

DOI:10.19651/j.cnki.emt.2519285

基于分布式时空卷积网络的航空发动机剩余使用寿命预测*

吕志云 郭晨霞 杨瑞峰

(中北大学仪器与电子学院 太原 030051)

摘要:为解决当前数据驱动航空发动机 RUL 预测方法因未能充分挖掘数据特征信息,导致数据利用率低、预测精度受限的问题,提出一种新型发动机 RUL 多尺度预测模型,称为 DSCN。所提出方法首先通过计算皮尔逊相关系数和最大信息系数捕捉发动机数据的线性及非线性关系,得到平稳与非平稳时序的趋势特征;其次,利用 MRFM 丰富数据特征,并在 TCN 基础上构建 Res-CAM 和 MHAM 增强模型对关键信息的捕捉能力,动态调整数据的动态权重。所提出方法在 C-MAPSS 数据集中 FD001 和 FD003 上进行试验验证,预测结果中 RMSE 和 Score 分别为 11.30、218.08;12.04、227.65。结果表明,该方法比目前最优方法在 Score 上分别降低了 4.67% 和 11.5%。

关键词: 航空发动机;剩余使用寿命;分布式时空卷积网络;残差通道注意力;多头注意力机制

中图分类号: TN807;TP319.5 **文献标识码:** A **国家标准学科分类代码:** 460.4030

Distributed spatio-temporal convolutional network for remaining useful life prediction of turbofan engines

Lyu Zhiyun Guo Chenxia Yang Ruifeng

(School of Instrumentation and Electronics, North University of China, Taiyuan 030051, China)

Abstract: To address the current limitations in data-driven remaining useful life (RUL) prediction methods for turbofan engines, which suffer from low data utilisation and constrained prediction accuracy due to inadequate exploitation of data feature information, a novel multi-scale RUL prediction model for engines is proposed. This model is termed the distributed spatio-temporal convolutional network (DSCN). The proposed method first captures linear and non-linear relationships in engine data by calculating Pearson correlation coefficients and maximum information coefficients, thereby obtaining trend features for both stationary and non-stationary time series. Secondly, it employs a multi-scale residual fusion module to enrich data features. Building upon temporal convolutional network (TCN), it incorporates residual channel attention module (Res-CAM) and multi-head attention module (MHAM) to enhance the model's ability to capture critical information, dynamically adjusting the weights of the data. The proposed method was experimentally validated on the FD001 and FD003 datasets within the C-MAPSS collection, yielding RMSE and Score values of 11.30 and 218.08; 12.04 and 227.65 respectively. Results indicate that this approach reduces the Score by 4.67% and 11.5% compared to the current state-of-the-art method.

Keywords: turbofan engines; remaining useful life; distributed spatio-temporal convolutional network; residual channel attention; multi-head attention module

0 引言

如今,预测和健康管理(prediction and health management, PHM)对于提高设备可靠性和降低维护成本至关重要。剩余使用寿命(remaining useful life, RUL)预

测作为 PHM 中的重要部分而在被广泛研究^[1-2]。航空发动机作为现代航空的重要组成部分,在航空航天中发挥着重要作用,通过准确预测航空发动机的剩余使用寿命,能显著提升飞行安全、降低运维成本,并为智能化的预测性维护提供关键支撑。

