^[14]。

近年来,随着人工智能和大数据技术的发展,DL方法已成为装备RUL预测领域的前沿和热点^[15]。在诸多基于DL的装备RUL预测方法中,循环神经网络(RNN)及其变体,如长短期记忆(LSTM)网络、门控循环单元(GRU)等,受到国内外研究者的广泛关注^[16-18]。例如,Sun等针对小样本数据,提出了一种基于CNN-GRU的RUL预测方法,并用发动机数据进行验证,其中GRU能够捕捉发动机的退化趋势,有效地提升了RUL预测精度^[19]。尽管LSTM、GRU等RNN变体在一定程度上缓解了传统RNN模型的梯度消失或梯度爆炸问题,能够较好地学习装备性能退化数据之间的长距离依赖关系,然而在面对长时间序列时,仍然存在对长期依赖关系学习不充分的问题^[20],为此,Transformer网络利用自注意力机制,能够更有效地聚焦于关键特征并捕捉时序数据中的长期依赖关系,可以有效提升RUL预测精度,已成为装

备RUL预测领域的研究热点^[21]。例如,段佳俊等提出了一种结合多尺度卷积神经网络和Transformer的RUL预测模型,利用卷积核的多分辨率分析提升退化特征的表征能力,依靠Transformer进行全局特征提取来进行RUL预测^[22]。Kim等结合了自适应RUL重加权技术,使用Transformer进行多变量时间序列数据的特征提取,改善了数据不平衡问题^[23]。尽管Transformer可以更好地捕捉时序数据中的长期依赖关系,但由于自注意力机制的存在,该方法在装备RUL预测中尚存在计算复杂度高、推理速度慢等问题^[24]。

出于减小计算复杂度的考虑,Gu等在2023年提出了Mamba模型^[25],Mamba模型基于结构化状态空间模型(SSM),结合选择性扫描机制,在长序列建模中展现出线性时间复杂度优势,可以更高效地捕捉序列数据中的复杂依赖关系^[26-28]。在装备RUL预测领域,Shi首次将Mamba模型用于锂电池的RUL预测,Mamba模型可有效表征锂电池的退化规律,在提升计算效率的基础上,实现了预测精度的同步提升^[29]。Wang等构建了多变量Mamba模型与自适应奇异值分解的混合架构,通过联合优化时频域特征提升了RUL预测精度^[30]。Liu等基于Mamba模型开发了多模态时间神经网络,实现了锂电池多源传感器数据的深度特征融合和RUL预测^[31]。Liang等将Mamba模型应用于锂电池退化早期预警,通过构建双阶段特征提取机制突破了传统方法对完整寿命周期数据的依赖性^[32]。Huang等将Mamba模型融入编码器-解码器架构,突破了传统模型在处理长序列依赖问题的局限性,提升了锂电池RUL预测精度^[33]。Li等将锂电池电化学定律以微分方程的形式嵌入Mamba模型中,构建了物理信息驱动的Mamba网络架构,增强了Mamba模型的长序列数据处理效率,显著提升了锂电池RUL预测精度,增强了模型的可解释性^[34]。Yue等将刀具磨损物理信息融入Mamba模型,提出了一种数据-物理模型协同驱动的RUL预测方法,提高了刀具RUL预测精度^[35]。Li等在双向Mamba框架下,提出了一种基于双向Mamba与

LSTM 并行网络 (BiMamba-LSTM) 的航空发动机 RUL 预测方法,该方法可在保证一定预测精度的同时,有效提升运算速度^[36]。

虽然现有基于 Mamba 的 RUL 预测方法可以较好地捕捉装备性能退按时序数据中的长期依赖关系,并能显著降低模型的计算复杂度,但现有方法仍存在以下共性问题:①现有 Mamba 模型未能突破经典 Mamba 的限制,仍然使用单一固定卷积核,限制了模型对复杂时序关系的捕捉能力;②虽然 Mamba 模型善于捕捉时序数据的长期依赖关系,但对局部时序特征的捕捉能力不足,导致模型预测精度和泛化性较低。鉴于此,本文提出一种采用多尺度 Mamba (MsMamba) 架构的 RUL 预测方法。首先,设计了 MsMamba 模块;其次,构建 MsMamba 模块与 GRU 模块深度并联拓扑;接着,基于动态门控机制设计了互补特征动态融合 (DFCF) 模块;最后,利用 NASA 公开的 C-MAPSS 航空发动机仿真数据集^[37],对所提方法的有效性进行了验证。

本文的主要贡献概括如下:①对 Mamba 的一维卷积层进行了多尺度改进,并提出了相应的多尺度卷积融合机制,突破了单一固定卷积核的局限,强化了 Mamba 对复杂退化模式的特征捕捉能力;②通过构建多尺度 Mamba 模块与 GRU 模块的深度并联拓扑,实现长短期特征的互补性捕捉,提高了模型的泛化性;③基于动态门控机制设计了 DFCF 模块,使得模型能够通过训练自主调整权重,实现长期退化趋势与短时动态特征的加权融合,提高模型的预测性能和泛化能力。

