

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 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, 本文提出了一种基于多尺度 Mamba 的剩余寿命预测方法。该方法首先构建了多尺度 Mamba-GRU 并行网络: 多尺度 Mamba 模块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; GRU 模块借助门控机制提取短时动态特征, 实现了长短期特征互补。其次, 设计互补特征动态融合模块, 通过动态门控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。最后, 利用全连接层完成退化特征映射与剩余寿命预测。在 NASA C-MAPSS 航空发动机数据集上验证, 结果表明: 所提出方法的 RMSE 优于主流模型, Score 较最优基线模型降低 22%~73%; 模型运行效率较 Cau-Mamba-LSTM 提升 57.5%。综上, 该方法在不同故障与工况下均具备高预测精度、强泛化能力及高效计算性能, 可为装备剩余寿命预测提供有效技术方案, 具有显著的工程应用潜力。

关键词: 剩余寿命预测; 多尺度 Mamba; GRU; 多尺度特征提取; 互补特征动态融合

中图分类号: TH17 **文献标志码:** A

DOI: xx

文章编号: xx

Equipment remaining useful life prediction method based on multi-scale Mamba

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

(1. Laboratory of Intelligent Control, Rocket Force University of Engineering, 710025, Xi'an;

2. State Key Laboratory of Fluid Power Components and Mechatronic Systems, Zhejiang University, 310058, Hangzhou)

Abstract: To address the issues of a single fixed convolutional kernel and insufficient capability in capturing local temporal features existing in current Mamba-based equipment remaining useful life prediction methods, this paper proposes a remaining useful life prediction method based on multi-scale Mamba. Firstly, the method constructs a multi-scale Mamba-GRU parallel network: the multi-scale Mamba module captures the long-term degradation trends of equipment through the synergy between multi-scale convolutional layers and the structured state space model; the GRU module extracts short-term dynamic features by means of a gating mechanism, thereby achieving the complementarity of long-term and short-term features. Secondly, a dynamic fusion of complementary features module is designed to perform weighted fusion of the above two types of features via dynamic gating weights, which effectively suppresses redundant information and enhances key features. Finally, fully connected layers are used to complete the mapping of degradation features and remaining useful life prediction. Validations conducted on the NASA C-MAPSS aero-engine dataset show that: the RMSE of the proposed method outperforms that of mainstream models, and its Score is reduced by 22%–73% compared with the optimal baseline model; the operational efficiency of the model is improved by 57.5% in comparison with Cau-Mamba-LSTM. In summary, the proposed method exhibits high prediction accuracy, strong generalization capability, and efficient computational performance under different fault and operating conditions. It can provide an effective technical solution for equipment remaining useful life prediction and has significant potential for engineering applications.

Key words: Remaining useful life prediction; multi-scale Mamba; GRU; multiscale feature extraction; 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会发生退化, 装备一旦发生故障, 常常会造成巨大的人员和财产损失, 尤其是诸如核电、航空航天、武器装备、高速铁路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 (Prognostics and Health Management, PHM) 技术近年来已成为工

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 (Remaining Useful Life, 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和核心^[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^[78]。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, 该类方法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], 该方法又可进一步划分为统计数据驱动类方法^[11-12]、传统机器学习类方法^[13]和深度学习 (Deep learning, DL) 类方法等^[14]。

近年来, 随着人工智能和大数据技术的发展, DL 类方法已成为装备 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 (Recurrent neural network, RNN) 及其变体, 如长短期记忆 (Long short-term memory, LSTM) 网络、门控循环单元 (Gated recurrent unit, GRU) 等, 具有高效的时序建模能力, 已成为基于 DL 的装备 RUL 预测中的重要方法, 得到了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], 针对该问题, 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特征能力, 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, 该类方法在装备 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 12 月份提出了 Mamba 模型^[25], Mamba 模型通过结构化状态空间模型 (Space state model, SSM) 与选择性扫描机制, 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, 一经提出, 便得到了各行各业研究者的广泛关注^[26-28]。在装备 RUL 预测领域, Shi 首次将 Mamba 用于锂电池的 RUL 预测, Mamba 能够捕获锂电池的退化规律, 在提高计算效率的同时, 也提高了预测精度^[29]。Wang 等构建了多变量 Mamba 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 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 模块融入编码器-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, 显著提高了锂电池 RUL 预测精度和模型的可解释性^[34]。Yue 等将刀具磨损物理信息融入 Mamba, 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 Cau-BiMamba-LSTM 交互的航空发动机 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化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, 本文提出一种基于 MsMamba 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; 进一步, 基于动态门控机制设计了 DFCF 模块; 最后, 利用 NASA 提供的 C-MAPSS (Commercial modular aero-propulsion system simulation) 发动机公开数据集^[37]对所提出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限制, 提高了 Mamba 对复杂退化模式的捕捉能力; (2) 通过构建多尺度 Mamba (Multi-scale Mamba, MsMamba) 模块与 GRU 模块的深度并联拓扑, 实现长短期特征互补性捕捉, 提高了模型的泛化性; (3) 基于动态门控机制设计了互补特征动态融合 (Dynamic Fusion of Complementary Features, DFCF) 模块, 使得模型能够通过训练自行调整加权长期退化趋势与短时动态特征, 提高模型的预测性能和泛化能力。

1 基于 MsMamba 的剩余寿命预测方法

本文所提出的 MsMamba-GRU-DFCF 模型总体架构如图 1 所示, 主要包含以下三部分: MsMamba-GRU 并行网络、DFCF 模块和全连接层, 接下来进行具体介绍。




