

基于并分支 GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法

郭稳稳^{1,2} 王国虎^{1,2} 原永亮³ 王沛颖¹ 郭银晓¹

(1. 郑州工业应用技术学院 机电工程学院, 郑州 451150)

(2. 河南省隧道工程机械工程技术研究中心, 郑州 451150)

(3. 河南理工大学 机械与动力工程学院, 焦作 454003)

摘要:【目的】基于深度学习的航空发动机剩余使用寿命预测,为保障航空发动机的可靠性奠定了基础。然而,现有研究多聚焦于欧氏空间中退化信息的获取,忽视了非欧氏空间中拓扑关系蕴含的额外退化信息。因此,提出了一种基于并分支图节点嵌入学习的门控循环神经网络(Parallel-Graph Node Embedding Learning-Gated Recurrent Unit, Parallel-GraphSAGE-GRU)的航空发动机剩余使用寿命预测方法。【方法】首先,基于最大互信息法描述航空发动机监测参数之间的关系,在此基础上,通过固定时间窗口构造图,输入序列获取发动机非欧氏空间的拓扑关系;其次,采用GRU提取欧氏空间中航空发动机时间退化关系;然后,在运行过程的每个时刻将GraphSAGE与GRU的输出隐式向量进行拼接,并通过全连接神经网络映射为航空发动机输入退化信息的剩余使用寿命值;最后,采用航空发动机剩余使用寿命数据集,对所提方法的有效性和先进性进行验证,所提方法的 R^2 最高达到0.988 6。【结果】结果表明,该方法能够兼顾预测精度及计算效率,具备良好的可行性。

关键词: 发动机; 剩余使用寿命; 特征信息提取; 图节点嵌入学习; 门控循环单元

中图分类号: TH17 **DOI:** 10.16579/j.issn.1001.9669.2026.07.004

0 引言

随着工业4.0的深入推进,智能制造对设备可靠性提出了更高要求。在工业智能化转型过程中,如何通过预测和健康管(Prognostics and Health Management, PHM)技术预防复杂机械设备的故障停机、提升设备的运行可靠性,已成为工业4.0推进过程中的核心问题。该技术通过多维度状态监测与数据分析,构建设备健康评估体系,能够显著提升复杂系统的运行可靠性^[1-2],尤其在恶劣工况环境下,能够整合温度、振动、压力等多源异构参数,实现对设备健康状态的动态评估。作为一种复杂机械设备,航空发动机的故障特征通常可由关键运行状态参数表征,包括气流压力、发动机的转速、油耗等多个参数。这些参数之间呈现复杂的非线性关系,增大了航空发动机剩余使用寿命(Remaining Useful Life, RUL)预测的难度。

目前,航空发动机的剩余使用寿命预测模型主要分为基于物理模型的方法和数据驱动的方法两类。基于物理模型的方法需要构造发动机退化过程中确切的物理模型,以准确反映发动机的退化过程,如Wiener过程^[3]、卡尔曼滤波^[4]等。在实际工程中,发动机的复杂性及先验知识的限制,导致无法构造确切的物理模型,

基于物理模型的方法在实际应用中受限;而传感器测量技术的发展能够保留大量发动机的运行数据,为基于数据驱动的方法的发展提供了可能。

对于数据驱动方法,健康指标(Health Indicators, HIs)在衡量发动机运行状态和准确的RUL预测方面承担着重要的作用。根据健康指标的构造方式,其主要分为具备实际意义的HIs和虚拟HIs两类。前者通过信号处理及数理统计的方式获得,如均值、方差、偏斜度等。后者则是在前者的基础上通过进一步融合HIs之间的潜在关系获取。近年来,基于深度学习HIs的方法广泛受到研究人员的青睐。为高效挖掘发动机监测数据价值、规避人工构建健康指标的复杂流程,国内外学者已开展大量相关研究,张鲁一航等^[5]根据人工预先设定的阈值,利用变分模态分解将发动机的退化数据分解为特定的子数据,获取了发动机寿命衰减过程中的变化行为。吴嘉俊等^[6]使用卷积神经网络和循环神经网络,从发动机的老化数据中获取空间退化信息和时间退化信息,结合注意力机制,构造了准确的发动机RUL预测模型。兰杰等^[7]利用编码-解码器完成了发动机退化过程中每个时刻健康指标的重构,从而实现了发动机退化信息的隐式表征。然而,

收稿日期: 2025-02-28 修回日期: 2025-05-30

基金项目: 国家自然科学基金项目(52404163); 河南省科技攻关项目(252102220079, 252102221003); 新一轮河南省重点学科(机械)(教研[2023]414号); 河南省高等学校重点科研项目(25B460020)

作者简介: 郭稳稳,女,1993年生,河南新郑人,实验师; 主要研究方向为机械寿命智能预测、机械强度分析等; E-mail: gzh47702@163.com。

引用格式: 郭稳稳, 王国虎, 原永亮, 等. 基于并分支 GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法[J]. 机械强度, 2026, 48(7): 32-39.