1 采用 MsMamba 架构的剩余寿命预测方法

1.1 数据预处理

鉴于传感器信号存在噪声且量纲不统一,首先采用离散小波变换对原始信号进行降噪处理,以抑制高频噪声干扰。随后,利用最小-最大归一化方法将各传感器数据缩放至 $[0,1]$ 区间,以消除量纲差异对模型训练的影响,加速模型收敛过程。

为了充分挖掘多变量时间序列中的时序相关性,采用滑动时间窗方法构建训练样本。设定时间窗长度为 L ,滑动步长为1个时间步。通过在时间轴上滑动截取,将连续 L 个时间步的多维传感器数据组合成一个 L 行 N 列的二维矩阵 $\mathbf{X} \in \mathbb{R}^{L \times N}$,并将时间窗内最后一个时间步的 RUL 设为标签。该预处理方式不仅增加了样本数,还有助于模型捕捉局部退化模式。

1.2 MsMamba-GRU 并行网络

采用多尺度 Mamba 架构的剩余使用寿命预测方法如图 1 所示,MsMamba-GRU 并行网络主要由两个并行子模块组成:捕捉长期退化趋势的 MsMamba 模块和提取短时动态特征的 GRU 模块。图 1 中 SiLU 和 GELU 分别为 Sigmoid 线性激活函数和高斯误差线性激活函数,Softmax 为归一化指数激活函数;GRU 中 h_{t-1} 和 h_t 分别为前一时刻和当前时刻的隐藏状态, r_t 和 z_t 分别为重置门和更新门,用于对历史状态信息的保留与当前输入信息的更新。




图 1 采用 MsMamba 架构的剩余寿命预测方法

Fig. 1 Equipment remaining useful life prediction method using MsMamba architecture

Mamba 模型基于结构化状态空间模型,通过选择性扫描机制实现线性时间复杂度,在处理长序列时具有显著优势。然而,原始 Mamba 仅采用单一尺度卷积核,难以适配装备退化数据的多尺度时序特征,且容易遗漏关键局部时序特征。

为此,本文设计了 MsMamba 模块,其核心在于用多尺度卷积层替换了原始 Mamba 中的一维卷积。多尺度卷积层结构如图 2 所示,包含 3 个不同尺度的卷积核:小尺度卷积核提取高频波动特征(剔除残余噪声);中尺度卷积核提取退化周期模式;大尺度卷积核捕捉长期退化趋势。




图 2 多尺度卷积层

Fig. 2 Multi-scale convolutional layers

多尺度特征通过动态门控权重机制融合,该机制根据输入内容自动调整各尺度权重,计算式如下

$$\begin{cases} \mathbf{X}_{\text{out}} = \sum_k (g_k \text{Conv}_k(\mathbf{X}_{\text{in}})) \\ g_k = \text{Softmax}(\text{GlobalAvgPool}(\text{Conv}_k(\mathbf{X}_{\text{in}}))) \end{cases} \quad (1)$$

式中: k 为卷积核尺度; D 为状态维度; $\mathbf{X}_{\text{in}} \in \mathbb{R}^{L \times D}$ 为输入多尺度卷积层的样本序列; $\mathbf{X}_{\text{out}} \in \mathbb{R}^{L \times D}$ 为加权融合后输出的样本特征,作为后续 SSM 层的输入; g_k 为尺度 k 对应的动态门控权重,用于衡量该尺度特征的重要性; $\text{GlobalAvgPool}(\cdot)$ 为全局均值池化,用于压缩特征序列并提取全局统计信息; $\text{Softmax}(\cdot)$ 为归一化函数,确保所有尺度的权重之和为 1,实现竞争性选择。

在 MsMamba 模块中,多尺度卷积与 SSM 通过下述协同机制实现优势互补,共同提升模型性能。

一方面,二者构建级联特征处理链,通过双向特征传递实现动态互补。多尺度卷积输出包含 3 类局部特征,有效避免了单一卷积核导致的特征遗漏问题;这些特征的权重由动态门控权重机制生成,为 SSM 提供了多分辨率输入,从而提高了模型对不同退化阶段的适应能力。同时,这种互动是双向的,当 SSM 检测到长期退化趋势异常时,会通过动态更新离散化参数反作用于卷积层,使多尺度卷积能够依据该信息动态抑制无关特征,进一步优化特征质量。另一方面,二者通过时域覆盖互补实现退化过程的全周期感知。多尺度卷积聚焦于局部突变及周期模式,为 SSM 提供退化早期预警特征,而 SSM 侧重全寿命周期退化轨迹建模,可滤除卷积层引入的瞬态干扰特征。最终,多尺度卷积与 SSM 的协同互补,使模型能够拟合更复杂多样的函数形式,显著提升了模型的表达能力和泛化能力。

GRU 引入了更新门和重置门,在有效提取时间序列信息的同时,缓解了传统 RNN 的梯度消失问题。相较于 Mamba,GRU 网络在处理短序列和局部特征对齐方面具有特定优势。本文采用浅层 GRU 与 MsMamba 并联,旨在专门捕捉装备退化过程中的短时动态特征,实现与 MsMamba 提取的长期趋势特征的互补。