收稿日期:2025-07-04

* 基金项目:山西省中央引导地方科技发展自由探索类基础研究项目(YDZJ SX2022A027)资助

RUL 的预测方法主要分为两类:基于物理模型的方法和数据驱动的方法^[3-4]。基于物理模型的方法需要通过根据设备的失效机理进行物理和数学建模。但其需要精确的失效机理知识,且容易受到工况的影响。数据驱动可以通过挖掘传感器历史数据中潜在的退化趋势。传统的数据驱动方法可以分为统计方法和机器学习方法。统计方法以概率与数理统计为基础,如使用 Wiener 过程和马尔可夫链的方法实现 RUL 预测^[5],但统计方法在复杂多变的工况下预测精度有限。随着信号收集和计算机技术的发展,从运行的机械设备中获取大量工业数据成为可能,从而加速了数据驱动的健康监测方法的发展。Liu 等^[6]结合小波变换和卷积神经网络(convolutional neural networks, CNN)来预测轴承 RUL,其中小波变换首先用于提取时频特征,然后采用多尺度 CNN 提取局部特征来估计 RUL。然而这种方法缺乏解决数据长期依赖问题的能力,在进行航空发动机 RUL 预测任务中,这种能力是不可或缺的。张菀等^[7]使用注意力增强长短期记忆网络(long short-term memory, LSTM)有效捕捉长序列数据的长期依赖关系,通过协方差相关性分析优化特征权重,捕捉传感器数据的非线性退化模式,却忽略了数据的上下文关系。Coursey 等^[8]提出双向长短期记忆网络(bidirectional long short-term memory, BiLSTM),采用独立标准化方法处理各发动机实例,解决数据分布不均问题,充分利用了 BiLSTM 在全寿命数据中捕捉上下文长期依赖关系的能力。Zhao 等^[9]利用 CNN 从获取的多传感器数据中提取局部鲁棒特征,并结合 BiLSTM 捕获时序前后文依赖,为实现刀具磨损的实时监测与维护提供了高效的预测方案,但在处理长序列时序数据时,BiLSTM 的递归结构易引发梯度消失问题。对此,潘雪娇等^[10]提出了一种基于自注意力机制和时间卷积网络的预测模型,该模型通过时域卷积网络(temporal convolutional network, TCN)捕获时间依赖性,避免递归计算导致的梯度问题,并使用自注意力机制自适应地为时间特征分配权重,从而提高了 RUL 预测的准确性,但该模型中单一的自注意力模块在处理复杂时序数据时,难以全面刻画长短期依赖关系的层级特征,且注意力机制的分布性不足可能会导致特征权重分配不够精细。针对这一局限,Song 等^[11]提出一种基于分布式注意力机制的时域卷积网络(distributed attention-based temporal convolutional network, DA-TCN),通过引入多分支注意力模块有效弥补了单一注意力模块在捕获不同时间尺度下退化特征的不足,同时结合 TCN 的时序建模能力实现高精度 RUL 预测。

然而,上述研究均聚焦于传感器数据时间维度上的特征提取,忽略了多个传感器之间存在的空间关系,无法充分利用传感器的空间特征。这种研究局限性在复杂场景中尤为明显,仅依赖时间序列分析无法显式建模传感器间的空间关系、动态工况及退化过程的时空协同特征,导致复杂场

景下预测精度下降^[12-13]。针对现有研究的局限性,本文提出了一种基于分布式时空卷积网络(distribution spatio-temporal convolutional network, DSCN)的 RUL 预测模型。首先通过计算皮尔逊相关系数和最大信息系数获取数据的潜在特征,利用多尺度残差融合模块(multi-scale residual fusion module, MRFM)丰富数据在时间维度上的特征。其次,设计了分布式时空卷积架构,从而实现对复杂多维数据中空间关联性与时空动态性的协同建模。具体来说,分布式时空卷积架构在时间维度利用多头注意力机制(multi-head attention module, MHAM)解析长序列信号的长期依赖模式,在空间维度通过残差通道注意力(residual channel attention module, Res-CAM)获取传感器阵列的空间相关性权重。最后经全连接层实现 RUL 的预测。与现有的深度学习方法相比,所提出的模型在捕捉复杂多维数据中的关键特征和处理长时间序列依赖关系方面具有显著优势,从而提升了 RUL 预测的精度和鲁棒性。

1 分布式时空卷积网络(DSCN)

本文所提出网络模型的主要框架如图 1 所示,该方法包含四个主要的子结构,即多尺度残差融合模块、加权不同时间步长的多头注意力机制、用于特征提取的 TCN、空间上加权不同传感器的残差通道注意力机制。多尺度残差融合模块挖掘时序数据中的潜在信息,与原始数据进行残差连接解决梯度消失的问题,提高模型泛化能力,使用时间多头注意力机制评估数据在不同时间步长中的贡献。为了在时间维度上提取到不同传感器间的隐含信息,引入用于特征表示的时域卷积网络。空间上残差通道注意力能避免重要信息的丢失并根据每一个传感器对 RUL 预测的贡献进行加权。最后输出到全连接层用于 RUL 预测。




图 1 网络架构图

Fig. 1 Architecture diagram of the network

1.1 多尺度残差融合模块(MRFM)