GUO Wenwen, WANG Guohu, YUAN Yongliang, et al. Remaining useful life prediction of aeroengine based on Parallel-GraphSAGE-GRU[J]. Journal of Mechanical Strength, 2026, 48(7): 32-39.



免费获取

这些研究致力于在欧氏空间中发动机健康指标的获取,忽略了退化过程中发动机健康指标之间的拓扑关系^[8]。拓扑关系可以为发动机 RUL 的预测提供额外的有效信息。目前,研究人员正在利用图神经网络来学习和探索信号中隐藏的拓扑关系,并逐步将其应用于 PHM 领域。叶欣等^[9]利用改进的变分模态分解方法及图神经网络构造了液压元件的 RUL 预测模型。

在现有研究中,对于航空发动机的退化信息获取往往局限于欧氏空间的处理,或者仅关注非欧氏空间中的发动机 HIs 拓扑关系,这种单一维度的分析限制了对发动机退化过程全面的理解。为实现全面反映航空发动机退化过程及准确的 RUL 预测,本研究提出一种基于并分支图节点嵌入学习的门控循环神经网络(Parallel-Graph Node Embedding Learning-Gate Recurrent Unit, Parallel-GraphSAGE-GRU)的航空发动机剩余使用寿命预测模型。将航空发动机的退化时间序列数据构造为可视图数据,利用 GraphSAGE 和 GRU 分别获取航空发动机 HIs 之间的拓扑关系和欧氏空间中的时序关系。在此基础上,联合欧氏空间与非欧氏空间中航空发动机退化过程的潜在关系,实现准确的剩余使用寿命预测。最后,通过航空发动机剩余使用寿命数据集对所提方法的有效性和先进性进行分析,以验证所提方法的有效性。

1 基于 GraphSAGE 获取非欧氏空间航空发动机的退化信息

GraphSAGE 算法是一种高效的图神经网络方法,旨在克服传统图卷积神经网络(Graph Convolutional Neural Network, GCN)存在的计算效率和存储的瓶颈问题^[10]。在 GraphSAGE 中,采用节点邻居的信息生成节点的嵌入表示,从而实现航空发动机的退化信息在非欧氏空间的关系表示。与图卷积神经网络类似,其输入由节点和边构成,可表示为

$$G = (V, E, A) \quad (1)$$

式中, $V = (v_1, v_2, v_3, \dots, v_n)$ 为图节点集合, v 为节点。 $E = (S_{11}, S_{12}, \dots, S_{ij}, \dots, S_{nn})$ 为边集合, S 为不同节点之间的权重。 $A \in \mathbf{R}^{n \times n}$ 为邻接矩阵,用于表示任意两个节点连接边的权值大小, n 为构造航空发动机退化信息的维度。

GraphSAGE 主要包括采样和聚合。它通过采用聚合函数,在每一层聚合节点自身和其邻居节点的信息,进而输出节点得到下一层的表示,如图 1 所示。其计算式为

$$h_{N(v)}^l = f_{\text{aggregate}}(\{h_{vu}^{l-1}\}) \quad (2)$$

$$h_v^l = \sigma[W \cdot f_{\text{concat}}(h_v^{l-1}, h_{N(v)}^l)] \quad (3)$$

$$h_v^l = \sigma\{W^k \cdot f_{\text{MEAN}}[\{h_v^{l-1}\} \cup \{h_{N(v)}^{l-1}, \forall u \in N(v)\}]\} \quad (4)$$

$$h_{v1}^l = \frac{h_v^l}{\|h_v^l\|_2} \quad (5)$$

式中, $f_{\text{aggregate}}(\cdot)$ 为聚合函数,将目标节点与相邻节点的

$l-1$ 层拼接; h_v^{l-1} 和 h_u^{l-1} 分别为第 $l-1$ 层和 l 层中目标节点 v 与相邻节点 u 的特征表示结果; $\forall u \in N(v)$, $N(v)$ 表示所有节点邻居的集合; $\sigma(\cdot)$, W^k 和 $f_{\text{concat}}(\cdot)$ 分别为非线性激活函数和可训练的参数和拼接函数; $\|h_v^l\|_2$ 为 h_v^l 的 L_2 范数; h_{v1}^l 为 h_v^l 归一化后的聚合结果; f_{MEAN} 函数为逐维度算术均值运算,用于对节点自身及全部邻域节点的上层特征向量求取各维度平均值,以完成特征聚合。