1.3 互补特征动态融合

为减小计算复杂度并保证较强的特征表达能力,本文设计了一个基于动态门控机制的互补特征动态融合模块,即 DFCF 模块。如图 1 所示,将 MsMamba 模块提取的长期退化趋势与 GRU 模块捕获的局部动态特征沿着最后一个维度进行拼接,拼接后的特征输入到多层感知机得到两组权重分数,对该权重分数进行 softmax 激活操作,得到两个动态权重,根据权重对两个分支输出进行加权求和实现动态融合,得到融合特征。这种动态门控机制能让模型根据输入数据灵活调整对两个分支的依赖,增强模型的表达能力和适应性。

经过 DFCF 模块动态融合后的特征被输入至全连接层。该全连接网络层包含两个隐藏层,通过线性变换结合非线性激活函数对融合特征进行降维映射,最终输出当前样本对应的 RUL 预测值。

1.4 计算复杂度分析

本文所提模型的计算复杂度主要来自于 MsMamba-GRU 并行网络和 DFCF 模块。

MsMamba 模块由输入投影层、多尺度卷积层、SSM 和输出投影层构成,输入投影层和输出投影层

的复杂度都是 $O(LD^2)$, 多尺度卷积层的复杂度为 $O(LDK)$, 其中 K 是卷积核的总尺寸, SSM 的计算复杂度为 $O(LD)$, 由于各部分串联, 且 K 远小于 D , 所以 MsMamba 模块的计算复杂度可近似为 $O(LD^2 + LD)$; GRU 模块的计算复杂度为 $O(LD^2)$; DFCF 模块的计算复杂度为 $O(LD^2)$ 。因此, 本文所提出的 MsMamba-GRU-DFCF 模型的总复杂度为 $O((n_1 + n_2 + 1)LD^2 + n_1LD)$, 其中, n_1 和 n_2 分别代表 MsMamba 和 GRU 的层数。相同输入的 Transformer 的计算复杂度为 $O(n_3(LD^2 + L^2D))$, n_3 为 Transformer 的层数。

现有的基于 Transformer 的装备 RUL 预测中, Transformer 层数通常设为 4~6, 输入序列长度为 24~30^[22]。为验证本文所提方法的计算复杂度, 将 Transformer 层数设为 4, 不同 L 下 Transformer 和本文所提方法的计算复杂度以及两种方法的计算复杂度的比见表 1。从表 1 中可以得到, Transformer 计算复杂度远高于本文所提方法, 并且随着输入时间序列的增长, 两者的比值逐渐增大。

表 1 本文方法和 Transformer 计算复杂度对比
Table 1 Comparison of computational complexity between the method in this paper and Transformer

L	计算复杂度		Transformer 与本文方法 计算复杂度的比
	本文方法	Transformer 方法	
24	2.25	19.46	8.64
25	2.34	20.30	8.66
26	2.43	21.13	8.67
27	2.53	21.98	8.68
28	2.62	22.82	8.69
29	2.72	23.66	8.70
30	2.81	24.51	8.71

2 实验验证

2.1 C-MAPSS 数据集描述

本研究采用 NASA 提供的 C-MAPSS 航空发动机仿真数据集对所提方法的有效性进行验证。该数据集包含 FD001~FD004 共 4 个子数据集, 用于模拟航空发动机在不同故障模式和运行工况下的退化过程。其中, FD001 和 FD003 子数据集对应的发动机均在单一工况下运行, 分别适配单一故障模式、双重混合故障模式。相比之下, FD002 和 FD004 的发动机运行于 6 种不同工况的动态变化环境中, 且同样涵盖上述两类故障模式。

2.2 评价指标

为全面评价模型性能, 本文采用均方根误差 (RMSE) 和评价分数 (Score) 作为检验模型预测精度的评价指标, 两类指标在衡量模型 RUL 预测性能方面具有互补作用。均方根误差作为衡量预测误差的常用指标, 能够客观反映模型总体预测误差水平, 而评价分数采用非对称惩罚机制, 对超前冒进的 RUL 预测施加更严厉的惩罚, 更加符合实际需求。

2.3 实验结果和分析

2.3.1 实验环境和超参数设置

本实验所采用的计算机配置为: AMD R9-7940HX 处理器、32 GB 内存, 搭载 NVIDIA RTX 4070 显卡 (8 GB 显存), 实验代码使用 Python 语言, 模型的训练以及优化基于 PyTorch 框架完成。实验采用的模型参数和训练超参数设置见表 2。

表 2 模型参数和训练超参数设置
Table 2 Model parameters and training hyperparameter settings

参数	数值			
	FD001	FD002	FD003	FD004
MsMamba 层数	3	2	3	2
GRU 层数	1	2	1	2
隐藏层维度	128	128	128	128
批量大小	128	128	128	512
学习率	0.001 0	0.001 0	0.001 0	0.000 5
权重衰减	0.000 1	0.000 1	0.000 1	0.000 1
时间窗长度	24	22	24	22
丢弃率	0.3	0.3	0.3	0.3