图1 MsMamba-GRU-DFCF 模型
Fig.1 MsMamba-GRU-DFCF model

1.1 MsMamba-GRU 并行网络

MsMamba 运用 SSM，有效地捕捉长序列中的相关信息，通过选择性地关注序列中的重要部分，忽略无关信息，从而在处理超长序列时能够更好地提取关键特征，提高建模的准确性，但 Mamba 模型本身没有专门针对局部特征的建模和对齐机制，对于短期的局部特征提取表现不佳。本文提出的 MsMamba-GRU 并行网络主要由两个子模块组成：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。

1.1.1 MsMamba 模块

在装备 RUL 预测领域，Mamba 模型基于 SSM，通过融合 RNN 与卷积神经网络（Convolutional neural networks, CNN）的优势，采用递归与卷积混合操作，将计算复杂度降低至线性级别，可显著提升装备性能退化数据处理效率。SSM 将退化数据表示为 $\mathbf{x}(t)$ 映射到隐藏状态 $\mathbf{h}(t) \in \mathbb{R}^{D \times L}$ ，并输出 $\mathbf{y}(t)$ 。该过程可以表示为如下线性常微分方程：

$$\mathbf{h}'(t) = \mathbf{A}\mathbf{h}(t) + \mathbf{B}\mathbf{x}(t) \quad (1)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{h}(t) \quad (2)$$

其中， D 表示状态维度的大小， L 表示退化数据长度， $\mathbf{h}'(t)$ 表示当前输入 $\mathbf{x}(t)$ 的隐藏状态， $\mathbf{h}(t)$ 表示上一时刻的隐藏状态， $\mathbf{A} \in \mathbb{R}^{D \times D}$ 表示状态矩阵， $\mathbf{B} \in \mathbb{R}^{D \times L}$ 和 $\mathbf{C} \in \mathbb{R}^{L \times D}$ 表示投影参数。

为适配离散的退化数据，Mamba 首先需对连续系统进行离散化，离散后的 SSM 结构如图 2 所示。具体来说，通过引入了一个时间尺度参数，并使用固定的离散化规则将连续参数 $\mathbf{A}$ 和 $\mathbf{B}$ 变换为离散参数 $\bar{\mathbf{A}}$ 和 $\bar{\mathbf{B}}$ 。常用的离散化规则是零阶保持（Zero-order hold, ZOH），其定义如下：

$$\bar{\mathbf{A}} = \exp(\Delta\mathbf{A}) \quad (3)$$

$$\bar{\mathbf{B}} = (\Delta\mathbf{A})^{-1}(\exp(\Delta\mathbf{A}) - \mathbf{I}) \cdot \Delta\mathbf{B} \quad (4)$$

其中， Δ 是一个时间尺度参数，其作用是将连续时间转换为离散时间步，从而使模型能够处理离散数据， $\mathbf{I}$ 表示单位矩阵。

$\mathbf{A}$ 和 $\mathbf{B}$ 离散化后，基于 SSM 的模型可以通过线性递归或全局卷积两种方式计算，训练时，模型通过全局卷积计算，推理时，通过线性递归计算。两种计算方式定义为：

$$\bar{\mathbf{K}} = (\mathbf{C}\bar{\mathbf{B}}, \mathbf{C}\bar{\mathbf{A}}\bar{\mathbf{B}}, \mathbf{C}\bar{\mathbf{A}}^2\bar{\mathbf{B}} \cdots \mathbf{C}\bar{\mathbf{A}}^{L-1}\bar{\mathbf{B}}) \quad (5)$$

$$\mathbf{y} = \bar{\mathbf{K}} * \mathbf{x} \quad (6)$$

$$\mathbf{h}_\tau = \bar{\mathbf{A}}\mathbf{h}_{\tau-1} + \bar{\mathbf{B}}\mathbf{x}_\tau \quad (7)$$

$$\mathbf{y}_\tau = \mathbf{C}\mathbf{h}_\tau \quad (8)$$

其中， L 和 $\bar{\mathbf{K}} \in \mathbb{R}^L$ 分别表示输入退化数据 $\mathbf{x}$ 和结构化卷积核的长度， τ 表示离散的时间步。




图2 离散后的 SSM 结构

Fig.2 SSM structure after discretization

Mamba 模块的结构如图 3 所示,核心组件是一维卷积层和选择性 SSM。一维卷积层用于提取局部窗口内的短期特征,能捕捉相邻时间步的局部模式;选择性 SSM 可动态建模序列的长期依赖关系。




图 3 Mamba 模块

Fig.3 Mamba Block

由于 SSM 在线性计算复杂度下具有不变特性,在推理过程中, A 、 B 、 C 均为不随输入变化的固定参数。Mamba 引入了选择机制,将离散化参数 $\bar{A}$ 和 $\bar{B}$ 转换为输入依赖的参数,从而在推理过程中根据输入序列和历史信息动态调整参数 $\bar{A}$ 和 $\bar{B}$ 。因此, Mamba 中的选择性 SSM 能够更灵活地处理输入信息,进而更有效地对复杂的时间信息进行建模。

Mamba 模块中只采用了单一尺度的卷积核。单一尺度卷积核具有以下不足:(1)单一尺度卷积核只能捕捉固定窗口内的局部特征,无法适应数据中多尺度的时序模式,模型可能遗漏关键特征,导致预测精度下降;(2)单一尺度的卷积需要堆叠多层才能扩大感受野,但会引入更高的计算复杂度和梯

