

DOI: 10.20189/j.cnki.CN/61-1527/E.202504002

面向多传感器耦合数据健康指标构建的装备 剩余寿命预测方法

成心怡, 郑建飞, 张 琪, 裴 洪, 姜 蕾
(火箭军工程大学, 西安 710025)

摘 要: 针对存在强耦合关系的多元传感器数据健康指标 (health index, HI) 难以构建而导致装备剩余寿命 (remaining useful life, RUL) 预测精度低的问题, 提出一种动态自适应传感器筛选机制与张量表示的 HI 构建方法, 并使用融合注意力机制双向长短期记忆 (attention-bidirectional long short-term memory, At-Bi-LSTM) 网络的预测框架实现了对多传感器装备的 RUL 精准预测。首先, 建立了动态自适应传感器筛选模型, 通过混合相似度度量和层次聚类实现特征分组, 并结合趋势强度指标与滑动方差比来构建双重过滤机制, 自适应筛选出与退化相关性高的关键传感器; 然后, 提出三阶张量 HI 构建方法, 并采用 Tucker 分解对时间-窗口-传感器三维数据进行解耦, 通过核心张量特征融合生成复合 HI, 进一步运用 At-Bi-LSTM 网络架构引入蒙特卡洛 Dropout 实现不确定性量化; 最后, 通过 C-MAPSS 数据集的实例验证了所提方法的有效性, 并通过模块化分析证明了动态特征筛选机制能够大幅提升预测结果的稳定性, 表明张量表示的 HI 构建方法对模型预测性能提升贡献显著。

关键词: 剩余寿命预测; 动态特征筛选; 张量表示; 健康指标构建; 不确定量化

中图分类号: V240.2

文献标志码: A

文章编号: 2097-2741(2025)04-011-11

Remaining Useful Life Prediction of Equipment Based on Health Index Construction from Multi-Sensor Coupled Data

CHENG Xinyi, ZHENG Jianfei, ZHANG Qi,
PEI Hong, JIANG Lei
(Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: A dynamic adaptive sensor screening mechanism and tensor-representation health index (HI) construction method was proposed to address the issue of low prediction accuracy in remaining useful life (RUL) prediction caused by difficulties in constructing HIs from strongly coupled multi-sensor data. Furthermore, an attention-bidirectional long short-term memory (At-

收稿日期: 2025-04-30

修回日期: 2025-05-13

录用日期: 2025-05-30

基金项目: 国家自然科学基金 (62373369, 62373368, 62233017); 中国博士后面上基金 (2023M734286);
陕西省科协青年人才托举计划 (20230127)

第一作者: 成心怡 (2001—), 女, 硕士研究生, 主要从事基于深度学习的设备寿命预测研究。E-mail: 13992593852@163.com

引用格式: 成心怡, 郑建飞, 张琪, 等. 面向多传感器耦合数据健康指标构建的装备剩余寿命预测方法[J]. 火箭军工程大学学报, 2025, 39 (4): 11-21. CHENG Xinyi, ZHENG Jianfei, ZHANG Qi, et al. Remaining useful life prediction of equipment based on health index construction from multi-sensor coupled data[J]. Journal of Rocket Force University of Engineering, 2025, 39 (4): 11-21.

Bi-LSTM)-based prediction framework was employed to enable accurate RUL prediction for multi-sensor equipment. First, a dynamic adaptive sensor screening model was developed, that performs feature grouping through hybrid similarity measurement and hierarchical clustering. A dual-filtering mechanism was then constructed by integrating trend strength indicators and the sliding variance ratio to adaptively screen key sensors with high degradation relevance. Subsequently, a third-order tensor HI construction method was proposed, and Tucker decomposition was applied to decouple the three-dimensional data comprising time, window and sensor. A composite HI was generated through the fusion of core tensor features, and further uncertainty quantification was achieved by introducing Monte Carlo Dropout using the At-Bi-LSTM network architecture. Finally, the effectiveness of the proposed method was validated using the C-MAPSS dataset. A modular analysis confirmed that the dynamic feature screening mechanism significantly enhanced the stability of the prediction results, and the tensor-representation HI construction method made a notable contribution to improving the model's prediction performance.

KEYWORDS: remaining useful life prediction; dynamic feature screening; tensor representation; health index construction; uncertainty quantification

随着航空航天与武器装备技术的快速发展,系统复杂性不断提升,对装备运行的安全性、可靠性和维护效率等提出了更高要求^[1]。传统的定期检修方式已难以适应现代高频次、高强度的任务需求,容易造成维护过度、成本上升以及不必要的停机检修^[2-3]。预测与健康管理(prognostics and health management, PHM)作为保障装备全寿命周期可靠运行的关键技术,能够通过对关键部件运行状态的监测与评估,实现故障预测与剩余寿命(remaining useful life, RUL)预测,有力支撑基于状态的维修决策^[4]。因此,准确的RUL预测方法能够优化维护策略,降低运营成本,并确保装备安全^[5]。目前,针对RUL预测的研究方法大致可以分为3类:基于物理建模的方法、数据驱动方法和物理-数据融合型混合方法^[6]。基于物理的方法通常依赖于准确的物理模型以刻画系统退化过程,虽具备良好的可解释性,但难以适应复杂多变的实际工况。数据驱动方法则利用传感器监测数据进行建模,无需先验物理知识,具备建模灵活、适应性强等优势,尤其在复杂装备和高维数据场景下展现出巨大的应用潜力。随着深度学习等人工智能技术的发展,数据驱动方法在RUL预测领域中已成为研究的主流方向^[7]。此外,近年来也有部分研究人员尝试将物理建模与数据驱动方法相结合,提出了物理-数据融合的混合建模思路,如在深度学习模型中引入物理约束或物理一致性损失函数,以提升预测的可靠性与可解释性,这类方法为RUL预测提供新的思路,但在