2.3.2 卷积核大小对预测结果的影响分析

本文通过 3 个不同尺度的卷积核提取退化信息, 需对卷积核组合情况进行对比分析, 以确定最优组合方案。不同卷积核组合下 FD001 子数据集的实验结果见表 3。根据表 3 的对比实验结果可以看出, 奇数尺度卷积核组合的预测性能全面优于偶数尺度卷积核组合。卷积核组合 [5, 7, 9] 下模型取得了最小的均方根误差和最优评价分数, 这显示不同尺度的卷积核组合对模型性能有较大影响。此外, 并非所有情况下卷积核尺度越大 (或越小), 模型性能就越好, 主要原因在于不同尺度的卷积核, 对装备退化时序特征的提取敏感程度存在差异。

表 3 不同卷积核尺度组合下 FD001 数据集预测结果

Table 3 Prediction results of the FD001 dataset under different convolution kernel scale combinations		
卷积核组合	均方根误差	评价分数
1,3,5	11.09	198.33
3,5,7	10.95	183.28
5,7,9	10.74	166.37
7,9,11	11.48	287.32
2,4,6	12.47	346.28
4,6,8	12.33	311.45
6,8,10	12.39	339.29
8,10,12	13.07	401.28

2.3.3 RUL 阈值上限对预测结果的影响分析

本研究利用分段线性函数对所提方法的训练样本进行 RUL 标注。人为设定发动机 RUL 阈值上限会明显影响模型预测性能。为了全面地探讨这些影响,在 FD001 子数据集上进行了一系列对比实验,不同 RUL 阈值上限情况下的预测结果见表 4。

表 4 不同 RUL 阈值上限下 FD001 数据集预测结果的对比

Table 4 Comparison of prediction results of FD001 dataset under different upper RUL thresholds		
RUL 阈值上限	均方根误差	评价分数
110	13.2	386.1
115	12.27	278.32
120	12.07	242.11
125	10.74	166.37
130	11.99	259.34

由表 4 可以看出,当 RUL 阈值上限为 125 时,

模型在 FD001 子数据集上取得最好的预测效果。当 RUL 阈值上限小于 125 时,随着 RUL 阈值上限的提高,预测误差逐渐减小,主要原因在于本文使用滑动时间窗制备样本,RUL 阈值上限越高,获得的样本数越大,而对于深度学习模型而言,通常样本数越大,模型训练越充分,预测误差也越小。当 RUL 阈值上限为 130 时,预测误差不降反增,主要原因在于,FD001 子数据集中第 39 号发动机的生命周期最大时长仅为 128 个时间步,将其 RUL 阈值上限设为 130,会引入错误的样本,错误的样本会影响模型的训练效果,降低模型的预测精度,并增大误差。

2.3.4 综合性能分析

图 3 给出了 C-MAPSS 数据集 4 个子数据集测试集中发动机剩余使用寿命的预测结果。可以看出,整体而言,预测曲线与真实值在变化趋势上基本一致,但预测误差呈现出明显的阶段性特征。按照剩余使用寿命数值范围划分,当剩余使用寿命为 80 及以上时,对应早期退化阶段,预测结果与真实值之间的偏差相对较大,最大误差约为 15~20;当剩余使用寿命介于 30~80 之间时,对应中期退化阶段,预测误差逐渐收敛,基本控制在±10 范围内;当剩余使用寿命低于 30 时,对应后期退化阶段,预测曲线与真实值高度一致。这种阶段性误差变化的主要原因在于:①早期阶段传感器信号变化微弱,导致模型难以捕捉初始退化特征;②训练样本分布不均衡(滑动时间窗生成的样本中,处于早期退化阶段的样本仅占总量的 28%),导致模型对早期退化状态学习不足,从而预测偏差较大。

为了进一步探索所建网络的预测精度,统计 4 个子数据集中所有发动机的 RUL 预测偏差如图 4 所示。由图 4 可知,4 个子数据集的 RUL 预测偏差均接近正态分布。大部分的偏差集中在[-10,10]区间内。




图 3 C-MAPSS 数据集测试集发动机 RUL 预测结果

Fig. 3 RUL prediction results of engines in the test set of the C-MAPSS dataset




图 4 C-MAPSS 数据集测试集发动机 RUL 预测误差
Fig. 4 C-MAPSS dataset test set engine RUL prediction bias

为了更直观地展示模型在发动机整个退化过程中的预测性能,图 5 分别从 FD001~FD004 测试集中选取了编号为 24、185、39、71 的发动机,绘制了其 RUL 预测值随运行时间变化的曲线。模型预测曲线

能够有效地跟踪真实 RUL 随运行时间的下降趋势。特别是在退化中后期,预测曲线通常能紧密跟随真实曲线的下降斜率,这证明了 MsMamba 模块在捕捉复杂退化模式方面的有效性,以及并行架构的整体优势。




图 5 典型发动机预测结果
Fig. 5 Typical engine prediction results

为了验证本文所提方法的计算效率,比较了不同方法处理相同长度序列时,运行相同周期花费的时间。由于 Mamba 的训练速度与推理速度远高于 Transformer^[25],所以本文不再比较所提方法与基于 Transformer 的 RUL 预测方法的运行速度。在保持隐藏层维度一致的前提下,比较了所提方法与 BiMamba-LSTM^[36]运行 100 个轮次的时间。所提方法的运行时间为 1 183 s,较 BiMamba-LSTM 运行时间(2 788 s)降低了 57.5%。这与两个方法的计算复杂度相吻合,所提方法的计算复杂度为