图 1 深层 GraphSAGE 的 1 阶邻居聚合

Fig. 1 Aggregation of neighbors in one-hop of deep GraphSAGE

航空发动机在持续运行过程中会经历老化过程。传统神经网络在处理这类退化数据时,未能充分考虑退化序列之间的拓扑关系,从而导致数据中潜在信息的丢失。此外,为了提高计算效率,采用 GraphSAGE 算法来深入研究航空发动机退化数据的潜在关系。

在构造 GraphSAGE 的输入样本时,采用固定滑动时间窗获取航空发动机退化数据的局部信息,在此基础上计算 HIs 之间非线性相关性,根据计算的结果构造 GraphSAGE 的输入。由最大信息系数(Maximum Information Coefficient, MIC)决定 HIs 之间的非线性相关性,可表达为

$$I([P, T], x, y) = \int p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)} dx dy \quad (6)$$

式中, $p(x, y)$ 为联合概率, $p(x)$ 与 $p(y)$ 均为边缘概率分布,基于互信息值, $f_{\text{MIC}}([P, T])$ 可表示为

$$f_{\text{MIC}}([P, T]) = \max_{a,b < B} \frac{\max I\{[P, T], x, y\}}{\log_2 \min\{a, b\}} \quad (7)$$

式中, a, b 分别为 x 轴和 y 轴网格的数量,可以计算不同网格下的互信息值, B 为网格的上限; $f_{\text{MIC}}([P, T])$ 为压力 P 和温度 T 之间的边缘属性,其他的参数也类似。然后将其作为 GraphSAGE 的输入以获取 HIs 之间的潜在关系。

2 基于 GRU 的欧氏空间退化信息获取

发动机的退化信息本质上是时间序列数据,在使用的过程中会呈现周期性、趋势性规律,因此需要考虑其退化信息的时间潜在关系。循环神经网络(Recurrent Neural Network, RNN)能够获取欧氏空间中时间序列的退化隐藏依赖关系。作为 RNN 的一种变体,门控循环神经网络(Gated Recurrent Unit, GRU)

是对传统 RNN 的改进,以缓解其梯度消失的问题^[11-12]。与长短期记忆神经网络(Long Short-Term Memory, LSTM)相比,GRU 结构更加简单,收敛速度更快,能够显著改善训练效率,如图 2 所示。GRU 包括重置门和更新门以控制历史信息的流动和记忆。其中,更新门决定了当前状态中引入历史信息的多少。重置门则根据历史信息决定当前的状态。重置门的值越大,则表示越多的历史信息融入当前状态中。对于单一的 GRU 结构,GRU 在 t 时刻的输出隐藏状态可表示为

$$z_t = \sigma(W_z[x_t, h_{t-1}] + b_z) \quad (8)$$

$$r_t = \sigma(W_r[x_t, h_{t-1}] + b_r) \quad (9)$$

$$\tilde{h}_t = \tanh(W_h[x_t, r_t \odot h_{t-1}] + b_h) \quad (10)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (11)$$

式中, h_t 、 h_{t-1} 和 $\tilde{h}_t$ 分别为当前时刻的隐藏状态、先前时刻的隐藏状态和中间隐藏状态; W_z 、 W_r 和 W_h 均为权重矩阵; b_z 、 b_r 和 b_h 均为对应的偏置矩阵; r_t 和 z_t 分别为重置门的输出和更新门的输出; $\odot$ 表示点乘。




图 2 GRU 的门控结构

Fig. 2 The gating mechanism of GRU

3 基于 GraphSAGE 与 GRU 的 RUL 预测

发动机的监测数据规模大、非线性、维度高。因此提出一种基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法,如图 3 所示。图 3 中, T' 为单个发动机监测数据样本的时间步长。基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法包括利用 GRU 实现欧氏空间退化时序信息的趋势获取和基于 GraphSAGE 获取非欧氏空间退化信息两部分。