实际应用中仍面临建模复杂且通用性不强等挑战。

以航空发动机为代表的多传感器复杂装备在运行过程中会产生大量高维数据^[8]。这些数据来自于不同传感器,记录了发动机在各个操作阶段的详细信息,如温度、压力、振动、转速等。多传感器的输出数据具有高维度、强耦合、非线性等特点,使得传统的基于单一传感器的分析方法无法有效捕捉发动机退化的复杂模式^[9],依赖单一传感器的特征提取和分析方法容易导致误诊断和误预测。当前,基于多传感器数据的分析方法成为解决此类问题的重要途径^[10]。例如,Ghorbani等^[11]提出的线性维纳过程为多源数据融合提供了有效的解决方案,该方法在特定场景下展现出良好的特征提取能力;Mustaffa等^[12]通过智能优化算法构建的特征选择机制,为高维数据处理提供了新的技术路径;Li等^[13]对14维发动机测量数据进行归一化后,将其直接输入到深度卷积神经网络(convolutional neural networks, CNN)中,从而实现了对RUL的准确预测;Al-Dulaimi等^[14]从发动机测量数据中删除不变数据,然后将剩余数据输入到由长短期记忆网络(long short-term memory, LSTM)和CNN组成的并行网络中来预测其RUL;Zhou等^[15]提出一种基于多尺度特征融合与并行学习的综合框架来预测发动机的RUL,取得了较好的效果。然而,上述方法虽然成功实现了对航空发动机的RUL预测,但均需依赖人工进行特征提取,对于如何实现特征自主提取的问题则有待进一步探索。

另外, 在多传感器健康指标 (health index, HI) 构建的过程中, 不同传感器之间的关联性常常会导致特征冗余和信息遮蔽现象^[16]。特征冗余指的是不同传感器之间可能提供相同或相似的信息, 不仅会增加数据处理的复杂性, 还会对模型的训练造成干扰; 信息遮蔽则是指某些关键的退化信息可能会被其他传感器的数据所掩盖, 导致预测模型无法准确捕捉到待评估对象的退化趋势, 进而会加剧 RUL 预测的误差。当前, 主流的特征选择策略往往依赖于人工经验而缺乏自适应机制, 常用的静态筛选或基于先验知识的方法难以适应复杂工况和非平稳环境下特征表达能力的动态变化。同时, 高维多源数据中存在的强耦合和冗余现象, 不仅进一步加剧信息遮蔽问题, 也使得关键信息难以被充分挖掘和提取, 进而影响到 HI 构建的准确性与稳定性^[17]。对此, Peng 等^[18]利用主成分分析 (principal component analysis, PCA) 法对原始监测数据进行降维, 并使用距离相似性和空间相似性构建刀具的 HI。传统的 PCA 方法虽然有效, 但其无法处理数据之间的非线性关系, 并且当数据量较大时, PCA 的性能表现较为一般。牟含笑等^[19]通过连续深度置信网络 (continuous deep belief network, CDBN) 构建 HI 来预测多元退化设备的 RUL, 并得到 RUL 的概率密度函数 (probability density function, PDF)。然而, 在高维强耦合数据中, 如何构建能准确表征发动机退化过程且保留关键信息的 HI, 仍是 RUL 预测亟需解决的难题。

鉴于此, 本文提出动态自适应传感器筛选与张量表示的 HI 构建方法, 实现了对关键特征的提取与 HI 构建的优化。同时, 进一步融合注意力机制双向长短期记忆网络 (attention-bidirectional long short-term memory, At-Bi-LSTM) 预测模型与蒙特卡洛 Dropout (Monte Carlo Dropout, MC Dropout) 技术, 实现了 RUL 预测中不确定性的量化与预测性能的提升。

1 健康指标构建

高质量 HI 可准确反映装备从正常到失效的退化过程, 为 RUL 建模提供坚实基础, 其具体实现流程如图 1 所示。首先, 对采集到的多通道传感器数据进行归一化与标准化等预处理操作, 并通过互信息 (mutual information, MI) 与动态时间规整 (dynamic time warping, DTW) 等混合相似度量方法, 对传感器通道进行 Ward 层次聚类与趋势强度指数 (trend strength index, TSI) 排序, 筛选出与退化过程高度相关的关键传感器信号; 然后, 基于选出的通道数据构建张量表示, 并采用 Tucker 分解提取多维融合特征, 从而构建出具有良好单调性和趋势性的健康指标; 最后, 引入 MC Dropout 机制的 At-Bi-LSTM 模型进行剩余寿命预测, 利用训练集进行 RUL 点估计, 并通过蒙特卡洛采样在测试阶段实现区间估计, 以量化预测不确定性, 全面提升模型的鲁棒性与可靠性。具体流程如图 1 所示。