2.25×10^6 ,较 BiMamba-LSTM 的计算复杂度 4.533×10^6 降低了 50.3%。实验结果验证了本文所提方法具备高效的计算性能。

2.4 对比实验和消融实验

2.4.1 与其他剩余寿命预测模型的对比实验

为证明本文所提方法在发动机 RUL 预测中的先进性,将本文所提方法与文献[7]中常见的发动机 RUL 预测模型进行比较,对比模型主要包括 BiGRU、CNN-GRU、CNN-Transformer、BiMamba-LSTM 和 ASTGCN,对比结果见表 5。

表 5 与其他先进预测模型的实验结果对比

Table 5 Results of the comparative experiments with other advanced prediction models

模型	均方根误差				评价分数			
	FD001	FD002	FD003	FD004	FD001	FD002	FD003	FD004
BiGRU ^[38]	12.43	19.26	13.91	21.38	338.42	2264.81	401.77	3711.26
CNN-GRU ^[19]	13.48				248.61			
CNN-Transformer ^[26]	11.26	13.65	12.63	13.53	251.00	1 200.00	724.00	946.00
BiMamba-LSTM ^[36]	13.16	13.09	13.85	14.37	264.00	793.00	426.00	948.00
ASTGCN ^[39]	12.09	13.08	13.08	15.27	250.71	827.29	305.66	1 211.00
本文模型	10.74	13.16	11.28	13.46	166.37	618.71	195.36	763.29

注:加粗表示最优数据。

根据表 5 的实验结果对比,本文提出的 MsMamba-GRU-DFCF 模型展现出显著的性能优势。在 FD001 数据集上,该模型的均方根误差较现有最优的 CNN-Transformer 模型降低了 4.6%,预测评分较 CNN-Transformer 下降了 33.7%,验证了其在单一故障模式下的预测精度突破。在复杂度更高的 FD003 子数据集中,本方法优势更为突出,均方根误差较 CNN-Transformer 降低了 10.7%,而预测评分骤降 73%,凸显其对多故障模式的强适应性。在 FD002 数据集上,该模型评分较 BiMamba-LSTM 降低了 22.0%,较 ASTGCN 降低了 25.2%,虽均方根误差略高,但对冒进预测控制更强。在 FD004 数据集上,该模型均方根误差和评价分数都取得最小值,证明该模型对多故障与多工况耦合场景适应力强。

本文所提方法得到上述提升的主要原因在于所提出的 MsMamba-GRU-DFCF 模型通过多尺度特征提取,解决了传统 Mamba 对复杂模式捕捉能力不足的缺陷,并且 GRU 模块捕捉的短期动态特征与 MsMamba 建模的长期退化趋势形成互补,强化了模型对不同特征的提取能力。此外,DFCF 模块通过动态权重自适应融合特征,优于固定融合策略。

2.4.2 消融实验

为了定量评估所提方法中各模块的有效性,设计相应的消融实验进行验证,实验比较了基础 GRU 模型、基础 Mamba 模型、基础 MsMamba 模型、M1 模型 (MsMamba-GRU)、M2 模型 (Mamba-GRU-DFCF)以及本文所提模型。其中,M1 模型直接将 MsMamba 和 GRU 提取到的特征进行拼接。实验采用 FD001 和 FD003 子数据集进行验证,所有模型均保持相同的超参数设置(时间窗长度、批量大小、学习率等与表 2 一致)。消融实验的结果见表 6。

表 6 MsMamba-GRU-DFCF 和基线模型的实验结果对比

Table 6 Comparison of results between MsMamba-GRU-DFCF and baseline models

模型	均方根误差		评价分数	
	FD001	FD003	FD001	FD003
GRU	16.28	15.89	552.41	630.87
Mamba	15.94	16.29	501.35	476.66
MsMamba	13.49	13.55	339.22	439.68
M1	12.33	12.94	216.58	378.24
M2	11.47	11.84	217.37	270.47
本文模型	10.74	11.28	166.37	195.36

注:加粗表示最优数据。

从表 6 中可以看出,本文所提 MsMamba-GRU-DFCF 模型中的各关键组件均发挥了重要作用。将原始 Mamba 的单尺度卷积替换为多尺度卷积后,MsMamba 在 FD001 上使均方根误差由 15.94 降至 13.49,降幅达 15.4%,评价分数由 501.35 降至 339.22,降幅达 32.3%,FD003 数据集亦呈现一致的性能提升趋势,证明对于 Mamba 模型进行多尺度改进能显著增强 Mamba 模型对复杂退化模式的刻画能力。继而并联 GRU(M1),均方根误差进一步降至 12.33,降幅为 8.6%,评价分数降至 216.58,降幅为 36.1%,表明长短期特征互补可抑制预测误差。引入 DFCF 动态加权后,完整模型的均方根误差与评价分数分别收敛至 10.74 与 166.37,相对 M1 模型再降低了 13.0%与 23.2%,验证了 DFCF 模块在抑制冗余信息、强化主导特征权重方面的必要性。与仅含原始 Mamba 的 M2 模型相比,均方根误差与评价分数分别再降 6.7%与 23.5%,进一步证明了 MsMamba 对于复杂退化模式有良好的捕捉能力。综上,各组件逐级叠加,最终使 FD001、FD003 数据集的均方根误差较基线 Mamba 模型分别降低了 32.6%、29.0%,评价分数分别降低了 66.8%、59.0%,充分证明了本文所提方法的有效性。