3.1 数据预处理

由于设备仪器、网络信号等因素,直接由传感器获取的航空发动机监测数据存在噪声、异常值等问题,如果直接用这些数据作为神经网络的输入,难以反映多种因素影响下航空发动机剩余使用寿命的实际情况,因此,卡尔曼滤波被用于对原始监测数据进行平滑处理。在此基础上, min-max 归一化方法被用于将滤波后的数据缩放为 0~1。min-max 归一化的计算式为

$$x_{i,j}^{\text{norm}}(t) = \frac{x_{i,j}(t) - x_{i,j}(t). \min()}{x_{i,j}(t). \max() - x_{i,j}(t). \min()} \quad (12)$$

式中, $x_{i,j}^{\text{norm}}(t)$ 为归一化后的结果; $x_{i,j}(t)$ 为第 i 个样本中第 j 个传感器在 t 时刻的数据; $x_{i,j}(t). \max()$ 和

$x_{i,j}(t). \min()$ 分别为第 j 个传感器所有时刻的最大值和最小值。

由于方差极小或者不变的属性对预测结果不影响,因此去掉了方差为零的属性。本研究中衡量航空发动机退化程度的表达式为

$$D_{\text{RUL}_i} = \max(C) - C_i \quad (13)$$

式中, D_{RUL_i} 为该传感器还能返回的数据次数; $\max(C)$ 为该传感器能够使用的最大循环次数。此外,根据文献[13],在初始使用阶段发动机性能不发生退化,在该阶段 D_{RUL_i} 值被认为没有发生改变。通常情况下,当真实的 $D_{\text{RUL}_i} < 125$ 个循环时,发动机开始发生老化。因此,退化阈值被设定为 125。




图 3 基于 Parallel-GraphSAGE-GRU 的预测模型

Fig. 3 Prediction model of based the Parallel-GraphSAGE-GRU

3.2 滑动时间窗处理

滑动时间窗处理可以将航空发动机的原始监测数据转化为神经网络所需要的序列数据,同时保持原始监测数据退化过程的局部依赖性。利用滑动时间窗处理航空发动机的退化信息,并构造 GraphSAGE 需要的图数据,生成训练集和测试集。将训练集输入神经网络进行训练,再将输出样本标签和真实样本标签进行对比,不断缩小迭代得到的输出误差从而更新网络的权重矩阵,进而得到训练好的网络模型。将测试集代入训练好的 Parallel-GraphSAGE-GRU 网络模型中,得到准确的航空发动机的 RUL 预测结果。

3.3 性能度量和参数设定

为了衡量所提预测模型的优劣,通过以下有效性指标进行评估,如 R^2 、均方根误差(Root Mean Square

error, RMSE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE), 其数学函数可定义为

$$R^2 = 1 - \frac{\sum_{m=1}^M (y'_m - y_m)^2}{\sum_{m=1}^M (y'_m - \bar{y})^2} \quad (14)$$

$$E_{\text{EMSE}} = \sqrt{\frac{1}{M} \sum_{m=1}^M (y'_m - y_m)^2} \quad (15)$$

$$E_{\text{MAPE}} = \frac{1}{M} \sum_{m=1}^M \left| \frac{y_m - y'_m}{y_m} \right| \quad (16)$$

式中, $\bar{y}$ 为真实数据的均值; M 为总数据; y'_m 和 y_m 为第 m 个预测值和真实 RUL 值。所有试验均是在个人计算机上完成, 所用框架为 Pytorch 和 Pytorch-geometric。计算机硬件环境如下: CPU 为 I7-12700H, GPU 为 NVIDIA GeForce GTX 3070Ti, 运行内存为 16GB。

设定固定滑动时间窗口长度为 $d=10$, 步长 $s=1$, 采用重叠滑动的方式, 有助于获取识别和跟踪发动机老化过程中的持续退化现象。基于 GraphSAGE 和 GRU 的层数被设定为 2, 隐藏层单元数为 64。训练时的超参数选取为: batch size=64, epoch=300, 优化器选取 Adam, 学习率为 1×10^{-4} , 损失函数为均方根损失。

4 试验分析

航空发动机的结构复杂、维护成本高。因此, 对飞机发动机的运行状态监测、准确预测 RUL 是一种有效且重要的安全措施。以航空发动机的数据集为例, 对提出的基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法进行试验验证。

