

DOI:10.19651/j.cnki.emt.2211132

# 基于注意力机制和残差深度分离卷积的 RUL 预测方法

兰杰<sup>1</sup> 李志宁<sup>1</sup> 李宁<sup>2</sup> 吕建刚<sup>1</sup>

(1.陆军工程大学石家庄校区 石家庄 050003; 2.陆军工程大学军械士官学校 武汉 430000)

**摘要:** 传统机械设备剩余使用寿命(RUL)预测方法需进行多源数据融合、建立健康指标等人工干预过程,预测精度受限于健康指标对设备退化过程的表征能力。为实现端对端的 RUL 预测并提升预测精度,提出了一种基于注意力机制和残差深度分离卷积网络相结合的 RUL 方法,并采用 C-MAPSS 航空发动机仿真数据集检验方法的有效性。采用滑动窗从发动机多源状态参数中截取多元序列作为表征发动机状态的样本,并基于一维可分离卷积网络建立 RUL 预测模型,为提升模型的预测精度在网络中引入了注意力机制和残差网络。最终所提方法对 C-MAPSS 4 个测试集的均方根误差均值分别为 11.28、14.12、11.57 和 15.61,且对发动机在运行期间的 RUL 预测也具有较好的泛化能力。通过与多种 RUL 预测方法的结果相比较,表明所提方法对 4 个测试集的整体预测精度均较高,是一种有效的机械设备 RUL 预测方法,并可用于设备的早期故障预警。

**关键词:** 剩余寿命预测;注意力机制;深度可分离卷积;残差网络;航空发动机

**中图分类号:** TH17 **文献标识码:** A **国家标准学科分类代码:** 460.99

## Prediction method of remaining useful life based on attention mechanism and residual depthwise separation convolution

Lan Jie<sup>1</sup> Li Zhining<sup>1</sup> Li Ning<sup>2</sup> Lyu Jiangan<sup>1</sup>

(1. Shijiazhuang Campus of Army Engineering University, Shijiazhuang 050003, China;

2. Wuhan Non-Commissioned Officer School of Army Engineering University, Wuhan 430000, China)

**Abstract:** Traditional methods for remaining useful life (RUL) prediction of mechanical equipment require manual intervention processes such as multi-source data fusion and establishment of health indicators, and the prediction accuracy is limited by the ability of health indicators to characterize the degradation process of the equipment. To achieve end-to-end RUL prediction and improve the prediction accuracy, a RUL method based on a combination of attention mechanism and residual depthwise separation convolutional network is proposed, and the effectiveness of the method is tested by using the C-MAPSS aero-engine simulation data set. A sliding window is used to intercept multivariate sequences from the engine multi-source state parameters as samples to characterize the engine state, and a RUL prediction model is built based on a one-dimensional separable convolutional network, and an attention mechanism and residual network are introduced into the network to improve the prediction accuracy of the model. The final mean root mean square error values of the proposed method for the four test sets of C-MAPSS are 11.28, 14.12, 11.57 and 15.61, respectively, and it also has good generalization capability for RUL prediction during engine operation. The comparison results with various RUL prediction methods show that the overall prediction accuracy of the proposed method is high for all four test sets, indicating that the method is an effective RUL prediction method for mechanical equipment and can be used for early fault warning of equipment.

**Keywords:** remaining useful life prediction; attention mechanism; depthwise separation convolution; residual network; turbofan engine

## 0 引言

随着机械设备集成化、智能化程度日益提升,传统维护

策略将难以满足高效智能的维修需求。对于一些重要的机械设备诸如航空发动机、机床、发电机组等,一旦发生故障则可能会造成严重的经济损失甚至人员伤亡,若能针对这

些设备实施全寿命状态监测,并根据设备状态预测其剩余使用寿命(remaining useful life, RUL),则可以在设备失效前进行预先维护,这将有助于降低设备的故障发生概率、节约维修成本,对于延长设备的使用寿命具有重要意义。