图 1 总体流程

Fig. 1 Overall flow chart

1.1 传感器筛选

在多传感器装备健康监测与故障诊断领域,原始传感器数据通常包含大量冗余信息、噪声干扰以及因操作条件变化而对信号产生的影响,若直接用于 HI 构建可能会导致模型稳定性下降。因此,合理的数据筛选过程至关重要^[20]。但由于大多数现有方法均通过手动选择传感器数据,容易忽略从不同发动机传感器收集到的数据之间的一致性,因此在实际工业应用中仍然具有一定的局限性。针对传统传感器选择方法依赖先验知识,无法适应设备退化模式动态变化的问题,本文提出了一种基于动态数据分析的自适应传感器筛选策略,通过多个步骤的综合考虑,能够在系统运行过程中自适应地筛选出最相关的传感器。

1.1.1 传感器信号相似性度量

在多传感器环境下,不同传感器数据可能具有一定的冗余性或者相关性。为减少信息冗余,提高关键特征提取的有效性,本文同时结合 MI 与 DTW 来度量传感器信号的相似性。

互信息用来度量 2 个随机变量共享的信息量^[21]。设 2 个传感器信号样本为 Z_1 和 Z_2 , 其统计形式分别为 X 和 Y , 时间序列的形式分别为 S_1 和 S_2 。互信息的定义如下

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (1)$$

式中: $p(x, y)$ 为联合概率分布; $p(x)$ 、 $p(y)$ 为边缘概率分布。互信息用于衡量 2 个信号的统计相关性,并能捕捉非线性关系。由于互信息值受变量熵大小的影响显著,不易直接比较,故本文进一步引入归一化互信息(normalized mutual information, NMI),即

$$f_{\text{NMI}}(X, Y) = \frac{I(X; Y)}{\min(H(X), H(Y))} \quad (2)$$

式中: $H(\cdot)$ 为信息熵。 f_{NMI} 值域为 $[0, 1]$, 数值越大表示传感器间非线性依赖关系越强。

DTW 是一种用于计算时间序列相似性的非欧几里得度量方法,适用于长度不等或具有时间滞后的信号^[22]。其核心思想是通过弹性匹配不同时间步的数据点,使 2 条时间序列的累积误差最小。设 S_1 与 S_2 为 2 条长度可能不同的时间序列,其 DTW 距离为

$$f_{\text{DTW}}(S_1, S_2) = \min_{\pi} \sum_{(i,j) \in \pi} d(S_1(i), S_2(j)) \quad (3)$$

式中: π 为对齐路径; $d(S_1(i), S_2(j))$ 为数据点

间的欧几里得距离。为了消除量纲影响,本文采用归一化 DTW 相似性,即

$$\bar{f}_{\text{DTW}}(S_1, S_2) = 1 - \frac{f_{\text{DTW}}(S_1, S_2)}{L \cdot R} \quad (4)$$

式中: L 为信号长度; R 为信号幅值范围。

NMI 虽能有效捕捉非线性统计依赖关系,却可能高估形态相似但无实质关联的信号,如随机噪声与周期信号可能因分布相似而导致 NMI 值虚高;而 DTW 虽解决了时序错位问题,却过度关注形态匹配,对幅值差异较为敏感且容易忽略变量间的统计相关性。为此,本文将归一化互信息与归一化 DTW 相似性进行加权融合,定义混合相似性指标为

$$S_{\text{mix}}(Z_1, Z_2) = \alpha \cdot f_{\text{NMI}}(X, Y) + (1 - \alpha) \cdot \bar{f}_{\text{DTW}}(S_1, S_2) \quad (5)$$

式中: α 为权重系数,用于平衡统计相关性与时间对齐相似性。

1.1.2 传感器聚类分析

为进一步去除冗余传感器信号,本文采用基于混合相似性的层次聚类方法。首先,根据混合相似性计算所有传感器间的相似度矩阵,然后将相似性矩阵转换为距离矩阵 D , 表达式为

$$D_{ij} = 1 - S_{\text{mix}}(Z_i, Z_j) \quad (6)$$

确保所有距离非负后,采用 Ward 最小方差法执行层次聚类,表达式为

$$\min \sum_{k=1}^K \sum_{Z_i \in C_k} \|Z_i - \mu_k\|^2 \quad (7)$$

式中: C_k 为第 k 个聚类簇; μ_k 为簇内样本均值。

由式 (7) 可知,该方法通过最小化簇内平方误差来确保每个簇内部的紧密性。通过预设的动态聚类阈值对聚类树进行截断,最终划分得到若干传感器子集。

1.1.3 关键传感器筛选

在完成聚类后,仍需进一步从不同簇中选择最具代表性的传感器。为此,运用 TSI 的筛选方法来最终选择出具有代表性的传感器子集。TSI 是一种衡量时间序列中长期趋势显著性的指标,能够有效判断传感器信号是否包含清晰、稳定的退化趋势。TSI 通过回归分析与方差比率计算传感器信号的长期趋势强度。具体而言,若某一传感器的 TSI 值较高,说明其信号中趋势成分占主导,具有较强的退化指示能力,因而更适合作为后续健康指标构建的关键数据源。TSI 的计算表达式为

$$f_{\text{Tsl}}(X) = \lambda \cdot |\beta| + (1 - \lambda) \cdot \frac{\sigma_b}{\sigma_f} \quad (8)$$