4.1 航空发动机的数据集描述


商用模块化航空推进系统仿真 (Commercial Modular Aero-Propulsion System Simulation, C-MAPSS) 数据集是由 NASA 以 PHM 为主题, 用仿真试验获取的多台航空发动机从正常运行到失效的数据集, 详细信息如表 1^[14] 所示。表 1 中, 1 个故障模式对应高、低压涡轮效率退化模式 (HPT); 2 个故障模式对应高、低压涡轮效率退化与流量退化模式 (HPT+LPT)。运行状态 1 表示发动机全程运行在海平面静止状态; 运行状态 6 表示包含不同高度、速度、推力的 6 种飞行状态。该数据集源于 Turbofan 航空发动机, 数据集中包括发动机的单元号、时间戳、3 种配置以及 21 个传感器直接获取的监测数据, 即可直接获取 HIs。该数据包括一些传感器噪声, 每组数据包括训练集、测试集、RUL 标签。其中 RUL 表示测试集的真实标签, 部分传感器随时间流逝变化的具体信息如图 4 所示。图 4 中, 图例数字为发动机编号, 1 表示第 1 台发动机, 31 表示第 31 台发动机, 以此类推。由图 4 可知, 部分发动机原始数据中部分传感器随着循环次数的变化构建出发动机的退化数据, 刻画发动机随着运行周期数目的增加偏离初始健康状态的程度。在航空

发动机性能退化前期, 影响航空发动机的因素变化较为缓慢, 随着运行时间的不断推进, 影响发动机的监测参数偏离初始状态的速率不断加快, 这与实际设备的运行退化趋势相符合。随着时间推移, 不同的传感器在该发动机上也发生不同的变化。图 5 所示为 4 个数据集中不同 HIs 互信息值计算的结果, 计算得到的互信息值结果作为邻接矩阵, 用于描述输入 HIs 之间的拓扑关系。


表 1 C-MAPSS 数据集的详细信息

Tab. 1 Detailed information of the C-MAPSS dataset

序号	FD001	FD002	FD003	FD004
训练集发动机个数	100	260	100	249
测试集发动机个数	100	259	100	248
运行状态	1	6	1	6
故障类别	1	1	2	2



(a) 2号传感器



(b) 12号传感器


图 4 在发动机上的传感器退化数据

Fig. 4 Degradation data of the sensors on the aeroengine


4.2 试验过程及结果分析

为探索基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法的有效性, 引入仅考虑欧氏空间和非欧氏空间的方法, 实现所提方法的消融试验。以 FD002 为例, FD002 中所有发动机的剩余使用寿命预测结果如图 6 所示, 由图 6 可知, 基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法能够准确地预测出当前发动机的剩余使用寿命。部分发动机的预测结果如图 7 所示。由图 7 可知, 所


提的方法能够准确预测单个发动机的剩余使用寿命的进程,尤其是在退化末期。




(a) FD001 原始互信息值计算结果



(b) FD002 原始互信息值计算结果



(c) FD003 原始互信息值计算结果



(d) FD004 原始互信息值计算结果

图5 不同数据集传感器参数互信息计算的结果

Fig. 5 Results of mutual information calculation for sensor




图6 FD002数据集中所有航空发动机的预测结果

Fig. 6 Prediction results of all aeroengines in the FD002 dataset

表2所示为不同数据集中详细的消融试验结果,由表2可知,在4个数据集中,基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法的预测性能总是优于仅使用单一空间信息的方法。这说明单一空间处理方法往往无法全面捕捉到发动机运行状态的多维度信息,从而导致预测结果存在偏差。基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法综合了欧氏空间和非欧氏空间的潜在关系,实现了互补信息。其多角度的汇总,使模型能够更全面地理解发动机的退化过程,进而对发动机的剩余使用寿命做出更为精准的预测。

对于 FD002 数据集,基于 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法的 R^2 为 0.979 2,这说明对导致发动机退化的原因的解釋率为 97.92%,而其他因素导致发动机退化的概率为 2.08%。相对于 GRU 和 GraphSAGE,所提方法的 R^2 分别改善了 1.17% 和 0.07%。 E_{RMSE} 为 4.271 3,相对于 GRU 和 GraphSAGE 分别下降 34.41% 和 27.68%; E_{MAPE} 为 0.0262,相对于 GRU 和 GraphSAGE 分别降低

30.87% 和 15.21%。其他 3 个数据集的结果见表 2。




图 7 FD002 数据集上部分航空发动机的预测结果

Fig. 7 Prediction results of some aeroengines in the FD002 dataset

不同方法的计算时间如图 8 所示。由图 8 可知,在 4 个数据集中,所有方法在 FD003 数据集上的测试时间最短,这是因为 FD003 数据集的测试样本是最少的。FD004 的测试时间最长,这是因为在 FD004 中的