上述实验结果表明,本文所提基于 Mamba 的多尺度特征提取、长短周期特征互补与动态融合方法,可有效降低 RUL 预测误差,提升航空发动机 RUL 预测精度。

2.5 模块可解释性分析

为验证 DFCF 模块“动态调整关注焦点”的核心功能,增强模块的可解释性,本节选取 FD001 子数据集 24 号发动机作为典型样本开展可视化分析,通过动态权重分布与时序响应曲线,揭示 MsMamba 与 GRU 模块在不同生命周期阶段的特征差异与演化机制,阐明 DFCF 模块的动态融合策略。选取 FD001 子数据集 24 号发动机作为典型样本,主要原因在于该样本数据完整覆盖退化早期、中期及晚期 3 个阶段,且前文已验证所提方法可以较好地捕捉不同退化阶段的特征融合规律,从而实现 RUL 的准确预测。

2.5.1 DFCF 动态权重分布

DFCF 模块基于动态门控机制,通过多层感知机生成的动态权重,反映了模型对长期退化趋势与短时动态特征的关注程度。图 6 给出了 24 号发动机的 RUL 与模型权重变化。




图 6 FD001 子数据集 24 号发动机 MsMamba 与 GRU 模块动态权重分布

Fig. 6 Dynamic weight distribution of MsMamba and GRU modules for engine No. 24 in the FD001 dataset

如图 6 所示,在退化早期,发动机退化特征微弱,传感器信号以短时动态波动为主(含工况瞬时波动、微弱噪声干扰)。此时 GRU 权重显著高于 MsMamba 权重,表明 DFCF 模块更关注 GRU 捕捉的短时动态特征,以提取早期微弱的瞬态退化信号。在退化中期,退化趋势逐渐显现,长期趋势与短时波动共同作用。MsMamba 与 GRU 权重趋于平衡,体现 DFCF 模块对长短期两类特征的协同关注,既能兼顾退化趋势的持续性又能保持对局部波动的敏感性。在退化晚期,性能退化加速,长期趋势主导失效过程。MsMamba 模块权重进一步提升,表明 DFCF 模块侧重 MsMamba 提取的长期退化趋势,以捕捉失效前的加速退化规律。

2.5.2 MsMamba 与 GRU 的时序响应特征

为进一步揭示特征融合的物理意义,图 7 给出了 24 号发动机的 MsMamba 与 GRU 特征均值时序响应。




图 7 FD001 子数据集 24 号发动机 MsMamba 与 GRU 特征均值时序响应曲线

Fig. 7 Time response curves of feature mean for MsMamba and GRU modules in engine No. 24 of the FD001 dataset

从图 7 中可以看出,GRU 特征均值稳定性较强,退化早期基本维持在 0.15~0.175 区间内,表明 GRU 提取的是相对稳定的特征以及与短时动态强相关的特征(如瞬时负载变化、小故障引发的信号波动),这些特征在早期更加显著,而退化晚期因退化趋势变大而被覆盖,重要性降低。MsMamba 特征均值退化早期波动较大,处于 0.05~0.08 区间,表明 MsMamba 侧重提取长期时序特征,与装备整体退化趋势强相关(如性能缓慢下降的趋势、磨损累积的规律)。因退化早期退化趋势弱,这些特征不明显,导致在退化早期 MsMamba 的重要性远低于 GRU。MsMamba 特征均值在退化晚期大幅下降,由 0.05 降至接近 0,对应发动机临近失效时的性能骤降崩溃阶段,长期退化特征呈现极端变化。DFCF 模块实现了对长短期特征的动态加权,可根据不同退化阶段的特征重要性自适应调整权重,在退化早期侧重短时动态特征,中期兼顾长短期特征,晚期聚焦长期趋势,与发动机实际退化物理规律相吻合。权重变化规律与特征均值响应曲线,和传感器信号退化模式(早期微弱波动、中期平稳过渡、晚期加速衰减)高度吻合,捕捉的特征与装备健康状态关联性明确,有效提升了方法的可解释性。

3 结 论

本文针对现有基于 Mamba 的装备 RUL 预测方法存在的卷积核单一固定、局部时序特征捕捉能力不足等问题,提出了一种基于 MsMamba 的 RUL 预测方法。所提方法构建了 MsMamba 模块与 GRU 的并行拓扑网络,通过 MsMamba 模块捕捉长期退化趋势,同时利用 GRU 门控机制提取短时动态特征,形成长短期特征互补。进一步设计了 DFCF 模块,通过可学习的动态权重实现长期退化趋势与短时动态特征的自适应融合,显著增强了对发动机全生命周期退化模式的综合感知能力。基于 NASA 公开 C-MAPSS 发动机数据集开展多组实验验证。结果表明,模型的均方根误差优于 BiGRU、CNN-Transformer、BiMamba-LSTM 等主流模型;模型的评价分数较当前最优基线模型降幅达 22%~73%,在复杂工况与故障模式耦合场景中表现尤为突出。进一步地,DFCF 模块的可解释性分析结果表明,通过动态门控机制实现了特征融合的自适应调整。综上,本文所提方法在不同故障模式与工况下均展现出较高的预测精度、良好的模型泛化能力和可解释性,具有较好的实际应用潜力。