度消失风险;(3)单一尺度的卷积核对所有输入位置使用相同的卷积操作,无法根据局部特征复杂度动态调整关注的尺度,模型灵活性不足,难以平衡不同阶段的特征重要性。

针对上述问题,本文对原始 Mamba 进行改进,设计了多尺度 Mamba 模块,即 MsMamba 模块。主要改进在于,用一个多尺度卷积层替换原始 Mamba 模块中一维卷积,以提升 Mamba 对复杂模式的捕捉能力。多尺度卷积层结构如图 4 所示:




图 4 多尺度卷积层

Fig.4 Multi-scale convolutional layers

多尺度卷积层共有三个不同尺度的卷积核,其中,小尺度卷积核提取短期高频波动,如传感器噪声或瞬时异常;中尺度卷积核提取中期周期模式,如装备正常运行的周期性振动;大尺度卷积核捕捉长期趋势,如部件磨损的累积效应。多尺度特征通过动态门控权重机制融合,该机制通过池化层和线性层将多尺度卷积输出的局部特征转换为全局统计量,作为权重计算的依据,多层感知机输出不同尺度的特征分配动态权重,使模型能根据输入内容自动选择主导尺度,提高了模型的泛化能力。动态门控权重机制如下:

$$\mathbf{x}_{\text{fused}} = \sum_k \left(\text{Conv1D}_k(\mathbf{x}_{\text{conv}}) \cdot \text{Softmax} \left(\text{Linear} \left(\frac{1}{L} \sum_{t=1}^L \text{Conv1D}_k(\mathbf{x}_{\text{conv}})^{(t)} \right) \right) \right) \quad (9)$$

其中, k 表示卷积核尺度, L 表示输入序列的长度, D 表示状态维度, $\mathbf{x}_{\text{conv}} \in \mathbb{R}^{L \times D}$ 表示输入卷积层的样本序列, $\mathbf{x}_{\text{fused}} \in \mathbb{R}^{L \times D}$ 表示融合后输出的样本特征, $\text{Conv1D}_k(\square)^{(t)}$ 表示 t 时刻,卷积核为 k 的一维卷

积特征值, $\frac{1}{L} \sum_{t=1}^L (\bullet)$ 表示全局均值池化, $\text{Softmax}(\text{Linear}(\bullet))$ 表示门控权重学习。

在 MsMamba 模块中,多尺度卷积与 SSM 通过如下协同机制实现互补,共同提升模型性能:(1)一方面,二者形成级联特征处理链,通过双向特征

传递实现动态互补。多尺度卷积输出包含三类局部特征,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,使多尺度卷积能够据此动态抑制无关特征,进一步优化特征质量。(2)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则侧重于全寿命周期退化轨迹建模,可过滤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。

1.1.2 GRU 模块

GRU 是源于 RNN 的一种网络架构。相较于传统 RNN 模型,GRU 不仅能提取时间序列信息,还能有效解决传统 RNN 中的梯度消失和梯度爆炸问题。GRU 的核心思想是引入门控机制,它包含更新门和重置门 2 个门控单元。这些门控单元控制信息在网络中的流动,使网络可以选择性地遗忘或者更新某些信息。这种机制使 GRU 可以更好地处理长期依赖关系,并减少需要训练的参数数量。GRU 计算公式如下:

$$r_t = \sigma(W_r h_{t-1} + U_r x_t) \quad (10)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (11)$$

$$\tilde{h}_t = \tanh(W_h + r_t \boxtimes U_h h_{t-1}) \quad (12)$$

$$h_t = z_t \boxtimes h_{t-1} + (1 - z_t) \boxtimes \tilde{h}_t \quad (13)$$

其中, r_t 是 t 时刻的重置门, z_t 是 t 时刻的更新门。 W_r 、 U_r 、 W_z 、 U_z 、 W_h 、 U_h 为权重矩阵; $\sigma(\cdot)$ 为 sigmoid 激活函数; $\tanh(\cdot)$ 为 tanh 激活函数。

GRU 的结构如图 5 所示。




图 5 GRU 的结构图

Fig.5 Structure of GRU

本文所提方法中,采用浅层 GRU,在实现对短

期动态特征的有效捕捉的同时,也保证了较低的计算复杂度。

1.2 DFCF 模块

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 6 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个权重分数,对这两个权重分数进行 softmax 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。图 6 中, X_{Mamba} 和 X_{GRU} 分别表示 Mamba 模块和 GRU 模块的输出。

1.3 全连接层

全连接层借助线性变换与非线性激活机制,可高效地挖掘输入特征和预测目标间的复杂关联模式。针对装备 RUL 预测任务,利用全连接层作为模型末端的输出层。该全连接层配备两个隐藏层,最终将特征空间映射至样本对应的 RUL 预测值。通过叠加多层全连接架构,模型得以逐层萃取输入特征里的高阶语义信息,强化对 RUL 预测任务的非线性建模能力,进而提升 RUL 预测的准确性与鲁棒性。以上所提出的整体模型设计架构兼顾了长期退化趋势捕捉与短期动态特征提取,因此,能够实现对装备 RUL 的高效预测。