测试样本最多,并且故障模式的多样化导致训练的模型更为复杂。具体的测试时间结果如表 2 所示。由表 2 可知,在 4 个数据集中,Parallel-GraphSAGE-GRU 的计算时间都比仅使用 GraphSAGE 或 GRU 的长,这是因为同时考虑欧氏空间和非欧氏空间导致模型更加复杂,但它们都处于同一量级,计算时间均小于 0.1 s,测试时间远小于工程需求(10 s)^[15]。通过改善硬件的水平,可改善所提方法的计算效率。




图 8 不同数据集上不同方法的测试时间

Fig. 8 Testing time of different methods on different datasets

表 2 消融试验结果

Tab. 2 Results of the ablation study

数据集	不同算法	R^2	E_{RMSE}	E_{MAPE}	时间/s
FD001	Parallel-GraphSAGE-GRU	0.983 9	6.961 7	0.019 7	0.043 2
	GRU	0.964 4	10.531 7	0.065 4	0.023 4
	GraphSAGE	0.973 5	9.080 2	0.056 6	0.031 5
FD002	Parallel-GraphSAGE-GRU	0.979 2	4.271 3	0.026 2	0.052 1
	GRU	0.967 9	5.433 4	0.037 9	0.027 3
	GraphSAGE	0.972 2	5.051 3	0.030 9	0.035 1
FD003	Parallel-GraphSAGE-GRU	0.988 6	8.719 7	0.043 5	0.032 5
	GRU	0.973 6	13.295 8	0.066 9	0.014 5
	GraphSAGE	0.978 2	12.061 7	0.061 7	0.023 2
FD004	Parallel-GraphSAGE-GRU	0.986 5	10.438 2	0.067 7	0.091 3
	GRU	0.974 4	13.588 2	0.088 1	0.055 3
	GraphSAGE	0.971 2	14.512 3	0.091 3	0.069 4

为了进一步验证所提方法的有效性和先进性,将 Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法与经典的算法[卷积神经网络(Convolutional Neural Network, CNN)、图卷积神经网络(Graphical Convolutional Neural Network, GCN)、长短期记忆神经网络(Long Short-Term Memory, LSTM)、极度梯度提升树(Extreme Gradient Boosting Tree, XGBoost)]和先进的算法[合并内存的记忆门控循环单元(Consolidated Memory Gated Recurrent Unit, CMGRU)]进行对比。详细的对比结果如表 3 所示。由表 3 可知,相对于传统方法,Parallel-GraphSAGE-GRU 的航空发动机剩余使用寿命预测方法在 4 个数

数据集上都取得较好的结果, 尽管FD001和FD003的运行状态单一, FD002和FD004数据集的运行状态则相对复杂。所提模型在处理这些数据时, 能够识别出航空发动机退化过程潜在的模式和规律, 从而完成有效的剩余使用寿命的预测。

表3 不同算法的对比结果

Tab. 3 Comparison results of different algorithms

数据集	不同算法	R^2	E_{RMSE}	E_{MAPE}
FD0001	Parallel-GraphSAGE-GRU	0.983 9	6.961 7	0.019 7
	CNN	0.952 8	12.131 5	0.077 0
	GCN	0.973 0	8.722 7	0.048 7
	CMGRU	0.980 1	7.352 4	0.025 7
	LSTM	0.974 2	8.945 3	0.052 1
	XGBoost	0.936 6	14.045	0.090 1
FD0002	Parallel-GraphSAGE-GRU	0.979 2	4.271 3	0.026 2
	CNN	0.952 3	13.237 6	0.076 9
	GCN	0.973 2	9.959 7	0.060 7
	CMGRU	0.984 4	7.573 8	0.043 1
	LSTM	0.964 1	11.489 8	0.066 5
	XGBoost	0.937 5	15.167 6	0.090 4
FD0003	Parallel-GraphSAGE-GRU	0.988 6	8.719 7	0.043 5
	CNN	0.961 1	16.142 4	0.103 9
	GCN	0.964 6	15.395 1	0.078 9
	CMGRU	0.979 9	11.581 9	0.061 2
	LSTM	0.952 3	17.875 5	0.093 2
	XGBoost	0.913 5	24.071 7	0.070 8
FD004	Parallel-GraphSAGE-GRU	0.986 5	10.438 2	0.067 7
	CNN	0.976 1	13.738 4	0.093 1
	GCN	0.960 7	17.846 2	0.120 1
	CMGRU	0.969 3	15.776 4	0.103 7
	LSTM	0.962 1	17.519 7	0.119 1
	XGBoost	0.934 6	23.010 7	0.123 4