多尺度残差融合在初始层后面并行引入 3 个不同膨胀率的空洞卷积,用于处理输入特征,提高特征提取效率,其膨胀率分别为 $r = 1, 2, 4$ 每个卷积核捕获不同尺度的局部细节,最后通过残差融合获得多尺度表示,具体细节如图 2 所示。

MRFM 通过式(1)中的残差连接对不同尺度提取到的特征进行融合,既保留了原始输入中的关键信息,又增强了每个尺度下的独有特征,经 Add 层进行加法融合的特征整

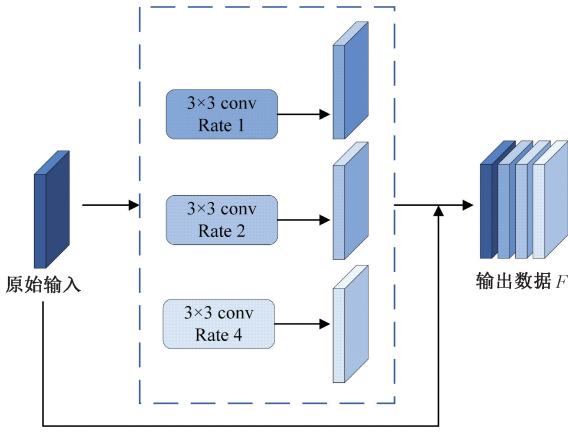


图2 MRFM结构图

Fig. 2 Structure diagram of the MRFM

合了更全面的发动机退化状态信息,能够有效提升预测模型的准确性。

$$Y_{\text{Add}} = \sum (y_1^i + y_2^i + y_3^i) \quad (1)$$

式中: Y_{Add} 表示最终的输出数据, y_1^i, y_2^i, y_3^i 分别表示来自MSFM中的3个不同卷积核的第*i*个通道的特征图。

1.2 加权不同时间步长的多头注意力机制(MHAM)

针对时间序列的复杂性,传统模型难以同时捕捉不同时间尺度的数据特征,采用多头注意力机制提取数据中时间维度上的相关性信息,如图3所示。该机制基于缩放Hadamard积注意力模型架构,通过构建多个独立的子空间,每个注意力头针对特定的特征交互模式进行独立建模,在完成各子空间的特征关联计算后,将各头的输出结果在Concat层按维度拼接,形成包含多视角特征依赖关系的综合注意力表示,其数学表达如下:

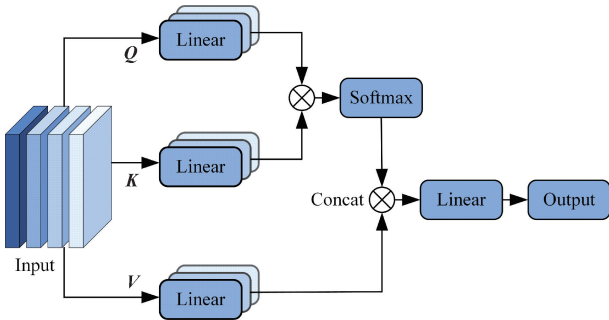


图3 多头注意力结构图

Fig. 3 Structure diagram of the multi-head attention

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (2)$$

$$\mathbf{Q} = \mathbf{F}\mathbf{W}^Q \quad (3)$$

$$\mathbf{K} = \mathbf{F}\mathbf{W}^K \quad (4)$$

$$\mathbf{V} = \mathbf{F}\mathbf{W}^V \quad (5)$$

$$\text{MHA}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)\mathbf{W}^O \quad (6)$$

式中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别表示查询矩阵、键矩阵、数值矩阵; d_k 表

示矩阵维度,缩放因子 $\sqrt{d_k}$ 用于避免点积结果过大导致Softmax层梯度消失; \mathbf{F} 表示经上一层处理输出的数字矩阵; $\mathbf{W}^Q, \mathbf{W}^K, \mathbf{W}^V$ 分别表示 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 的权重矩阵; 每个 head_i 对应一个缩放Hadamard积注意力头; \mathbf{W}^O 表示当前的权重矩阵。

1.3 用于特征表示的时间卷积模块(TCN)

TCN是专为时序数据特征表示设计的深度神经网络架构,核心由因果、扩张卷积和残差连接构成。其优势在于通过因果卷积确保当前时刻的特征仅依赖历史信息,避免未来数据泄露,满足时序预测任务的因果逻辑,同时通过分层扩张卷积核能够在有限层数内捕获长距离时间依赖。TCN的网络结构如图4所示。