式中: β 为信号趋势的鲁棒回归斜率; σ_b 和 σ_f 分别为前后时间窗口的信号方差; λ 为平衡趋势变化与方差比率的权重因子。

为确保选择出最能反映设备退化趋势的传感器, 本文基于操作条件向量 $\mathbf{v}$ 的一范数对阈值进行动态调整, 即

$$\tau = \tau_0 \cdot \|\mathbf{v}\| \quad (9)$$

式中: τ_0 为初始阈值常数; $\|\mathbf{v}\|$ 表示操作条件的复杂性。当某个传感器的 $f_{\text{Tsl}} \geq \tau$ 时, 该传感器将被选为关键传感器。

1.2 基于张量表示的健康指标构建

在对工业设备性能退化建模过程中, 传统的方法多采用向量或矩阵形式对时间序列数据进行建模, 然而此类方法难以充分捕捉多维信息之间的耦合特性。针对该问题, 本文提出基于张量表示的 HI 构建方法, 将原始传感器多变量时间序列转化为三阶张量表示, 并通过自适应 Tucker 分解提取关键退化特征, 从而构建更具物理意义与稳定性的 HI。

设某一装备的传感器数据矩阵为

$$\mathbf{S} = \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1d} \\ s_{21} & s_{22} & \cdots & s_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ s_{T1} & s_{T2} & \cdots & s_{Td} \end{bmatrix} \in \mathbb{R}^{T \times d} \quad (10)$$

式中: T 为时间步长; d 为传感器维度。为增强张量结构的物理可解释性, 本文所构建张量的传感器维度通常包含反映设备多个关键部件运行状态及其动态演化过程中多个关键物理量的传感器数据, 如总温、总压、低压压气机转速、燃油流量、推力控制信号等。

通过滑动窗口机制, 采用长度为 w 、步长为 s 的窗口从 $\mathbf{S}$ 中截取连续的局部片段来构建三阶张量 $\chi \in \mathbb{R}^{N \times I \times d}$ 。窗口个数为 $N = (T - w) / s + 1$, 张量的 3 个维度分别表示窗口个数、窗口长度、传感器维度。张量表示的原理如图 2 所示。




图 2 张量表示原理

Fig. 2 Principle of tensor representation

为了从张量中压缩提取出有效特征, 本文采用 Tucker 分解方法, 该方法是一种高阶张量分解技术, 可看作是 PCA 在多维空间中的推广形式。Tucker 分解将原始张量 χ 近似表示为一个核心张量 $\mathbf{G}$ 以及一组因子矩阵的乘积形式, 即

$$\chi \approx \mathbf{G} \times_1 \mathbf{U}^{(1)} \times_2 \mathbf{U}^{(2)} \times_3 \mathbf{U}^{(3)} \quad (11)$$

式中: $\times_n$ 表示第 n 模的张量乘积; $\mathbf{U}^{(1)} \in \mathbb{R}^{I_1 \times R_1}$ 、 $\mathbf{U}^{(2)} \in \mathbb{R}^{I_2 \times R_2}$ 、 $\mathbf{U}^{(3)} \in \mathbb{R}^{I_3 \times R_3}$ 为因子矩阵, 分别表示张量在时间-窗口-传感器上的因子; $\mathbf{G} \in \mathbb{R}^{R_1 \times R_2 \times R_3}$ 为低秩核心张量。

为避免人工设定分解秩, 引入基于方差解释率的动态秩估计策略。对张量在每一模进行展平, 计算其奇异值分布, 并依据累计方差贡献率确定最小秩, 使其满足

$$\frac{\sum_{i=1}^{R_n} \sigma_i^2}{\sum_{j=1}^{I_n} \sigma_j^2} \geq \theta \quad (12)$$

式中: θ 为预设方差阈值; σ 为奇异值。

完成张量表示后, 利用核心张量中代表时间演化特征的第一维提取退化趋势, 设核心张量 $\mathbf{G} \in \mathbb{R}^{R_1 \times R_2 \times R_3}$, 则构建 HI 的方法为

$$H_n = \frac{1}{R_3} \sum_{j=1}^{R_3} \mathbf{G}(n, :, j) \quad (13)$$

式中: H_n 为第 n 个时间窗口的健康值; R_3 为传感器方向的秩; $:$ 表示取该维度的所有元素。该式提取核心张量在传感器方向的均值作为每个窗口的健康值, 反映了设备运行状态的整体演化趋势。