目前常用的 RUL 预测方法主要可分为基于物理模型的预测方法和基于数据驱动的预测方法。其中基于物理模型的 RUL 预测方法主要是从物理角度研究设备的退化机理,进而预测其失效时间。李洪松等<sup>[1]</sup>建立了一种基于非对称循环载荷作用下裂纹萌生的寿命预测模型,用于预测涡轮发动机叶片的疲劳寿命;白高俊等<sup>[2]</sup>通过建立柴油机活塞的有限元仿真模型,用于预测活塞的疲劳寿命。该类方法预测精度较高,但建模过程较为复杂,仅适用于结构简单的系统或单个部件,难以针对复杂的系统建立预测模型,由此导致其适用范围较小。基于数据驱动的预测方法主要通过从设备的测试数据中提取健康指标或退化特征用以表征设备的退化过程,进而建立数据与剩余寿命之间的联系,该类方法无需研究设备的退化机理,在当前应用最为广泛。数据驱动预测法又可分为基于相似性模型<sup>[3-4]</sup>、基于机器学习<sup>[5-6]</sup>、基于机器学习<sup>[7-9]</sup>等多种方法。

传统基于机器学习的 RUL 预测方法一般需要人工从数据中提取退化特征,预测精度受限于特征对退化过程的表征能力,且此过程十分依赖于研究者的先验知识。近年来,深度学习在特征提取和非线性映射关系学习方面取得显著成效,通过深层神经网络可以直接建立设备的状态数据到 RUL 的非线性映射关系,避免了人工对特征提取过程的干预,进而实现端对端的 RUL 预测。其中循环神经网络和卷积神经网络(convolutional neural network, CNN)在 RUL 预测模型应用较多。循环神经网络可获取长时间序列的时序依赖性,常被用于实现时间序列的回归预测,因此是 RUL 预测模型中最常用的网络类型,赵宏志等<sup>[10]</sup>采用长短期记忆(long and short-term memory, LSTM)循环神经网络搭建序列到序列的编码器模型,并将解码器最后时刻的输出特征映射为样本的 RUL;陈倩倩等<sup>[11]</sup>利用深度残差网络和双向门控循环神经网络分别提取输入数据的空间和时序特征,提升了 RUL 预测模型的特征提取效果;车昱娇等<sup>[12]</sup>采用核主成分分析法融合轴承振动信号的 14 类时域特征,并将融合特征输入经 Dropout 策略改进的 LSTM 模型中预测轴承的 RUL。卷积神经网络可从时间维度和空间维度提取多元时间序列的特征,因此也被用于构建 RUL 预测模型,杨小东等<sup>[13]</sup>提出一种基于一维和二维融合的 CNN 网络模型用于提取振动信号的时域和频域特征,并将特征用于预测轴承的 RUL;吕德峰等<sup>[14]</sup>采用主成分分析对发动机的多元数据降维,采用一维 CNN 将降维特征映射为发动机的 RUL;陈保家等<sup>[15]</sup>通过深度堆栈自编码器网络获取轴承振动信号的深度特征,而后将深度特征输入到时间卷积神经网络中实现轴承的 RUL 预测;张加劲<sup>[16]</sup>采用 CNN 和双向 LSTM 获取特征中的长短期依赖

关系,并引入注意力机制增强重要特征的作用,提升了航空发动机的 RUL 预测精度。

为实现端对端的 RUL 预测并进一步提升 RUL 的预测精度,本文建立了一种基于一维可分离卷积网络的 RUL 预测模型,并在网络的输入层后引入注意力机制层以增强重要特征的作用,在每个分离卷积层的输入和输出之间建立残差连接,以增强网络在训练过程中的稳定性,进而提升网络的学习能力。本文采用 NASA 发布的 C-MAPSS 发动机数据集检验预测模型的效果,以该数据集中的训练集训练预测模型,以测试集验证模型,并采用通用的均方根误差(root mean squared error, RMSE)和 score 评分函数对 RUL 预测结果进行评价。通过与国内外多种预测方法相比较,结果表明本文所提方法对 4 个测试集的整体预测精度均较高,且对于发动机在运行过程的 RUL 预测也具有较好的泛化能力,说明了该方法是一种有效的 RUL 预测方法。