参考文献:

- [1] 李响, 徐宜销, 雷亚国, 等. 面向旋转机械装备的智能故障诊断通用基础模型研究 [J]. 西安交通大学学报, 2025, 59(7): 1-12.
LI Xiang, XU Yixiao, LEI Yaguo, et al. Research on general foundation model for intelligent fault diagnosis for rotating machinery [J]. Journal of Xi'an Jiaotong University, 2025, 59(7): 1-12.
- [2] ZHAO Xiaoli, YAO Jianyong, DENG Wenxiang, et al. Intelligent fault diagnosis of gearbox under variable working conditions with adaptive intraclass and inter-class convolutional neural network [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(9): 6339-6353.
- [3] ZHAO Xiaoli, HU Yuanhao, LIU Jiahui, et al. A novel intelligent multicross domain fault diagnosis of servo motor-bearing system based on domain generalized graph convolution autoencoder [J]. Structural Health Monitoring, 2025, 24(3): 1485-1499.
- [4] 王宇, 刘秋发, 彭一真. 非均匀监测条件下滚动轴承剩余寿命预测方法 [J]. 机械工程学报, 2023, 59(23): 96-104.
WANG Yu, LIU Qiufa, PENG Yizhen. A remaining useful life prediction approach with nonuniform monitoring conditions for rolling bearings [J]. Journal of Mechanical Engineering, 2023, 59(23): 96-104.
- [5] YANG Lei, LIAO Yuhe. An optimal dual data-driven framework for RUL prediction with uncertainty quantification [J]. IEEE Sensors Journal, 2025, 25(3): 4943-4957.
- [6] LI Penghua, WU Xiankui, GROSU R, et al. Applying neural network to health estimation and lifetime prediction of lithium-ion batteries [J]. IEEE Transactions on Transportation Electrification, 2025, 11(1): 4224-4248.
- [7] HACHEM H, VU H C, FOULADIRAD M. Different methods for RUL prediction considering sensor degradation [J]. Reliability Engineering & System Safety, 2024, 243: 109897.
- [8] KORDESTANI M, SAIF M, ORCHARD M E, et al. Failure prognosis and applications: a survey of recent literature [J]. IEEE Transactions on Reliability, 2021, 70(2): 728-748.
- [9] LEI Yaguo, LI Naipeng, GONTARZ S, et al. A model-based method for remaining useful life prediction of machinery [J]. IEEE Transactions on Reliability, 2016, 65(3): 1314-1326.
- [10] 张波, 胡昌华, 张浩, 等. 机器学习应用于随机退化设备剩余寿命预测的综述 [J]. 哈尔滨工程大学学报, 2024, 45(9): 1783-1790.
ZHANG Bo, HU Changhua, ZHANG Hao, et al. A review of remaining useful life prediction for stochastic degrading devices based on machine learning [J]. Journal of Harbin Engineering University, 2024, 45(9): 1783-1790.
- [11] SUN Lijun, LIANG Yuying, YAN Zaizai. Remaining useful life (RUL) prediction based on the bivariate two-phase nonlinear wiener degradation process [J]. Entropy, 2025, 27(4): 349.
- [12] RUAN Diwang, MA Lin, YANG Yingng, et al. Improvement by Monte Carlo for trajectory similarity-based RUL prediction [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-11.
- [13] PRATHIBA R V, SARAVANAN M, DAVID P W, et al. Machine learning-based direct estimation of remaining useful life (RUL) of IGBT using multi-precursor prognostics [J]. Electrical Engineering, 2025, 107(3): 3435-3449.
- [14] SHI Junren, GAO Jun, XIANG Sheng. Adaptively lightweight spatiotemporal information-extraction-operator-based DL method for aero-engine RUL prediction [J]. Sensors, 2023, 23(13): 6163.
- [15] WANG Guochao, WANG Yu, LI Baotong, et al. Probabilistic deep learning based on bayes by backprop for remaining useful life prognostics of consumer electronics [J]. IEEE Transactions on Consumer Electronics, 2025, 71(1): 839-848.
- [16] LIU Huihan, LI Yanmei, LUO Laijin, et al. A lithium-ion battery capacity and RUL prediction fusion method based on decomposition strategy and GRU [J]. Batteries, 2023, 9(6): 323.
- [17] YU Wennian, KIM I Y, MECHEFSKE C. Analysis of different RNN autoencoder variants for time series classification and machine prognostics [J]. Mechanical Systems and Signal Processing, 2021, 149: 107322.
- [18] VELASCO-GALLEGO C, LAZAKIS I. Mar-RUL: a remaining useful life prediction approach for fault prognostics of marine machinery [J]. Applied Ocean Research, 2023, 140: 103735.
- [19] SUN Shuhan, WANG Jiongqi, XIAO Yaqi, et al. Few-shot RUL prediction for engines based on CNN-GRU model [J]. Scientific Reports, 2024, 14(1): 16041.
- [20] JING Tao, ZHENG Pai, XIA Liqiao, et al. Transformer-based hierarchical latent space VAE for interpretable remaining useful life prediction [J]. Advanced Engineering Informatics, 2022, 54: 101781.