2 基于 At-Bi-LSTM 的 RUL 预测模型

在 RUL 预测任务中, 设备退化过程通常具有高度的不确定性, 仅依赖点估计方法难以满足实际工业场景对安全性和鲁棒性的要求。为提升模型的预测可信度, 本文构建以 At-Bi-LSTM 为核心的时序建模框架, 用于提取退化序列中的上下文特征, 并引入 MC Dropout 机制, 通过多次前向采样实现对模型输出不确定性的量化^[23], 从而建立起既具预测准确性又具不确定性感知能力的 RUL 预测方法。

2.1 MC Dropout 原理

MC Dropout 是一种将 Dropout 技术解释为近似贝叶斯推理的策略, 最早由 Gal 等^[24]提出。其

核心思想是在训练和推理阶段均启用 Dropout 机制，并通过多次前向传播采样网络的预测分布，从而实现对预测结果的不确定性建模。

在贝叶斯深度学习中，目标是学习模型参数的后验分布

$$p(W|D) \propto p(D|W) p(W) \quad (14)$$

式中： D 为训练数据； $p(D|W)$ 为似然函数； $p(W)$ 为先验分布。

MC Dropout 通过在前向传播中引入随机性，模拟从后验分布中采样模型参数，从而得到预测分布为

$$p(y^*|x^*, D) \approx \frac{1}{M} \sum_{m=1}^M f^{(m)}(x^*) \quad (15)$$

式中： $p(y^*|x^*, D)$ 为给定输入特征 x^* 和训练数据 D 条件下，输出 y^* 的预测分布； $\sum_{m=1}^M f^{(m)}(x^*)$ 为第 m 次以不同 Dropout 掩码进行前向传播的预测结果； M 为采样次数。

通过 MC Dropout 得到多个预测样本后，可计算预测均值 μ 和标准差 σ 为

$$\begin{cases} \mu = \frac{1}{M} \sum_{m=1}^M \hat{y}^{(m)} \\ \sigma^2 = \frac{1}{M} \sum_{m=1}^M (\hat{y}^{(m)} - \mu)^2 \end{cases} \quad (16)$$

式中： $\hat{y}^{(m)}$ 为第 m 次的预测值。

2.2 网络架构设计

本文采用 At-Bi-LSTM 作为核心结构，并结合 MC Dropout 实现对预测不确定性的建模。在该结构中，输入的多维时间序列首先通过 Bi-LSTM 进行上下文编码，从而获取每个时间步前后状态的综合信息；随后，借助 Attention 计算不同时间步的重要性权重，使模型能够聚焦于关键退化阶段的特征；最后，将加权后的全局特征向量作为退化表示，输入至回归层进行 RUL 预测。

为了实现不确定性量化，本文引入 Dropout 层，并在预测阶段使其保持激活状态。通过多次前向传播，MC Dropout 等价于对网络参数进行多次采样，从而得到 RUL 的预测分布。具体而言，在测试时以相同输入重复 M 次前向传播，最终获得一组预测值 $\hat{y}^{(1)}, \hat{y}^{(2)}, \dots, \hat{y}^{(M)}$ 。通过计算均值作为 RUL 预测，标准差作为不确定性指标，实现预测值与可信区间的联合输出。该架构在兼顾准确性的同时，引入轻量级的不确定性建模机制，为后续的维修决策提供更可靠的依据。

3 实验验证与分析

3.1 数据集描述

本文实验使用航空发动机 C-MAPSS 数据集，该数据集由 NASA 提供，主要用于航空发动机健康管理与 RUL 预测研究。该数据集记录了多台发动机在不同运行条件下的传感器数据，包括操作条件和传感器读数。数据包括训练集、测试集以及真值数据。每条记录包含时间戳、操作条件和 21 个传感器的读数，其相关参数如表 1 所示。在处理过程中，数据经过标准化与滑动窗口划分，确保每组数据的一致性和适用性。

表 1 C-MAPSS 数据集

Table 1 C-MAPSS dataset

参数	FD001	FD002	FD003	FD004
训练集发动机台数	100	260	100	249
测试集发动机台数	100	259	100	248
工作状态	1	6	1	6
故障模式	1	1	2	2
训练样本	17 731	48 819	21 820	57 522
测试样本	100	259	100	248

3.2 实验过程

为了筛选出与设备退化相关性较高的关键传感器，结合混合相似度量度和层次聚类方法，对传感器进行分组，确保每个传感器组内的相关性最大化，然后运用 TSI 进一步筛选出对退化过程具有显著影响的传感器。通过该模型，有效地减少了冗余传感器数据，仅保留了与健康状态密切相关的传感器，部分发动机传感器筛选结果如图 3 所示。其中，蓝色方块表示经过筛选后保留的传感器。从图中可以看出，编号 15 的发动机未选择传感器 11~15，因为这几个传感器在其寿命周期内呈现出明显的趋势不稳定、剧烈波动或信噪比较低特征。而编号 1 的发动机在对应通道上则表现出稳定的退化趋势，因而被保留下来。