1.4 对不同传感器加权的空间残差通道注意力(Res-CAM)

残差通道注意力是在通道注意力机制的基础上引入了残差连接,使用通道注意力对上一层TCN输出的特征图在通道维度上进行处理。借助残差连接将加权后的新特征与原始输入结合,避免关键信息被抑制,并缓解了梯度消失的问题,提高模型稳定性。其结构图如图5所示。

首先对特征数据 F 分别进行平均池化和最大池化,经共享多层感知机(Multilayer Perceptron, MLP)处理后同位元素相加,并由Sigmoid激活函数得到通道注意力权重 $M_c(F)$,其原理表示为:

$$F_{\text{avg}}^c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F^c(i, j) \quad (7)$$

$$F_{\text{max}}^c = \max_{i,j} F^c(i, j) \quad (8)$$

$$M_c(F) = \sigma(W_2 \cdot \delta(W_1 \cdot F_{\text{avg}}^c)) + \sigma(W_2 \cdot \delta(W_1 \cdot F_{\text{max}}^c)) \quad (9)$$

$$F' = M_c(F) \otimes F \quad (10)$$

式中: F_{max}^c 和 F_{avg}^c 分别为特征 F 的最大池化和平均池化结果; δ 为共享多层感知机; σ 为Sigmoid激活函数; W_1, W_2 为多层感知机网络的权重系数; $M_c(F)$ 为获取到的通道权重; F' 为经逐通道相乘后的新特征。

2 实验设计

2.1 数据集介绍

本研究采用的商用模块化航空推进系统仿真数据集(C-MAPSS)是RUL预测实验中广泛使用的数据集^[14-16]。该数据集用于模拟真实发动机的退化状况,如图6所示,并记录了不同失效模式下涡扇发动机的退化数据^[17]。在图6中可以看出,由各个传感器在发动机上的位置分布是相互影响的,因此,考虑传感器之间的空间关系,充分利用其空间特征对于RUL的预测至关重要。

C-MAPSS数据集包含FD001-FD004 4个子数据集,本文选用FD001和FD003用于实验验证,数据信息如表1所示。在涡扇发动机的生命周期内收集21个传感器的RUL值和运行数据,但并非所有传感器的数据都对寿命预测有意义。因此,剔除编号为1、5、6、10、16、18、19的传感器数据,将剩余数据作为实验的输入^[18-19]。