Fig.6 DFCF module

1.4 MsMamba-GRU-DFCF 模型计算复杂度分析

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

由图 3 可知, MsMamba 模块由输入投影层、多尺度卷积层、SSM 和输出投影层构成, 当输入序列长度为 L , 模型状态维度设为 D 时, 输入投影层和输出投影层的复杂度都是 $O(L \times D^2)$, 多尺度卷积层的复杂度为 $O(L \times D \times K)$, 其中 K 是卷积核的总尺寸, SSM 的计算复杂度为 $O(L \times D)$, 由于各部分串联, 且 K 远小于 D , 所以 MsMamba 模块的计算复杂可近似为 $O(L \times D^2 + L \times D)$; GRU 模块的计算复杂度为 $O(L \times D^2)$; DFCF 模块的计算复杂度为 $O(L \times D^2)$ 。因此, 本文所提出的 MsMamba-GRU-DFCF 模型的总复杂度为 $O((n_1 + n_2 + 1)L \times D^2 + n_1 L \times D)$, 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 $O(n_3(L \times D^2 + L^2 \times D))$, 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 层, 输入序列长度为 24~30^[22]。为验证本文所提出方法的计算复杂度, 将 Transformer 层数设为 4, 表 1 给出了不同输入序列长度 L 下, Transformer 和本文所提方法的计算复杂度比值。从表 1 中可以看出, 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	本文方法 FLOPs	Transformer FLOPs	Trans/本文
24	2.252×10^6	19.464×10^6	8.64
25	2.346×10^6	20.301×10^6	8.66
26	2.439×10^6	21.139×10^6	8.67
27	2.533×10^6	21.980×10^6	8.68
28	2.627×10^6	22.823×10^6	8.69
29	2.721×10^6	23.668×10^6	8.70
30	2.815×10^6	24.515×10^6	8.71

1.5 基于 MsMamba 的装备剩余寿命预测算法

本文所提出的基于 MsMamba 的装备 RUL 预测方法可概括为算法 1, 主要步骤包括:

步骤 1: 对输入的装备状态监测序列进行预处理, 同时初始化模型参数, 为后续训练做好准备。

步骤 2: 使用 MsMamba-GRU 并行网络, 分别利用 SSM 与门控机制提取长期退化趋势 $\mathbf{X}_{\text{Mamba}}$ 和短时动态特征 $\mathbf{X}_{\text{GRU}}$ 。

步骤 3: 通过 DFCF 模块对提取到的长期退化趋势和短时动态特征进行动态加权融合, 得到融合特征 $\mathbf{X}_{\text{Combine}}$ 。

步骤 4: 通过全连接层实现特征 $\mathbf{X}_{\text{Combine}}$ 到标签的映射, 得到预测值 $\hat{y}$ 。

步骤 5: 在训练阶段, 通过均方误差损失函数计算预测值 $\hat{y}$ 与真实值 y 的误差, 并根据误差通过梯度下降法更新模型参数。

算法 1: 基于多尺度 Mamba 的装备剩余寿命预测算法

```

输入: 历史监测数据  $\mathcal{Z} = \{x_1, x_2, \dots, x_N\}$ , 标签  $y = \{y_1, y_2, \dots, y_N\}$ ,  $N$  为最大迭代次数
1 对  $\mathcal{Z}$  预处理
2 初始化网络参数  $\theta$ 
3 // MsMamba-GRU 并行网络
4 for each  $x_n \in \mathcal{Z}$  do
5      $x_{\text{Mamba}} \leftarrow$  MsMamba 模块
6      $x_{\text{GRU}} \leftarrow$  GRU 模块;
7 // DFCF 模块
8  $x_{\text{Combine}} \leftarrow$  DFCF ( $x_{\text{Mamba}}, x_{\text{GRU}}$ )
9 //RUL 预测回归模块
10  $f_1 \leftarrow \text{ReLU}(W_1 x_{\text{Combine}} + b_1)$ 
11  $f_2 \leftarrow \text{ReLU}(W_2 \text{Dropout}(f_1) + b_2)$ 
12  $\hat{y} \leftarrow W_3 \text{Dropout}(f_2) + b_3$ 
13 //损失计算和参数更新 (仅训练阶段)
14  $\mathcal{L} = \text{MSE}(y, \hat{y})$ 
15  $\theta \leftarrow \theta - \eta \nabla_{\theta} \mathcal{L}$ 
16 输出: RUL 预测值  $\hat{y}$ 

```

2 实验验证

接下来, 利用 NASA 提供的 C-MAPSS 公开数据集^[37]对本文所提出的基于 MsMamba 的装备 RUL 预测方法的可行性和有效性进行验证, 并进一步通过对比实验和消融实验验证本文所提出方法的先进性和优越性。

2.1 数据集描述

C-MAPSS 航空发动机退化数据集利用商用模块化航空动力仿真系统生成, 在数据生成的过程中, 发动机从健康状态启动, 随着运行时间的增加, 发动机逐渐退化, 直到完全失效, 即视为故障状态。C-MAPSS 数据集包含四个子数据集, 它们分别模拟了不同故障模式和运行条件下的发动机退化情况。具体而言, FD001 和 FD002 中的发动机呈现高压压缩机退化故障模式, 而 FD003 和 FD004 则涵盖了高压压缩机退化和风扇退化两种故障模式。此外, FD001 和 FD003 的发动机在单一运行条件下工作, 而 FD002 和 FD004 则在六种不同运行条件的动态变化中工作, 详细信息如表 2 所示。每条样本序列模