## 1 相关原理

### 1.1 一维可分离卷积

深度可分离卷积是对传统卷积的改进算法,其通过拆分空间维度和通道维度之间的相关性,减少了卷积运算所需的参数量<sup>[17]</sup>,被广泛的应用于深度卷积神经网络的结构优化。一维卷积能实现对多元时间序列的特征提取,在运算过程中卷积核沿时间方向执行卷积运算。本文采用可分离一维卷积实现传统一维卷积的功能,与传统一维卷积计算流程不同,可分离一维卷积运算过程分为逐通道卷积和逐点卷积两部分,其中逐通道卷积指由多个单通道卷积核与输入的对应该通道进行卷积运算得到分离卷积的中间表示,此过程中卷积核的数量与输入通道数一致;逐点卷积是指采用大小为 1 的多通道卷积核对中间表示进行卷积运算,此过程中卷积核的通道数与中间表示的通道数一致,输出的通道数取决于逐点卷积核的个数,把逐点卷积的输出在通道轴上进行拼接后得到分离卷积的最终输出。图 1 所示为一维分离卷积的运算流程,假设卷积运算的输入通道数为 4,输出通道数为 5,单通道卷积核大小为 3,则普通卷积实现该过程所需优化的参数量为: $4 \times 3 \times 5 = 60$ ,可分离卷积需优化的参数量为: $4 \times 3 + 4 \times 1 \times 5 = 32$ 。由此可见,可分离卷积网络在训练过程中需优化的参数量远比普通卷积少。

### 1.2 残差网络

深度网络在学习复杂映射关系方面比浅层网络更具优势,但随着网络层数加深,梯度向浅层反向传播时会出现消失或爆炸的问题,由此导致训练过程不稳定。残差网络被提出用于解决此类问题,并被首先应用于图像识别领域<sup>[18]</sup>。具体方法是在每层网络的输入和输出之间添加一条跳跃连接,连接示意如图 2 所示,残差网络的计算公式如下:

$$H(x) = x + F(x) \quad (1)$$

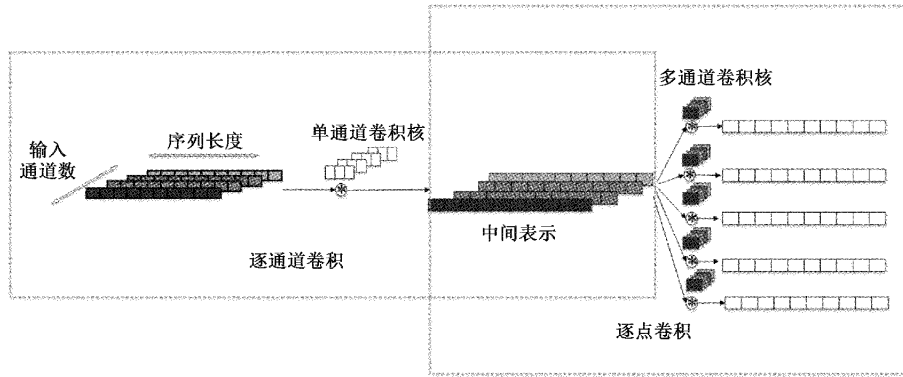


图 1 一维可分离卷积运算过程

式中:  $x$  表示网络输入,  $F(x)$  为卷积的输出,  $H(x)$  为网络输出, 当输入和输出通道数不一致时, 通常对  $x$  进行卷积运算使其与  $F(x)$  的通道数相同后再进行相加运算, 经残差连接后卷积网络学习的映射关系为  $F(x) = H(x) - x$ , 残差网络的应用有效缓解了深度网络存在的梯度消失和爆炸的问题, 增强了训练过程中的稳定性, 进而提升网络的学习能力。