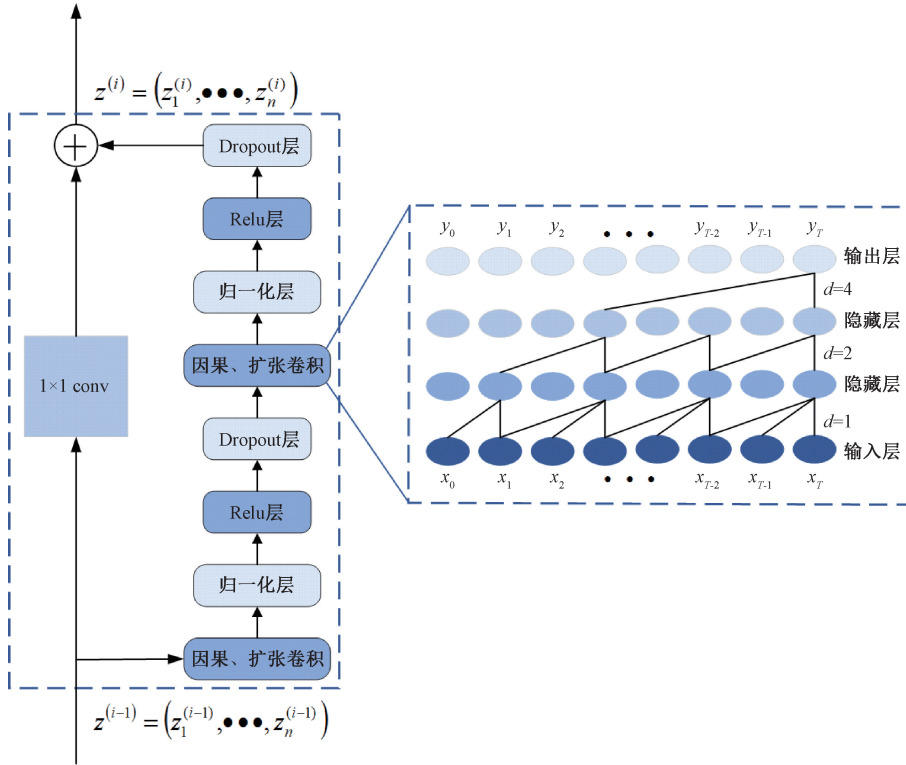


图 4 TCN 模块结构图

Fig. 4 Structure diagram of the TCN module

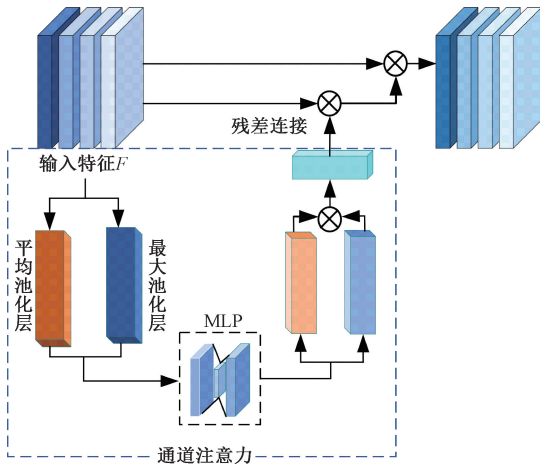


图 5 残差通道注意力

Fig. 5 Residual channel attention

2.2 数据预处理

为了使不同的传感器数据之间具有可比性,本文使用最大最小归一化对传感器数据统一量纲^[20],归一化公式如式(12)所示。

$$x_i' = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (11)$$

式中: x_i 表示第 i 个传感器数据, $\max(x_i)$ 和 $\min(x_i)$ 分别表示传感器数据在当前时间步长中的最大值和最小值。




图 6 发动机示意图

Fig. 6 Engine schematic diagram

在处理后的传感器数据中,提取出传感器的最大信息系数(MIC)、皮尔逊相关系数(ρ),从不同角度捕捉数据的关键信息,量化数据的变化趋势,提取到的信息与原始数据融合作为输入数据。相关公式如下:

$$MIC(X, Y) = \max_{X_G * Y_G < n^{0.6}} \frac{I(X_G, Y_G)}{\log_2 \min(|X_G|, |Y_G|)} \quad (12)$$

$$I(X_G, Y_G) = \sum_{X_G \in XY_G \in Y} \sum_{Y_G} p(X_G, Y_G) \log \left(\frac{p(X_G, Y_G)}{p(X_G)p(Y_G)} \right) \quad (13)$$

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X\sigma_Y} = \frac{\sum_{i=1}^n (X_{G_i} - \bar{X}_G)(Y_{G_i} - \bar{Y}_G)}{\sqrt{\sum_{i=1}^n (X_{G_i} - \bar{X}_G)^2} \sqrt{\sum_{i=1}^n (Y_{G_i} - \bar{Y}_G)^2}} \quad (14)$$

式中: X, Y 表示不同的传感器数据, G 表示当前时间步, $p(\cdot)$ 表示其概率分布, n 表示当前时间步包含的样本数。

表1 数据集信息

Table 1 Dataset information

数据集	FD001	FD003
训练集发动机数量	100	100
测试集发动机数量	100	100
工况数量	1	1
故障模式	1	2
训练集样本数	17 731	21 820
测试集样本数	10 196	13 696

2.3 评价指标

在航空发动机健康管理中, C-MAPSS 数据集常用的评价指标有均方根误差(Root Mean Square Error, RMSE)和性能评分函数 Score^[21], 定义公式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \Delta y_i^2} \quad (15)$$

$$Score = \begin{cases} \sum_{i=1}^N (e^{-\frac{\Delta y_i}{13}} - 1), & \Delta y_i < 0 \\ \sum_{i=1}^N (e^{\frac{\Delta y_i}{10}} - 1), & \Delta y_i \geq 0 \end{cases} \quad (16)$$