在传感器筛选后，采用三阶张量 HI 构建方法。首先，利用经过筛选的传感器数据构建时间-窗口-传感器三维张量，然后使用 Tucker 分解对三维数据进行解耦，以提取设备退化过程中的关键特征。具体来说，Tucker 分解将张量表示为核心张量和因子矩阵的乘积，能够有效地降低数据维度，同时保留设备退化过程的主要特征。通过核心张量中的时间演化特征，计算每个时间步的 HI，

并生成设备的退化曲线。图4为100台发动机的训练集与测试集数据构建的HI曲线，用于反映发动机在运行过程中逐步偏离初始健康状态的程度。从图中趋势可以观察到，设备在早期阶段性能变化较为平缓，随着运行周期的延长，HI偏离初始状态的速度逐步加快，呈现加速退化的特征，这一变化趋势与真实设备的劣化行为高度一致。




图3 部分发动机传感器筛选结果
Fig. 3 Partial results of engine sensor selection




图4 张量表示提取的健康指标
Fig. 4 Tensor representation of extracted health indices

本文采用鲁棒性和趋势性2个指标对所构建的HI进行评估，并将本文方法与PCA、深度置信网络（deep belief network, DBN）和CDBN进行对比。表2展示不同方法在测试集上的平均评价指标结果。结果表明，基于张量表示提取的HI在鲁棒性和趋势性方面均优于上述常用HI构建方法。本文还设计了消融实验，分别添加张量构建策略和自适应传感器筛选机制。结果显示，两者在提升

健康指标质量方面均具有独立贡献，完整模型在鲁棒性和趋势性指标上表现相对最优，进一步证明所提方法中各模块设计的合理性与协同优势。

表2 HI评价指标对比		
Table 2 Comparison of HI evaluation indices		
HI构建方法	鲁棒性	趋势性
PCA	0.849	0.867
DBN	0.905	0.945
CDBN	0.943	0.953
固定14维传感器+张量构建	0.945	0.955
自适应传感器筛选+向量构建	0.937	0.952
本文方法	0.958	0.961

在构建HI之后，采用Bi-LSTM网络对RUL进行预测，并在Bi-LSTM层后加入Attention机制以增强模型的特征提取能力。同时引入MC Dropout技术，在预测阶段保持Dropout激活，参数设置为0.4。由于每次前向传播过程中网络结构均会发生随机变化，因此每次预测结果也有所不同。通过进行1 000次MC仿真采样，可获得多个RUL预测点估计值，并可以计算得到均值与方差，从而构建RUL预测的近似概率分布，用于衡量预测的不确定性。RUL标签采用分段线性设定，最大值设为发动机的平均寿命，约125个循环周期。表3展示了模型的具体结构配置。

表3 Bi-LSTM网络参数	
Table 3 Parameters of Bi-LSTM network	
参数	数值
网络结构	256-128-1
时间窗长度	30
优化器	Adam
Dropout	0.4
训练次数	100
初始学习率	0.001
Batch size	128

3.3 结果分析

本文从得分（Score）和均方根误差（root mean square error, RMSE）2个维度对比了文献[19]、[25]和[26]中的预测方法与本文所提方法，Score和RMSE的表达式为

$$L_{\text{score}} = \sum_{i=1}^N \begin{cases} \exp\left(-\frac{e_i}{\alpha}\right) - 1, & e_i < 0 \\ \exp\left(\frac{e_i}{\alpha}\right) - 1, & e_i \geq 0 \end{cases} \quad (17)$$

$$\varepsilon_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (18)$$

式中: N 为数据总数; $e_i = \hat{y}_i - y_i$; y_i 为第 i 时刻的 RUL 真实值; $\hat{y}_i$ 为第 i 时刻的 RUL 预测值; α 为调节参数, 用于控制误差的惩罚权重。

计算结果如表 4 所示, 与深度学习模型 CNN、Growing RNN 和 CDBN-Bi-LSTM 相比, 本文所提出的预测方法在 Score 与 RMSE 性能指标中均优于上述 3 种模型。其中, 本文方法的 L_{score} 相较于 CNN 模型降低了约 85.8%, 较 CDBN-Bi-LSTM 模型降低了约 16.7%; 在 RMSE 指标中, 本文方法的 $\varepsilon_{\text{RMSE}}$ 相较于 CNN 模型降低了约 46.2%, 较 CDBN-Bi-LSTM 模型降低了约 20.7%。这是由于本文方法充分考虑了多传感器数据间的耦合关系, 采用张量表示构建 HI 并结合 At-Bi-LSTM 网络进行预测, 从而显著提升了 RUL 预测的准确性与稳定性。

为验证本文预测模型的工程适用性, 图 5 展示了多组涡扇发动机全寿命周期内剩余使用寿命预测结果。需要特别指出, 发动机性能退化特征与监测参数具有强相关性, 监测数据完整性会直接影响模型输出精度。研究分别选取 FD001、FD002、FD003 和 FD004 数据集中的典型发动机