图 2 残差网络

### 1.3 自注意力机制

注意力机制源于对人类视觉的研究: 人眼在视野中会着重观察自己想关注的事物, 而自觉忽略掉其他事物, 注意力机制最先被应用于机器翻译任务<sup>[19]</sup>, 研究人员发现将注意力机制引入到序列到序列的模型中会显著提升翻译的准确率。在其他深度学习领域, 通过在模型中引入自注意力机制为特征赋予权重, 增强重要特征的作用, 能够提升预测的精度。因此本文在输入层后连接一个自注意力层, 为输入的多元时间序列赋予权重。

假定多元时间序列矩阵  $\mathbf{X} = [x_1, x_2, \dots, x_N]$ , 其中  $\mathbf{X} \in R^{d \times N}$ ,  $d$  为特征维度,  $N$  为序列长度, 自注意力机制的运算流程如下:

1) 将输入矩阵  $\mathbf{X}$  映射为  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  3 个矩阵, 其中  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  分别代表查询矩阵、键矩阵和值矩阵, 公式如下:

$$\mathbf{Q} = \mathbf{W}_q \cdot \mathbf{X} \in R^{D_q \times N} \quad (2)$$

$$\mathbf{K} = \mathbf{W}_k \cdot \mathbf{X} \in R^{D_k \times N} \quad (3)$$

$$\mathbf{V} = \mathbf{W}_v \cdot \mathbf{X} \in R^{D_v \times N} \quad (4)$$

2) 计算自注意力机制输出矩阵:

$$\mathbf{H} = \mathbf{V} \cdot \frac{\text{softmax}(\mathbf{K}^T \cdot \mathbf{Q})}{\sqrt{D_k}} \quad (5)$$

式中:  $\mathbf{W}_q, \mathbf{W}_k, \mathbf{W}_v$  是把  $\mathbf{X}$  映射为  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  的权重矩阵, 可通过网络的反向传播优化计算;  $D_k$  为矩阵  $\mathbf{Q}$  的行数,  $\text{softmax}()$  函数将矩阵  $\mathbf{K}^T \cdot \mathbf{Q}$  的每一列转化为和为 1 的权重向量, 注意力机制的输出矩阵  $\mathbf{H}$  的每一列均为值矩阵  $\mathbf{V}$  中所有列向量的加权和, 输出矩阵  $\mathbf{H} \in R^{D_v \times N}$ 。

## 2 RUL 预测模型

### 2.1 数据集简介

本文主要针对 NASA 发布的 C-MAPSS 航空发动机仿真数据集建立 RUL 预测模型, 该数据集内含 4 个子集, 涵盖发动机在多种运行条件下的 21 类传感器测量数据, 其中每个子集包含一个训练集和一个测试集, 训练集内是发动机从健康到故障状态的全寿命数据, 测试集内是发动机从某时刻开始的非完整寿命的数据, 数据集中每个样本均已知的真实的 RUL 值。数据集具体描述如表 1 所示。

表 1 C-MPASS 航空发动机数据集

数据集	训练集		测试集		运行条件	故障模式
	发动 机数	总样 本数	发动 机数	总样 本数		
FD001	100	20 631	100	13 096	1	1
FD002	260	53 579	259	33 991	6	1
FD003	100	24 720	100	16 596	1	2
FD004	249	61 249	248	41 214	6	2

### 2.2 数据预处理

在建立 RUL 预测模型前, 先采用 Z-Score 方式对多元传感器数据进行标准化处理, 使所有样本被规范在  $\mu = 0, \sigma^2 = 1$  的分布范围内, 标准化公式如式(6)所示。

$$y' = \frac{y - \text{mean}(y)}{\text{std}(y)} \quad (6)$$

其中,  $\text{mean}()$  和  $\text{std}()$  分别代表待标准化的传感器数值的均值和标准差。

图 3 所示为 FD001 训练集中 100 台发动机的 21 个传感器变量的全寿命曲线图, 由图可知有 7 类传感器数据类型无变化趋势, 说明该 7 类传感器数据不能表征发动机的退化过程。同理对其余 3 个子集进行分析, 最终保留 FD001 和 FD003 剩余的 14 类传感器数据作为有效数据, 保留 FD002 和 FD004 全部的 21 类传感器数据类型。