式中: Δy_i 表示第 i 个样本的 RUL 真实值与预测值之间的差值。

RMSE 是衡量预测值与真实值偏差的重要指标, 其数值越小, 表明预测值与真实值的吻合度越高^[22]。然而, RMSE 仅能反映误差的整体离散程度, 无法区分预测值与真实值的相对大小关系。高估可能因未能及时预警故障, 引发安全隐患甚至更严重的后果; 低估会导致提前预警, 造成不必要的资源浪费。因此引入 Score 指标, 通过增大对高估的惩罚力度, 更精准地评估预测结果的实际价值。Score 衡量了模型拟合 RUL 预测值与实际值的能力, 当 Score 值越低时, 表明预测结果的误差更小、应用到实际工程后提前预警的时效性更强, 因此, 可以间接表明在避免滞后风险和资源浪费方面表现更优^[23]。

2.4 实验参数设置

训练和测试过程是使用 Keras 实现的, 该 Keras 在 NVIDIA GeForce RTX 4070 显卡上的 TensorFlow 上运行。将经过预处理的数据输入进基础网络中进行训练, 通过网格搜索策略, 得到网络最优参数, 如表 2 所示。这些

超参数经多次实验结果调优后确定, 最终使模型在 C-MAPSS 数据集上实现了 RUL 预测性能的最优表现。

表2 DSCN 参数

Table 2 DSCN parameters

模块	参数	数值
多尺度残差	卷积核个数	64
	扩张率	1/2/4
	卷积核大小	3
时间多头注意力	头数	8
	维度	128
	TCN	卷积核大小
通道注意力	扩张率	1/2/4
	卷积核个数	64
	降维比例	4
全连接层	全连接层 1	100(ReLU)
	全连接层 2	20(ReLU)
超参数	Dropout	0.2
	输出层	1
	损失函数	RMSE
	优化器	Adam
	学习率	0.001(epochs \geq 80) 0.01(epochs<80)

3 实验结果

图 7、8 分别展示了 FD001 和 FD003 数据集中 100 台发动机的 RUL 预测结果。从图中可以看出, 测试结果与真实值之间误差较小, 验证了本文构建的预测模型对飞机发动机 RUL 预测的有效性。




图7 FD001 预测结果

Fig. 7 FD001 prediction result

从测试集中随机选取两个发动机的测试样本, 其预测结果如图 9、10 所示。试验结果表明, 测试样本在早期阶段中, 该方法的预测值稳定在预设的常数阈值附近。随后, 预测值总体上呈现下降趋势, 直至测试周期结束。虽然在




图 8 FD003 预测结果

Fig. 8 FD003 prediction result

发动机退化的初期阶段,其预测值与真实值存在偏差,但当发动机临近完全退化时,预测结果展现出较高的准确性。




图 9 FD001 中发动机预测结果

Fig. 9 Engine prediction result in FD001




图 10 FD003 中发动机预测结果

Fig. 10 Engine prediction result in FD003

为验证所提方法的有效性,本文将其与当前主流的机器学习算法及文献中提出组合模型进行对比分析,对比结果列于表 3。实验表明,各方法在该数据集上均取得了良好的预测效果,而本文提出的预测模型,其预测性能优于其他方法。具体而言,该方法在 FD001 和 FD003 上预测

的 Score 得分较最优对比方法分别降低了 4.96% 和 11.4%。为评估所提模型中各模块对整体性能的贡献,本研究进行了消融实验,结果如表 4 所示。

表 3 对比试验

Table 3 Comparative tests

方法	FD001		FD003	
	RMSE	Score	RMSE	Score
Earlier CNN	18.45	1286.70	19.82	1596.20
CNN	12.61	273.70	12.64	284.10
LSTM	16.14	338.00	16.18	852.06
CNN-Bilstm	15.01	394.38	14.54	364.33
TCN	13.10	247.19	12.43	271.50
DA-TCN	11.78	229.48	11.56	257.11
Proposed method	11.30	218.08	12.04	227.65

表 4 消融试验

Table 4 Ablation tests

方法	FD001		FD003	
	RMSE	Score	RMSE	Score
TCN	13.10	247.19	12.43	271.50
TCN+MRFM+MHA	14.98	250.49	14.07	240.06
TCN+MRFM+ Res-CAM	13.88	234.73	14.26	238.26
TCN+ MHA+Res-CAM	14.72	226.58	15.21	257.41
TCN+MRFM+MHA+ Res-CAM	11.30	218.08	12.04	227.65