拟了一台发动机从正常运行至发生故障的完整过程, 记录了多种传感器参数和运行状态信息, 各监测传感器的物理含义如表 3 所示。

表 2 C-MAPSS 数据集基本信息

Table 2 Basic information of the C-MAPSS dataset

子数据集	FD001	FD002	FD003	FD004
运行条件	1	6	1	6
故障模式	1	1	2	2
训练集发动机数	100	260	100	248
测试集发动机数	100	259	100	249

表 3 监测传感器实际物理含义

Table 3 Actual physical meanings of monitoring sensors

序号	符号	物理含义	单位	趋势
S1	T2	风扇入口总温	°R	-
S2	T24	低压压缩机出口总温	°R	↑
S3	T30	高压压缩机出口总温	°R	↑
S4	T50	低压涡轮机出口总温	°R	↑
S5	P2	风扇入口压力	psia	-
S6	P15	外涵道总压	psia	-
S7	P30	高压压缩机出口总压	psia	↓
S8	Nf	风扇物理速度	rpm	↑
S9	Nc	核心机物理速度	rpm	↑
S10	epr	发动机压力比	-	-
S11	Ps30	高压压缩机出口静压	psia	↑
S12	phi	燃油流量与 Ps30 之比	pps/ psi	↓
S13	NRf	风扇修正速度	rpm	↑
S14	NRc	核心机修正速度	rpm	↑
S15	BPR	涵道比	-	↑
S16	farB	燃烧室燃气比	-	-
S17	htBleed	放气焓	-	↑
S18	Nf_dmd	风扇转速目标值	rpm	-
S19	PCNfR_d md	风扇转速的修正目标 值	rpm	-
S20	W31	高压涡轮机冷却剂流 量	lbm/s	↓
S21	W32	低压涡轮机冷却	lbm/s	↓

2.2 数据预处理

2.2.1 传感器选择、小波降噪与数据归一化

C-MAPSS 数据集使用 21 个传感器对发动机健康状态进行监测。这些传感器在单一运行条件下, 随着运行时间的推移呈现出不同的变化规律。能够发现有部分传感器信号在整个退化周期内的输出保持不变, 显然这些数值与 RUL 没有关联, 应当剔除。这里选取了剩余 14 个与设备性能退化相关的传感

器信号作为本文所提方法的输入信号。

在发动机实际运行过程中, 传感器采集到的信号通常会受到噪声影响, 为了减小噪声对 RUL 预测结果的影响, 本文采用离散小波变换 (Discrete Wavelet Transform, DWT) 对原始信号进行降噪处理, 离散小波变换如下式:

$$c_{j,k} = \int_{-\infty}^{\infty} f(t) \psi_{j,k}(t) dt = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{2^j}} \psi\left(\frac{t-k2^j}{2^j}\right) dt \quad (14)$$

$$f'(t) = \sum_j \sum_k c_{j,k} \cdot \psi_{j,k}(t) \quad (15)$$

其中, j 是尺度, k 是平移, $f(t)$ 是原始信号, $c_{j,k}$ 是离散小波变换后得到的系数, $\psi_{j,k}(t)$ 是离散小波基函数, $f'(t)$ 是重构后的信号。

由于发动机在不同工况下的退化特性复杂, 并且不同类型传感器的测量值存在明显差异, 考虑到不同传感器的数值范围和量纲差异较大, 若直接输入模型进行训练, 可能会导致训练过程中的梯度不稳定与收敛困难。为此, 本文对选定特征实施了最小-最大归一化处理, 将其缩放至 [0, 1] 区间, 归一化函数定义如下:

$$x^{i,j} = \frac{x^{i,j} - x_{\min}^j}{x_{\max}^j - x_{\min}^j} \quad (16)$$

其中, $x^{i,j}$ 代表第 i 个时间步长时第 j 个传感器的值, $x_{\max}^j$ 和 $x_{\min}^j$ 分别表示第 j 个传感器数据的最大值和最小值。

2.2.2 滑动时间窗处理

RUL 预测问题本质为多变量时间序列处理问题, 其中不同时间点上的传感器数据之间的相关性较为重要。本文采用滑动时间窗方法, 通过将多个时间点的数据组合在一起, 形成更高维度的特征向量, 借助于本文 MsMamba-GRU-DFCF 模型提取更丰富的特征, 从而提高模型的预测性能。同时使用滑动时间窗能够进一步降低噪声的影响, 提高模型的泛化能力。如图 7 所示, 传感器的历史监测数据被划分为多个时间窗口, 每个窗口的长度为 T , 滑动步长 S 为并作为模型的输入。每个时间窗口的数据 $\mathbf{X}_i \in \mathbb{R}^{T \times n}$, 其中 n 是特征维度。每个时间窗样本对应的 RUL 标签值是时间窗内最后一个时间步对应的 RUL 标签值。




图7 滑动时间窗训练样本生成

Fig.7 Generation of training samples using a sliding time window

2.2.3 剩余寿命标注

在 RUL 预测任务中,装备生命周期早期健康水平较高且退化特征较少,导致模型难以提取有意义的特征。文献[38]在研究中发现,使用分段函数处理训练标签可以在一定程度提高预测精度。如图 8 所示,该方法在原始线性退化函数基础上设定一个阈值上限,当 RUL 值超过此阈值时将其剪切为常数。业界普遍将阈值上限设为 110~130^[39],本文将阈值上限设定为 125,以提升模型在不同生命周期阶段的预测能力。