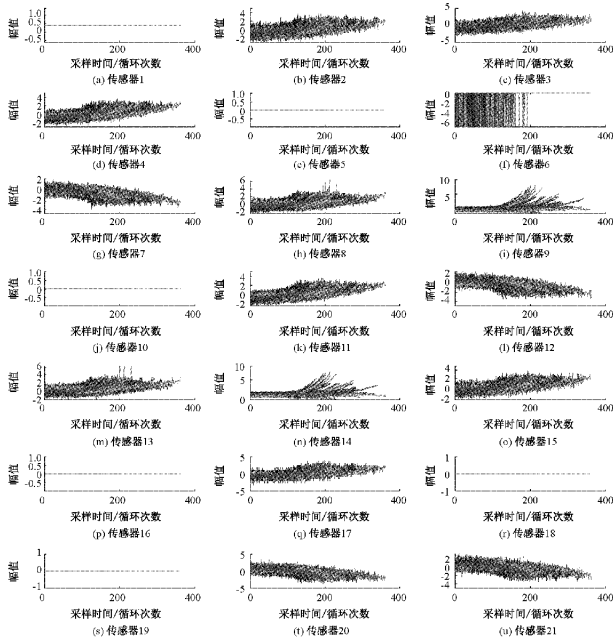


图 3 FD001 训练集样本 21 个传感器变量时序图




图 4 RUL 预测模型网络结构

在 Pytorch1.11 深度学习框架中搭建上述网络模型, 并利用 C-MAPSS 中的训练集训练模型, 以测试集检验模型的有效性。训练过程中设置 Batch size 为 128, 训练最大迭代次数为 60, 学习率为 0.001, 一维分离卷积采用 padding='same' 的方式填充输入序列, 以保持卷积层输入和输出的序列长度相等。以 FD001 预测模型为例, 网络参数设置如表 3 所示。

为防止样本长度太长造成信息冗余和模型膨胀, 采用固定宽度的滑动窗从原始样本中截取短序列作为新样本, 滑动窗沿时间方向每滑动 1 步截取一个样本, 其中 FD001 和 FD003 滑动窗口设为 30, 即样本的张量形状为 [14, 30], FD002 和 FD004 滑动窗口设为 36, 即样本的张量形状为 [21, 36]; 经滑动窗口处理后, 训练集和测试集样本数量如表 2 所示。以每个样本最后时刻的 RUL 值作为该样本的 RUL 标签, 并对 RUL 标签进行分段线性修正, 设定 RUL 的最大阈值为 125, 当样本的实际 RUL > 125 时, 将其修正为 RUL = 125。

表 2 训练集和测试集样本量

数据集	训练集 总样本数	测试集 总样本数	样本 形状
FD001	17 731	100	[14, 30]
FD002	44 659	250	[21, 36]
FD003	21 820	100	[14, 30]
FD004	52 534	235	[21, 36]

### 2.3 RUL 预测模型

建立基于一维可分离卷积网络的 RUL 预测模型, 并在模型网络中引入自注意力机制和与残差网络, 模型的网络结构如图 4 所示。模型网络结构主要由输入层、自注意力机制层、4 个一维可分离卷积层、全连接层和输出层组成, 其中每个分离卷积层的输入和输出之间建立残差连接, 残差模块中采用一维卷积实现输入和输出通道数的对齐, 在每个分离卷积层后使用 ReLU 激活函数以增强网络的稀疏性和非线性映射能力。向网络中输入经过预处理的发动机多源传感器序列, 输出样本对应的 RUL 预测值。

### 2.4 评价指标

为评价每个测试集整体的 RUL 预测效果, 采用 RMSE 和 score 评分函数评价预测结果, 此两类指标越小则表明 RUL 预测结果的精度越高, 其中 score 评分函数对 RUL 预测值大于实际值的情况设定了更高的惩罚函数。评价指标的具体计算公式如下:

$$\text{error}_i = \text{Rul}_{\text{predict},i} - \text{Rul}_{\text{true},i} \quad (7)$$