- [21] STERNHARZ G, ELHALWAGY A, KALGANOVA T. Data-efficient estimation of remaining useful life for machinery with a limited number of run-to-failure training sequences [J]. *IEEE Access*, 2022, 10: 129443-129464.
- [22] 段佳俊, 陆中, 王捷. 基于多尺度 CNN 和 Transformer 的航空发动机寿命预测方法 [J/OL]. *航空动力学报*. (2024-11-19) [2025-05-18]. <https://doi.org/10.13224/j.cnki.jasp.20240311>.
- DUAN Jiajun, LU Zhong, WANG Jie. Aero-engine life prediction method based on multi-scale CNN and transformer [J/OL]. *Journal of Aerospace Power*. (2024-11-19) [2025-05-18]. <https://doi.org/10.13224/j.cnki.jasp.20240311>.
- [23] KIM G, CHOI J G, LIM S. Using transformer and a reweighting technique to develop a remaining useful life estimation method for turbofan engines [J]. *Engineering Applications of Artificial Intelligence*, 2024, 133 (Part E): 108475.
- [24] WANG Zihan, KONG Fanheng, FENG Shi, et al. Is mamba effective for time series forecasting? [J]. *Neurocomputing*, 2025, 619: 129178.
- [25] GU A, DAO T. Mamba: linear-time sequence modeling with selective state spaces [EB/OL]. (2023-12-01) [2025-03-04]. <https://arXiv.org/abs/2312.00752>.
- [26] CHANG Yanshuo, LU Wei, XUE Feng, et al. Combining market-guided patterns and mamba for stock price prediction [J]. *Alexandria Engineering Journal*, 2025, 113: 287-293.
- [27] PAN Zhaojie, LI Chenyu, PLAZA A, et al. Hyper-spectral image classification with mamba [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 1-14.
- [28] MING Ri, CHEN Na, PENG Jiangtao, et al. Semantic tokenization-based mamba for hyperspectral image classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 4227-4241.
- [29] SHI Zhuangwei. MambaLithium: Selective state space model for remaining-useful-life, state-of-health, and state-of-charge estimation of lithium-ion batteries [EB/OL]. (2024-03-08) [2025-04-21]. <https://arXiv.org/abs/2403.05430>.
- [30] WANG Haikun, DAI Xiwei, CUI Liming, et al. A progressive learning residuals based on multivariate mamba and adaptive singular value decomposition method for remaining useful life prediction of lithium-ion batteries [J]. *Ionics*, 2025, 31(2): 1731-1746.
- [31] LIU Zeyu, DU Xiaofang, SHI Yuhai. Application of multi-modal temporal neural network based on enhanced sparrow optimization in lithium battery life prediction [J]. *Scientific Reports*, 2024, 14(1): 27476.
- [32] LIANG Yuqi, ZHAO Shuai. Early prediction of remaining useful life for Lithium-Ion batteries with the state space model [J]. *Energies*, 2024, 17(24): 6326.
- [33] HUANG Jiahui, LIU Lei, ZHAO Hongwei, et al. RUL-mamba: mamba-based remaining useful life prediction for lithium-ion batteries [J]. *Journal of Energy Storage*, 2025, 120: 116376.
- [34] LI Penghua, AO Zhesheng, HOU Jie, et al. Physics-informed mamba neural network with potential knowledge for state-of-charge estimation of lithium-ion batteries [J]. *Journal of Energy Storage*, 2025, 123: 116546.
- [35] YUE Caixu, QIN Yiyuan, LIU Xianli, et al. Data-physics collaborativige fusion prediction method for tool remaining useful life based on mamba state space and physical description [J]. *Journal of Manufacturing Systems*, 2025, 81: 1-15.
- [36] LI Min, ZHU Longxia, LUO Meiling, et al. Remaining useful life prediction of airplane engine based on bidirectional mamba and causal discovery [J]. *Sensors*, 2025, 25(11): 3429.
- [37] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation [C]//2008 International Conference on Prognostics and Health Management. Piscataway, NJ, USA: IEEE, 2008: 1-9.
- [38] 许丹阳, 尚洁, 蒋琛, 等. 基于自适应时空图卷积网络的航空发动机剩余寿命预测 [J]. *计算机集成制造系统*, 2025, 31(6): 2165-2177.
- XU Danyang, SHANG Jie, JIANG Chen, et al. Remaining useful life prediction of aero-engines based on adaptive spatial-temporal graph convolutional network [J]. *Computer Integrated Manufacturing Systems*, 2025, 31(6): 2165-2177.
- [39] AL-DULAIMI A, ZABIHI S, ASIF A, et al. NBLSTM: noisy and hybrid convolutional neural network and BLSTM-based deep architecture for remaining useful life estimation [J]. *Journal of Computing and Information Science in Engineering*, 2020, 20(2): 021012.

(编辑 武红江)