图8 分段函数处理 RUL 标签值

Fig.8 Processing RUL label values with a piecewise function

2.3 评价指标

为全面评价模型性能,本文采用均方根误差(Root mean square error, RMSE)和评价分数(Score)作为检验模型预测精度的评价指标,两者在衡量预测性能方面具有互补作用:RMSE 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 Score 采用非对称惩罚机制对冒进预测施加更严厉惩罚,更加符合实际工程需求。RMSE 和 Score 的定义式如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n d_i^2} \quad (17)$$

$$\text{Score} = \begin{cases} \frac{1}{n} \sum_{i=1}^n e^{\frac{d_i}{13}-1}, & d_i < 0 \\ \frac{1}{n} \sum_{i=1}^n e^{\frac{d_i}{10}-1}, & d_i \geq 0 \end{cases} \quad (18)$$

其中, $d_i = \hat{y}_i - y_i$ 表示第 i 个样本点的 RUL 的预测

值 $\hat{y}_i$ 和真实值 y_i 的差值, n 为样本总数。

2.4 实验结果和分析

2.4.1 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(32GB 内存)和 NVIDIA RTX 4070 显卡(8GB 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如表 4 所示。

表4 实验参数设置

Table 4 Experimental parameter settings

	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	0.001	0.001	0.0005
权重衰减	0.0001	0.0001	0.0001	0.0001
时间窗长度	24	22	24	22
丢弃率	0.3	0.3	0.3	0.3

2.4.2 卷积核大小对预测结果的影响分析

本文通过三个不同尺度的卷积核提取不同尺度下的退化信息,因此需对卷积核组合情况进行对比分析,以确定最优组合方案。表 5 给出了不同卷积核组合下,FD001 子数据集的实验结果。根据表 5 的对比实验结果,可以看出奇数核全面优于偶数核。为进一步探究不同卷积核组合对实验结果的影响,图 9 给出了实验结果随卷积核的变化情况。如图 9 所示,卷积核组合[5, 7, 9]的模型取得了最小的 RMSE 和 Score 值,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在处理退化特征时的敏感程度不同。

表5 不同卷积核大小组合的结果

Table 5 Results for different combinations of convolutional

kernel sizes		
卷积核	RMSE	Score
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




图 9 不同卷积核组合实验结果

Fig.9 Experimental results of different convolutional kernel combinations

2.4.3 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，表 6 给出不同 RUL 阈值上限情况下的预测结果。

表 6 不同 RUL 阈值上限下的 RUL 预测结果对比

Table 6 RUL prediction results for upper RUL thresholds

RUL 阈值上限	RMSE	Score
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 6 可以得到，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，获得的样本数量越大，而对于深度学习模型而言，通常样本数量越大，模型训练越充分，预测误差也会越小。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高只有 128，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，增大误差。

2.4.4 综合性能分析

图 10 详细展示了 C-MAPSS 数据集四个子数据集的测试集发动机 RUL 预测结果，其中，圆点标记的线条代表 RUL 真实值，方形标记的线条代表 RUL 预测值。从图中可观察到以下现象：整体上预测曲

线与真实值趋势吻合，但预测误差呈现明显的阶段性特征：在 $RUL \geq 80$ 周期的早期退化阶段，预测值普遍与真实值误差较大，最大偏差达 15-20 周期；在 $30 \text{ 周期} \leq RUL < 80$ 周期的中期阶段，预测偏差收敛至 ± 10 周期内；在 $RUL < 30$ 周期的后期阶段，预测曲线与真实值高度贴合。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（如图 7 滑动时间窗生成的样本中， $RUL > 80$ 的样本仅占总量 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，统计四个子集中所有发动机的 RUL 预测偏差如图 11 所示。由图 11 可知，四个子集的 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。

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 12 分别从 FD001-FD004 测试集中选取了编号 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（真实 $RUL < 80$ 左右），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。

为了验证本文所提方法的计算效率，本文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 Cau-Mamba-LSTM^[36]运行 100 个 epoch 的时间。所提方法的运行时间为 1183 秒，较 Cau-Mamba-LSTM 运行时间（2788 秒）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 2.252 MFLOPs, 较 Cau-Mamba-LSTM 的计算复杂度 4.533 MFLOPs 降低了 50.3%。实验结果证明了本

文所提方法的具有高效的计算效率。




图 10 C-MAPSS 数据集测试集发动机 RUL 预测结果

Fig.10 RUL prediction results of engines in the test set of the C-MAPSS dataset




图 11 C-MAPSS 数据集测试集发动机 RUL 预测偏差

Fig.11 C-MAPSS dataset test set engine RUL prediction bias




图 12 FD001-FD004 典型发动机预测结果

Fig.12 Typical engine prediction results

2.5 对比实验和消融实验

2.5.1 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, 接下来将本文所提出方法与文献中常见的发动机 RUL 预测模型进行比较, 对比模型主要包括 BiGRU、CNN-BiGRU、CNN-Transformer、Cau-BiMamba-LSTM 和 ASTGCN, 对比结果如表 7 所示, 其中粗体表示最优。

根据表 7 的对比实验结果, 本文提出的 MsMamba-GRU-DFCF 模型展现出显著性能优势。在 FD001 数据集上, 该模型的 RMSE 较现有最优的 CNN-Transformer 模型降低 4.6%, 预测评分较 CNN-Transformer 大幅下降 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 多故障场景中, 本方法优势更为突出: RMSE 较 CNN-Transformer 降低 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 Score 较 Cau-BiMamba-LSTM 降 22.0%, 较 ASTGCN 降 25.2%, 虽 RMSE 略高, 但对冒进预测控制更强。在 FD004 上, 该模型 RMSE 和 Score 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。