4 结 论

本文提出了一种新型的网络模型用于航空发动机剩余寿命预测。首先通过 MRFM 丰富数据中的时间特征,然后进入 DSCN 获取特征之间的时间依赖关系,利用 Res-CAM 捕获传感器间的空间关系。最后,对不同维度的输入特征进行动态加权,在保证不丢失原始特征的前提下突出重要特征,提升 RUL 预测精度。试验结果表明,该模型可以有效实现航空发动机的 RUL 预测。但受限于航空发动机的复杂工况和多种因素的影响,想要进一步提高精度和鲁棒性,未来的研究中将对模型的整合与预测方法进行优化,为复杂设备的 PHM 提供更多方案。

参考文献

[1] 徐硕,侯贵生. 基于 VAE-D2GAN 的涡扇发动机剩余使用寿命预测[J]. 计算机集成制造系统, 2022, 28(2): 417-425.
 XU SH, HOU G SH. Remaining useful life prediction of turbofan engine based on VAE-D2GAN [J]. Computer Integrated Manufacturing Systems, 2022, 28(2): 417-425.
 [2] 郭晓静, 俞玉晶, 徐晓慧. 基于深度学习方法的航空发

- 动机寿命预测模型[J]. 振动、测试与诊断, 2024, 44(2): 330-336, 412.
- GUO X J, YUN Y J, XU X H. Life prediction model of aero-engine based on deep learning method[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(2): 330-336, 412.
- [3] 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 CH Y. Engine remaining useful life prediction via fusion of multi-scale local features and Transformer global learning[J]. Acta Automatica Sinica, 2024, 50(9): 1818-1830.
- [4] 兰杰, 李志宁, 李宁, 等. 基于注意力机制和残差深度分离卷积的 RUL 预测方法[J]. 电子测量技术, 2023, 46(15): 149-157.
- LAN J, LI ZH N, LI N, et al. RUL prediction method based on attention mechanism and residual depthwise separable convolution[J]. Electronic Measurement Technology, 2023, 46(15): 149-157.
- [5] 郭庆, 李印龙, 郑天翔. 基于非线性 Wiener 过程航空发动机性能退化预测[J]. 推进技术, 2021, 42(9): 1956-1963.
- GUO Q, LI Y L, ZHENG T X. Performance degradation prediction of aero-engine based on nonlinear Wiener process[J]. Journal of Propulsion Technology, 2021, 42(9): 1956-1963.
- [6] LIU H, LIU ZH Y, JIA W Q, et al. Remaining useful life prediction using a novel feature-attention based end-to-end approach[J]. IEEE Transactions on Industrial Informatics, 2020, 17(2): 1197-1207.
- [7] 张苑, 张泰瑀, 贾民平, 等. 多传感器融合和 MHA-LSTM 的电机轴承剩余寿命预测[J]. 仪器仪表学报, 2024, 45(3): 84-93.
- ZHANG W, ZHANG T Y, JIA M P, et al. Remaining life prediction of motor bearings based on multi-sensor fusion and MHA-LSTM[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 84-93.
- [8] COURSEY A. Data-driven models for remaining useful life estimation of aircraft engines and hard disk drives[D]. Honors College Theses, 2022, 116.
- [9] ZHAO R, YAN R, WANG J, et al. Learning to monitor machine health with convolutional bi-directional LSTM networks[J]. Sensors, 2017, 17(2): 273.
- [10] 潘雪娇, 董绍江, 朱朋, 等. 基于 TCN 和残差自注意力的变工况下滚动轴承剩余寿命迁移预测[J]. 振动与冲击, 2024, 43(1): 145-152.
- PAN X J, DONG SH J, ZHU P, et al. Transfer prediction of remaining useful life of rolling bearings under variable conditions based on TCN and residual self-attention[J]. Journal of Vibration and Shock, 2024, 43(1): 145-152.
- [11] SONG Y, GAO S, LI Y, et al. Distributed attention-based temporal convolutional network for remaining useful life prediction[J]. IEEE Internet of Things Journal, 2021, 8(12): 9594-9602.
- [12] 曲桂娟, 刘冬阳, 杨旭, 等. 基于传感器时序信息增强的剩余寿命预测方法[J/OL]. 航空学报, 1-15[2025-09-08]. <https://link.cnki.net/urlid/11.1929.v.20250721.0858.002>.
- QU G X, LIU D Y, YANG X, et al. Remaining useful life prediction method based on sensor temporal information enhancement[J/OL]. Acta Aeronautica et Astronautica Sinica, 2025, 1-15[2025-09-08]. <https://link.cnki.net/urlid/11.1929.v.20250721.0858.002>.
- [13] LI T M, XIAO S S, SI Z J, et al. Data-model interactive remaining useful life prediction method for multi-sensor monitored linear stochastic degrading devices[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(5): 1234-1245.
- [14] 张鑫阳, 王可庆, 贾新旺, 等. 基于并行 TCN-SE-BiLSTM 模型的涡扇发动机剩余寿命预测[J]. 电子测量技术, 2024, 47(24): 179-187.
- ZHANG X Y, WANG K Q, JIA X W, et al. Remaining useful life prediction of turbofan engine based on parallel TCN-SE-BiLSTM model[J]. Electronic Measurement Technology, 2024, 47(24): 179-187.
- [15] 聂磊, 徐诗奕, 张吕凡, 等. 基于多头注意力机制的飞机发动机寿命预测研究[J]. 推进技术, 2023, 44(8): 192-200.
- NIE L, XU SH Y, ZHANG L F, et al. Research on aircraft engine life prediction based on multi-head attention mechanism[J]. Journal of Propulsion Technology, 2023, 44(8): 192-200.
- [16] 张加劲. 基于注意力机制和 CNN-BiLSTM 模型的航空发动机剩余寿命预测[J]. 电子测量与仪器学报, 2022, 36(8): 231-237.
- ZHANG J J. Remaining useful life prediction of aero-engine based on attention mechanism and CNN-BiLSTM model[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 231-237.
- [17] GU Y, WYLIE B, BOYTE S, et al. An optimal sample data usage strategy to minimize overfitting and underfitting effects in regression tree models based on remotely-sensed data[J]. Remote Sensing, 2016,