样本, 编号分别为 68、97、60 和 94, 对其全寿命周期内的 RUL 进行持续预测分析。图 5 中真实值寿命指的是每台发动机从初始健康状态至实际退役 (或判定为失效) 的工作周期数, 由 C-MAPSS 数据集中提供的标签明确给出, 代表其剩余寿命的“真实值”。实验数据表明, 虽然初始测试阶段预测曲线与真实值存在阶段性偏离, 但随着发动机工作循环数的累积, 模型预测误差呈现收敛趋势。这种时变预测特性对于健康管理领域具有重要实践意义, 特别是在状态评估与视情维护决策方面, 可以有效提升安全保障水平并优化运维经济性。

表 4 不同方法 RUL 预测结果对比

Table 4 Comparison of RUL prediction results of different methods

剩余寿命预测方法	L_{score}	$\varepsilon_{\text{RMSE}}$
CNN ^[25]	1 287	18.45
Growing RNN ^[26]	303	14.31
CDBN-Bi-LSTM ^[19]	219.50	12.51
本文方法	182.86	9.92

图 6 和图 7 采用 MC 仿真方法, 分析了 FD001 中编号为 68 和 100 的涡扇发动机 95% 置信区间随




图 5 单个发动机 RUL 预测结果

Fig. 5 RUL prediction results of single engine




图 6 68号发动机RUL概率分布

Fig. 6 RUL probability distribution of engine 68




图 7 100号发动机RUL概率分布

Fig. 7 RUL probability distribution of engine 100

时间演化的预测曲线以及最后6个监测点处RUL的PDF。结果表明,随着设备运行时间增加,退化迹象逐渐明显,模型生成的置信区间带宽逐步收敛,呈现出预测稳定性增强的趋势,体现出较强的时变自适应能力。此外,从RUL的PDF分布可以看出,在设备接近失效时,预测结果具有明显的峰态集中特征,表明模型在后期可实现高置信度的寿命估计。而在退化初期,PDF分布相对平缓,反映出模型对早期预测的不确定性识别能力。这种基于概率统计的区间估计机制,不仅能够提供期望值信息,还能辅助评估预测结果的可靠性,从而为设备健康评估、剩余寿命预警及预防性维护策略的制定提供更为稳健和量化的决策支持,具有较强的工程实用价值。

4 结论

针对多元传感器数据强耦合关系导致HI难构建,进而影响多传感器装备RUL预测精度的问题,本文提出了一种基于动态自适应传感器筛选机制与张量表示的HI构建方法,建立了At-Bi-LSTM网络的预测框架。通过系统验证与对比分

析,形成以下结论。

1) 提出的动态自适应传感器筛选机制,通过混合相似度量与层次聚类的特征分组策略,结合趋势强度和滑动方差比双重过滤准则,有效提升了关键退化特征的选择可靠性。实验表明该模块使预测结果稳定性提升,验证了特征筛选对模型鲁棒性的增强作用。

2) 构建的三阶张量HI建模方法,采用Tucker分解实现时间-窗口-传感器三维数据的耦合关系解耦,通过核心张量特征融合生成的复合HI相较于传统单维特征提取方法,能够使模型预测精度得到提升,证实了多维数据建模对性能改善的显著贡献。

3) 运用At-Bi-LSTM预测模型,引入MC Dropout实现不确定性量化。结果表明,本文方法在验证数据集上的RUL预测精度显著优于其他对比模型。

本文结合张量构建HI与At-Bi-LSTM网络的预测框架实现了装备RUL预测,在后续的研究中将构建包含不确定性传播机制的决策优化系统,以进一步提升复杂工况下剩余寿命预测模型的可解释性和工程适用性,为航空发动机全寿命周期