5 结论

针对航空发动机RUL预测不准确且忽略了拓扑空间潜在信息的问题, 提出了一种基于Parallel-GraphSAGE-GRU的航空发动机剩余使用寿命预测方法, 获取发动机的监测参数与RUL之间的映射关系, 从而改善航空发动机剩余使用寿命的预测精度。通过C-MAPSS数据集, 验证所提方法的有效性和先进性, 得到以下主要结论:

1) 通过最大互信息法描述非欧氏空间中航空发动机的HIs之间的潜在关系的同时, 为欧氏空间描述航空发动机退化过程引入更多拓扑关系。

2) GraphSAGE被引入以获取航空发动机退化过程中的变化关系, 利用邻居采样聚合的方式生成发动

机退化过程的拓扑关系, 在保证有效获取退化关系的同时, 缩短了计算时间。

3) 通过与其他剩余使用寿命预测方法相比, Parallel-GraphSAGE-GRU能够获得更优的 R^2 、 E_{RMSE} 、 E_{MAPE} , 这说明所提方法具有更好的预测精度和鲁棒性。

参考文献 (References)

- [1] 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): 301-312.
Mu Hanxiao, Zheng Jianfei, Hu Changhua, et al. Remaining useful life prediction of multivariate degradation equipment based on CDBN and BiLSTM[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(7): 301-312. (In Chinese)
- [2] 刘业峰, 王帅, 刘晶晶, 等. 基于TCN-SA和Bi-GRU的轴承剩余寿命预测[J]. 计算机集成制造系统, 2026, 32(4): 1428-1437.
Liu Yefeng, Wang Shuai, Liu Jingjing, et al. Bearing remaining life prediction based on TCN-SA and Bi-GRU[J]. Computer Integrated Manufacturing Systems, 2026, 32(4): 1428-1437. (In Chinese)
- [3] 高旭东, 胡昌华, 张建勋, 等. 基于分数布朗运动过程模型的混合随机退化设备剩余寿命预测[J]. 自动化学报, 2023, 49(9): 1989-2002.
Gao Xudong, Hu Changhua, Zhang Jianxun, et al. Remaining useful life prediction for mixed stochastic deteriorating equipment based on fractional Brownian motion process[J]. Acta Automatica Sinica, 2023, 49(9): 1989-2002. (In Chinese)
- [4] 席霄鹏, 陈茂银, 周东华. 基于多速率传感器测量数据的剩余寿命预测[J]. 控制工程, 2020, 27(5): 771-775.
Xi Xiaopeng, Chen Maoyin, Zhou Donghua. Remaining useful life prediction based on multirate sensor measurement data[J]. Control Engineering of China, 2020, 27(5): 771-775. (In Chinese)
- [5] 张鲁一航, 杨彦明, 陈永展, 等. 基于VMD-CNN-BiLSTM的变工况涡扇发动机剩余使用寿命预测[J]. 北京航空航天大学学报, 2026, 52(4): 1279-1289.
Zhang Luyihang, Yang Yanming, Chen Yongzhan, et al. Remaining useful life prediction of variable-operating turbofan engine based on VMD-CNN-BiLSTM [J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(4): 1279-1289. (In Chinese)
- [6] 吴嘉俊, 苏春, 张玉茹. 基于双重自注意力机制和长短期记忆网络的剩余寿命预测[J]. 系统工程与电子技术, 2024, 46(6): 1986-1994.
Wu Jiajun, Su Chun, Zhang Yuru. Remaining useful life prediction based on double self-attention mechanism and long short-term memory network[J]. Systems Engineering and Electronics, 2024, 46(6): 1986-1994. (In Chinese)
- [7] 兰杰, 李宁, 李志宁, 等. 基于GRU Encoder-decoder和注意力机制的RUL预测方法[J]. 现代电子技术, 2023, 46(8): 99-105.
Lan Jie, Li Ning, Li Zhining, et al. Method of RUL prediction based on GRU Encoder-decoder and attentional mechanism [J]. Modern Electronics Technique, 2023, 46(8): 99-105. (In Chinese)
- [8] Qiu Z W, Li W L, Tang T, et al. Denoising graph neural network