表 7 与其他先进预测模型的对比实验结果

Table 7 Results of the comparative experiments with other advanced prediction models

模型	FD001		FD002		FD003		FD004	
	RMSE	Score	RMSE	Score	RMSE	Score	RMSE	Score
BiGRU	12.43	338.42	19.26	2264.81	13.91	401.77	21.38	3711.26
CNN-GRU ^[19]	13.48	248.61	—	—	—	—	—	—
CNN-Transformer ^[26]	11.26	251	13.65	1200	12.63	724	13.53	946
Cau-BiMamba-LSTM ^[36]	13.16	264	13.09	793	13.85	426	14.37	948

ASTGCN ^[38]	12.09	250.71	13.08	827.29	827.29	305.66	15.27	1211.00
本文模型	10.74	166.37	13.16	618.71	11.28	195.36	13.46	763.29

2.5.2 消融实验

为了定量评估所提出方法中各模块的有效性，接下来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 Mamab 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 4 一致）。

表 8 MsMamba-GRU-DFCF 和基线模型的结果对比

Table 8 Comparison of results between MsMamba-GRU-DFCF and baseline models

模型	FD001		FD003	
	RMSE	Score	RMSE	Score
GRU	16.28	552.41	15.89	630.87
Mamba	15.94	501.35	16.29	476.66
MsMamba	13.49	339.22	13.55	439.68
M1	12.33	216.58	12.94	378.24
M2	11.47	217.37	11.84	270.47
本文模型	10.74	166.37	11.28	195.36

表 8 给出了消融实验的结果，从表 8 中可以看出，本文提出的 MsMamba-GRU-DFCF 模型中各关键组件均展现出显著贡献。将原始 Mamba 的单尺度卷积替换为多尺度卷积后，MsMamba 在 FD001 上使 RMSE 由 15.94 降至 13.49，降幅达 15.4%，Score 由 501.35 降至 339.22，降幅达 32.3%，FD003 亦呈现一致趋势，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），RMSE 进一步降至 12.33，降幅 8.6%，Score 降至 216.58，降幅 36.1%，表明长短期特征互补可显著抑制预测误差。引入 DFCF 动态加权后，完整模型的 RMSE 与 Score 分别收敛至 10.74 与 166.37，相对 M1 再降 4.8%与 23.2%，验证了 DFCF 在抑制冗余信息并强化主导特征方面的必要性。与仅含原始 Mamba 的 M2 相比，RMSE 与 Score 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 与 FD003 的 RMSE 和 Score 较基线 Mamba 分别降低 32.6%与 29.0%、66.8%与 59.0%，充分证明了本文所提方法的有效性。

通过以上实验结果可以看出，本文所提出的基于 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显著降低 RUL 预测误差，提升发动机 RUL 预测精度。

2.6 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，本节选取典型样本

（FD001 中发动机 24）进行可视化分析，通过动态权重分布与时序响应曲线，揭示 MsMamba 与 GRU 在不同生命周期的特征贡献规律，阐明 DFCF 模块的动态融合机制。这里选取 FD001 子数据集典型发动机样本（编号 24）的主要原因在于该发动机数据覆盖退化早期（RUL≥80 周期）、中期（30 周期≤RUL<80 周期）及晚期（RUL<30 周期）三个完整的阶段，且前文已验证所提出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。

2.6.1 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 13 给出了发动机 24 的 RUL 与模型权重变化。




图 13 MsMamba 与 GRU 的权重分布

Fig.13 Weight distribution of MsMamba and GRU

如图 13 所示，在退化早期，发动机退化特征微

弱, 传感器信号以短时波动 (如噪声、瞬时工况变化) 为主。此时 GRU 权重显著高于 MsMamba 权重, 表明 DFCF 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。两者权重趋于平衡, 体现 DFCF 对两类特征的协同关注, 兼顾退化趋势的持续性与局部波动的敏感性。在退化晚期, 性能退化加速, 长期趋势主导失效过程。MsMamba 权重进一步提高, 说明 DFCF 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。

2.6.2 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 14 给出了发动机 24 的 MsMamba 与 GRU 特征均值时序响应。




图 14 MsMamba 与 GRU 的时序响应特征

Fig.14 Temporal response characteristics of MsMamba and GRU

从图中可以看出, GRU 特征均值呈现显著的稳定性, 在退化早期基本维持在 0.15-0.175, 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 特征均值在退化早期波动较大, 处于 0.05-0.08 区间, 表明 MsMamba 提取的是长期特征以及与整体退化强相关的特征 (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降低, 从 0.05 降至接近 0, 对应发动机快失效时性能崩溃, 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, 根据退化阶段的特征显著性自适应调整权重, 早期侧重短时动态, 中期协同关注, 晚期聚焦长期趋势, 与发动机实际退化物理规律一致。权重变化与特征均值响应反映的传感器信号退化模式 (早期微弱波动、晚期加速衰减) 高度吻合, 捕