管理提供更可靠的技术支撑。

参考文献

- [1] ZHOU M H, LI Y J, CAO Y Y, et al. Physics-informed spatio-temporal hybrid neural networks for predicting remaining useful life in aircraft engine[J]. *Reliability Engineering & System Safety*, 2025, 256: 110685.
- [2] 任超, 李慧琴, 李天梅, 等. 基于退化模型动态校准的设备剩余寿命预测方法[J]. *航空学报*, 2023, 44(19): 176-191.
- REN C, LI H Q, LI T M, et al. Equipment remaining useful life prediction method with dynamic calibration of degradation model[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(19): 176-191.
- [3] ZHA W T, YE Y H. An aero-engine remaining useful life prediction model based on feature selection and the improved TCN[J]. *Franklin Open*, 2024, 6: 100083.
- [4] XU Z Q, ZHANG Y J, MIAO J G, et al. Global attention mechanism based deep learning for remaining useful life prediction of aero-engine[J]. *Measurement*, 2023, 217: 113098.
- [5] HU L K, HE X J, YIN L F. Remaining useful life prediction method combining the life variation laws of aero-turbfan engine and auto-expandable cascaded LSTM model[J]. *Applied Soft Computing*, 2023, 147: 110836.
- [6] SONG H D, LIU X J, SONG M Q. Comparative study of data-driven and model-driven approaches in prediction of nuclear power plants operating parameters[J]. *Applied Energy*, 2023, 341: 121077.
- [7] 陈俊英, 席月芸, 李朝阳. 多尺度局部特征和 Transformer 全局学习融合的发动机剩余寿命预测[J]. *自动化学报*, 2024, 50(9): 1818-1830.
- CHEN J Y, XI Y Y, LI C Y. Prediction of aeroengine remaining life by combining multi-scale local features and transformer global learning[J]. *Acta Automatica Sinica*, 2024, 50(9): 1818-1830.
- [8] TIAN H X, YANG L Z, JU B T. Spatial correlation and temporal attention-based LSTM for remaining useful life prediction of turbfan engine[J]. *Measurement*, 2023, 214: 112816.
- [9] ULLAH B, KAMRAN M, RUI Y C. Predictive modeling of short-term rockburst for the stability of subsurface structures using machine learning approaches: T-SNE, K-means clustering and XGBoost[J]. *Mathematics*, 2022, 10(3): 449.
- [10] KHAN I U, HUA C R, LI L B, et al. Remaining useful life prediction for a cracked rotor system via moving feature fusion based deep learning approach[J]. *Measurement*, 2025, 239: 115433.
- [11] GHORBANI S, SALAHSHOOR K. Estimating remaining useful life of turbfan engine using data-level fusion and feature-level fusion[J]. *Journal of Failure Analysis and Prevention*, 2020, 20(1): 323-332.
- [12] MUSTAFFA Z, SULAIMAN M H. Battery remaining useful life estimation based on particle swarm optimization-neural network[J]. *Cleaner Energy Systems*, 2024, 9: 100151.
- [13] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. *Reliability Engineering & System Safety*, 2018, 172: 1-11.
- [14] AL-DULAIMI A, ZABIHI S, ASIF A, et al. A multimodal and hybrid deep neural network model for remaining useful life estimation[J]. *Computers in Industry*, 2019, 108: 186-196.
- [15] ZHOU L, WANG H W, XU S S. Aero-engine prognosis strategy based on multi-scale feature fusion and multi-task parallel learning[J]. *Reliability Engineering & System Safety*, 2023, 234: 109182.
- [16] ZHOU Z H, BAI M L, LONG Z H, et al. An adaptive remaining useful life prediction model for aeroengine based on multi-angle similarity[J]. *Measurement*, 2024, 226: 114082.
- [17] ZHOU Z H, LONG Z H, WANG R D, et al. An aircraft engine remaining useful life prediction method based on predictive vector angle minimization and feature fusion gate improved transformer model[J]. *Journal of Manufacturing Systems*, 2024, 76: 567-584.
- [18] PENG P, LI Y H, GUO Z Y. High-performance remaining useful life prediction for aeroengine based on combining health states and trajectory similarity[J]. *Engineering Applications of Artificial Intelligence*, 2025, 141: 109799.
- [19] 牟含笑, 郑建飞, 胡昌华, 等. 基于 CDBN 与 BiLSTM 的多元退化设备剩余寿命预测[J]. *航空学报*, 2022, 43(7): 308-319.
- MU H X, ZHENG J F, HU C H, et al. Remaining useful life prediction of multivariate degradation equipment based on CDBN and BiLSTM[J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(7): 308-319.
- [20] 郑建飞, 牟含笑, 胡昌华, 等. 考虑多性能指标相

- 关性的退化设备剩余寿命预测[J]. 哈尔滨工程大学学报, 2022, 43(5): 620-629.
- ZHENG J F, MU H X, HU C H, et al. Remaining useful life prediction of degradation equipment considering multiple performance indexes correlation[J]. Journal of Harbin Engineering University, 2022, 43(5): 620-629.
- [21] 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, (2025-01-22)[2025-04-12]. <https://doi.org/10.13196/j.cims.2024.0433>.
- XU D Y, SHANG J, JIANG C, et al. Remaining useful life prediction of aero-engines based on adaptive spatial-temporal graph convolutional network[J/OL]. Computer Integrated Manufacturing Systems, (2025-01-22)[2025-04-12]. <https://doi.org/10.13196/j.cims.2024.0433>.
- [22] CHEN J X, LI D P, HUANG R Y, et al. Aero-engine remaining useful life prediction method with self-adaptive multimodal data fusion and cluster-ensemble transfer regression[J]. Reliability Engineering & System Safety, 2023, 234: 109151.
- [23] 金诗杭. 基于时间卷积网络的涡扇发动机剩余寿命预测[D]. 重庆: 重庆大学, 2022: 41-45.
- JIN S H. Remaining useful life prediction of turbo-fan engine based on temporal convolutional network [D]. Chongqing: Chongqing University, 2022: 41-45.
- [24] GAL Y, GHAHRAMANI Z. Dropout as a Bayesian approximation: representing model uncertainty in deep learning[C]//Proceedings of the 33rd International Conference on Machine Learning. New York, USA: ACM, 2016, 48: 1050-1059.
- [25] BABU G S, ZHAO P L, LI X L. Deep convolutional neural network based regression approach for estimation of remaining useful life[C]//Database Systems for Advanced Applications. Cham: Springer International Publishing, 2016: 214-228.
- [26] ELDALI M, KUMAR K D. Fault diagnosis and prognosis of aerospace systems using growing recurrent neural networks and LSTM[C]//2021 IEEE Aerospace Conference. Piscataway, NJ, USA: IEEE, 2021: 1-20.

(编辑: 刘建民)