- based hydraulic component fault diagnosis method[J]. Mechanical Systems and Signal Processing, 2023, 204: 110828.
- [9] 叶欣,王东锋,齐建军,等. 基于 IVMD 及 GNN 的外啮合齿轮泵剩余寿命预测研究[J]. 液压气动与密封, 2022, 42(8): 9-17.
- Ye Xin, Wang Dongfeng, Qi Jianjun, et al. Research on residual life prediction of external gear pump based on IVMD and GNN[J]. Hydraulics Pneumatics & Seals, 2022, 42(8): 9-17. (In Chinese)
- [10] Liu J L, Ong G P, Chen X Q. GraphSAGE-based traffic speed forecasting for segment network with sparse data [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(3): 1755-1766.
- [11] 柴同,袁逸萍,马军岩,等. 基于 K-CNN 和 N-GRU 的风电机组发电机状态预测[J]. 机械强度, 2023, 45(5): 1043-1049.
- Chai Tong, Yuan Yiping, Ma Junyan, et al. State prediction of wind turbine generator based on K-CNN and N-GRU [J]. Journal of Mechanical Strength, 2023, 45(5): 1043-1049. (In Chinese)
- [12] 刘庆江,孙春亮,周继昌,等. 融合 Attention 和 GRU 的压缩机组故障预警技术研究[J]. 石油工程建设, 2024, 50(4): 35-39.
- Liu Qingjiang, Sun Chunliang, Zhou Jichang, et al. Fault warning technology for compressor unit based on integration of Attention and GRU [J]. Petroleum Engineering Construction, 2024, 50(4): 35-39. (In Chinese)
- [13] 林荣祥,王海瑞,朱贵富. 一种融合神经网络的航空发动机寿命预测方法研究[J]. 机械科学与技术, 2025, 44(11): 2034-2046.
- Lin Rongxiang, Wang Hairui, Zhu Guifu. An aero-engine life prediction method incorporating neural networks [J]. Mechanical Science and Technology for Aerospace Engineering, 2025, 44(11): 2034-2046. (In Chinese)
- [14] 秦子轩,张晓东,白广芝,等. 基于多尺度特征融合的航空发动机剩余寿命预测[J]. 航空发动机, 2024, 50(4): 114-120.
- Qin Zixuan, Zhang Xiaodong, Bai Guangzhi, et al. Aeroengine remaining useful life prediction based on multi-scale feature fusion [J]. Aeroengine, 2024, 50(4): 114-120. (In Chinese)
- [15] Zhou J H, Qin Y, Luo J, et al. Remaining useful life prediction by distribution contact ratio health indicator and consolidated memory GRU [J]. IEEE Transactions on Industrial Informatics, 2023, 19(7): 8472-8483.

Remaining useful life prediction of aeroengine based on Parallel-GraphSAGE-GRU

GUO Wenwen^{1,2} WANG Guohu^{1,2} YUAN Yongliang³ WANG Peiying¹ GUO Yinxiao¹

(1. School of Mechatronics Engineering, Zhengzhou University of Industrial Technology, Zhengzhou 451150, China)

(2. Henan Engineering Research Center of Tunnel Engineering Machinery, Zhengzhou 451150, China)

(3. School of Mechanical and Power Engineering, Henan Polytechnic University, Jiaozuo 454003, China)

Abstract: [Objective] Deep learning-based remaining useful life (RUL) prediction of aeroengine provides a foundation for guaranteeing the reliability of the aeroengine. However, most researches are devoted to the acquisition of degenerate information in Euclidean space, while topological relations in non-Euclidean space can provide additional degenerate information. Thus, a novel RUL prediction method named parallel graph node embedding learning-gated recurrent unit (Parallel-GraphSAGE-GRU) was proposed in this work. [Methods] Firstly, the maximum mutual information method was used to describe the relationships among monitoring parameters of aeroengine. Then, a series of graph inputs was constructed using a fixed time window to obtain topological relations in the non-Euclidean space of the aeroengine. Besides, GRU was used for the acquisition the temporal degradation relations of the monitoring parameters for aeroengine in the Euclidean space. The implicit vectors of GraphSAGE and GRU at each moment were concatenated and mapped to the RUL values of the input degradation information by fully connected neural network. The C-MAPSS dataset was used to validate the effectiveness and advancement of the proposed method, and the best R^2 of the proposed method reached 0.988 6. [Results] The results indicate that this method is feasible in ensuring prediction accuracy and computational efficiency.

Key words: Engine; Remaining useful life; Feature information extraction; Graph node embedding learning; Gated recurrent unit

Corresponding author: GUO Wenwen, E-mail: gzh47702@163.com

Fund: National Natural Science Foundation of China (52404163); Science and Technology Plan Project of Henan Province (252102220079, 252102221003); New Phase Henan Provincial Key Discipline (Mechanical Engineering) (EDU [2023] 414); Henan Provincial Key Research Project in Higher Education Institutions (25B460020)

Received: 2025-02-28 Revised: 2025-05-30

(编辑:刘欢欢)