- 8(11): 943.
- [18] 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 Z X, ZHANG X D, BAI G ZH, et al. Remaining useful life prediction of aero-engine based on multi-scale feature fusion[J]. Aeroengine, 2024, 50(4): 114-120.
- [19] ZHU Y, WANG H, LIU J, et al. Remaining useful life prediction approach based on data model fusion: An application in rolling bearings[J]. IEEE Sensors Journal, 2024, 24(24): 42230-42244.
- [20] 万忠义, 吴开平, 徐彬, 等. 基于多维时序融合特征的滚动轴承剩余使用寿命预测[J]. 制造技术与机床, 2025(2): 9-16.
WAN ZH Y, WU K P, XU B, et al. Remaining useful life prediction of rolling bearings based on multi-dimensional temporal fusion features[J]. Manufacturing Technology & Machine Tool, 2025(2): 9-16.
- [21] HUANG K, JIA G, JIAO Z, et al. MSEvoNet: Multiscale spatiotemporal evolution networks for remaining useful life prediction in complex industrial systems[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-17.
- [22] 武滢, 韦康, 杨帅军. 基于蝗虫优化 LSTM 网络的滚动轴承剩余寿命预测[J]. 制造技术与机床, 2024(5): 35-41.
WU Y, WEI K, YANG SH J. Remaining life prediction of rolling bearings based on locust-optimized LSTM network [J]. Manufacturing Technology & Machine Tool, 2024(5): 35-41.
- [23] 章东平, 王大为, 何数技, 等. 基于跨维度特征融合的航空发动机寿命预测[J]. 浙江大学学报(工学版), 2025, 59(7): 1504-1513.
ZHANG D P, WANG D W, HE SH J, et al. Aero-engine life prediction based on cross-dimensional feature fusion [J]. Journal of Zhejiang University (Engineering Science), 2025, 59(7): 1504-1513.

作者简介

吕志云, 硕士, 主要研究方向为机械设备的寿命预测, 故障诊断。

E-mail: 2769635883@qq.com

郭晨霞(通信作者), 博士, 副教授, 主要研究方向为自动化测试技术, 视觉测量技术。

E-mail: guochenxia@nuc.edu.cn

杨瑞峰, 博士, 教授, 主要研究方向为自动化测试与控制技术、智能仪器、装备试验检测与系统集成。

E-mail: yangruifeng@nuc.edu.cn