捉的特征与装备健康状态关联明确, 增强了方法的可解释性。

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。所提方法创新性地构建了 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自适应融合长期趋势与短时特征, 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。利用 C-MAPSS 发动机数据集对本文所提出方法进行了验证。结果表明, 模型的 RMSE 优于 BiGRU、CNN-Transformer、Cau-BiMamba-LSTM 等主流模型; 模型的预测评分 Score 较最优基线模型降低 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显示, 其通过动态门控机制实现了特征融合的自适应调整。综上, 本文所提出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, 李熹伟, 李乃鹏, 杨彬. 面向旋转机械装备的智能故障诊断通用基础模型研究[J/OL]. 西安交通大学学报, <https://link.cnki.net/urlid/61.1069.T.20250102.0812.003>.
- [2] LI Xiang, XU Yixiao, LEI Yaguo, et al. Research on a General Basic Model for Intelligent Fault Diagnosis of Rotating Machinery and Equipment[EB/OL]. [2025-01-02]. <https://link.cnki.net/urlid/61.1069.T.20250102.0812.003>.
- [3] ZHAO X, YAO J, DENG W, et al. Intelligent fault diagnosis of gearbox under variable working conditions with adaptive intraclass and interclass convolutional neural network [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 34 (9): 6339-6353.
- [4] ZHAO X, HU Y, LIU J, 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..
- [5] 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.
- [6] WANG Yu, LIU Qiufa, PENG Yizhen. Remaining Life Prediction Method of Rolling Bearings Under Non-uniform Monitoring Conditions [J]. Journal of Mechanical Engineering, 2023, 59 (23): 96-104.
- [7] YANG L, LIAO Y. An optimal dual data-driven framework for RUL prediction with uncertainty quantification[J]. IEEE Sensors Journal, 2025, 25(3): 4943-4957.
- [8] LI P, WU X, RADU G, 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, 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*, 2019, 70(2): 728-748.
- [9] LEI Y, LI N, LIN J, 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(09): 1783-1790.
- ZHANG Bo, HU Changhua, ZHANG Hao, et al. Review of Machine Learning Applied to Remaining Life Prediction of Stochastically Degrading Equipment [J]. *Journal of Harbin Engineering University*, 2024, 45 (09): 1783-1790.
- [11] SUN L, LIANG Y, YAN Z. Remaining useful life (RUL) prediction based on the bivariate two-phase nonlinear Wiener Degradation Process [J]. *Entropy*, 2025, 27(4): 349.
- [12] RUAN D, LIN M, YANG Y, 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 J, GAO J, XIANG S. Adaptively Lightweight spatiotemporal information-extraction-operator-based DL method for Aero-Engine RUL prediction[J]. *Sensors*, 2023, 23(13): 6163.
- [15] WANG G C, WANG Y, LI B T, 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 H, LI Y, LUO L, 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 W, 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. *Applied Ocean Research*. 2023, 140: 103735.
- [19] SUN S, WANG J, XIAO Y, et al. Few-shot RUL prediction for engines based on CNN-GRU model *Scientific Reports*, 2024, 14(1): 16041.
- [20] JING T, ZHENG P, XIA L, et al. Transformer-based hierarchical latent space VAE for interpretable remaining useful life prediction [J]. *Advanced Engineering Informatics*, 2022, 54: 101781.
- [21] TERNHARZ 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]. *航空动力学报*, 2025, 1-12.
- DUAN Jiajun, LU Zhong, WANG Jie. Aeroengine Life Prediction Method Based on Multi-scale CNN and Transformer [J]. *Journal of Aerospace Power*, 2025, 1-12.
- [23] KIM G, CHOI J, 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: 108475.
- [24] WANG Z, KONG F, FENG S, 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, 2023, arXiv preprint arXiv: 2312.00752.
- [26] CHANG Y, LU W, XUE F, et al. Combining market-guided patterns and mamba for stock price prediction [J]. *Alexandria Engineering Journal*, 2025, 113: 287-93.
- [27] PAN Z, LI C, PLAZA A, et al. Hyperspectral Image Classification with Mamba [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 63.
- [28] MING R, CHEN N, PENG J, 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 Z. MambaLithium: Selective state space model for remaining-useful-life, state-of-health, and state-of-charge estimation of lithium-ion batteries. arxiv preprint arxiv: 2403.05430. 2024 Mar 8.
- [30] WANG H, DAI X, CUI L, 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 Z, DU X, SHI Y. 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 Y, ZHAO S. Early Prediction of Remaining Useful Life for Lithium-Ion Batteries with the State Space Model [J]. *Energies*, 2024, 17(24): 6326.
- [33] HUANG J, LIU L, ZHAO H, et al. RUL-Mamba: Mamba-based remaining useful life prediction for lithium-ion batteries. *Journal of Energy Storage*. 2025, 120: 116376.
- [34] LI P, AO Z, HOU J, 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 C, QIN Y, LIU X, et al. Data-physics collaborative 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, M, ZHU L, LUO M, et al. Remaining useful life prediction of airplane engine based on bidirectional Mamba and causal discovery. *Sensors* 2025, 25, 3429. <https://doi.org/10.3390/s25113429>.
- [37] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation [C]. *Proceedings of the International Conference on Prognostics and Health Management*. Denver, CO, USA, 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/OL]. *计算机集成制造系统*, 1-22[2025-06-15]. <https://doi.org/10.13196/j.cims.2024.0433>.
- XU Danyang, SHANG Jie, JIANG Chen, et al. Research on Remaining Life Prediction of Aero-engines Based on

- Adaptive Spatio-temporal Graph Convolutional Network[EB/OL]. [2025-06-15]. <https://doi.org/10.13196/j.cims.2024.0433>.
- [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.