表 3 模型网络参数设置

网络层	参数设置	输出形状
输入层		[14,30]
自注意力层		[14,30]
分离卷积层	逐点卷积核个数 200	[200,30]
分离卷积层	逐点卷积核个数 200	[150,30]
分离卷积层	逐点卷积核个数 200	[200,30]
分离卷积层	逐点卷积核个数 200	[30,30]
平铺层		[None,900]
全连接层	隐含层单元数 30	[None,30]
输出层		[None,1]

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n error_i^2} \quad (8)$$

$$score = \begin{cases} \sum_{i=1}^n (\exp \frac{-error_i}{13} - 1), & error_i < 0 \\ \sum_{i=1}^n (\exp \frac{error_i}{10} - 1), & error_i > 0 \end{cases} \quad (9)$$

式中:  $Rul_{predict,i}$ 、 $Rul_{true,i}$  分别代表测试集中第  $i$  个测试样本的 RUL 预测值和真实值。

综上所述,可将 RUL 预测方法概括为图 5 所示的流程图。

### 3 结果及分析

#### 3.1 RUL 预测结果

图 6 为 4 个测试集中所有样本的 RUL 预测结果,为便于分析结果,图中发动机的序号根据每个样本实际的 RUL 值从大到小的顺序重新进行了排列。由图 6 的 4 个图像可知,4 个测试集的样本 RUL 预测值分布于实际值附近。FD001 和 FD003 的图像显示,当样本的实际 RUL 较小时,RUL 预测与实际值的误差相对较小;当样本的实际 RUL 较大时,RUL 预测值与实际值的误差会明显增大。进一步分析其原因,当 RUL 接近于 0 时,说明该测试样本处于发动机的寿命末期阶段,样本中包含的有效故障信息增多,与训练集中处于寿命末期的故障样本相似度增强,其输出的 RUL 预测值更接近于故障样本的 RUL 真实值,

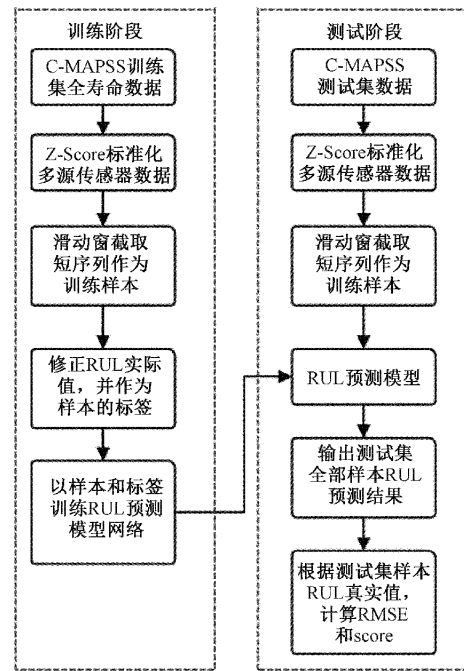




图 5 C-MAPSS 数据集 RUL 预测流程

由此误差较小;而当样本的 RUL 实际值较大时,说明发动机处于健康状态,此时样本数据中包含的故障信息较少,信噪比较低,样本的 RUL 预测值更容易受到传感器数据随机波动的影响,由此导致误差较大。

为消除在训练过程中网络随机初始化导致的结果波动,对每个子集的预测模型重复 5 次训练,每次训练后输出测试集的预测结果。预测结果的评价指标如表 4 所示,将 5 次结果的 RMSE 和 score 制成箱线图分别如图 7(a)和 (b)所示。由表 4 和图 7 可知对于 FD001 和 FD003 两数据集的 RMSE 和 score 的均值和最小值均小于 FD002 和 FD004 两数据集,这说明经过训练后,模型对前两个测试集具有更好的泛化能力。分析其原因,FD001、FD003 两数据集与 FD002、FD004 两数据集的发动机在不同条件下运行,且后两个数据集中样本数量远多于前两个数据集,这意味着后两个数据集的预测模型需要在训练过程中建立更为复杂的映射关系,在相同的网络结构和参数条件下,






图 6 测试集所有样本的预测结果

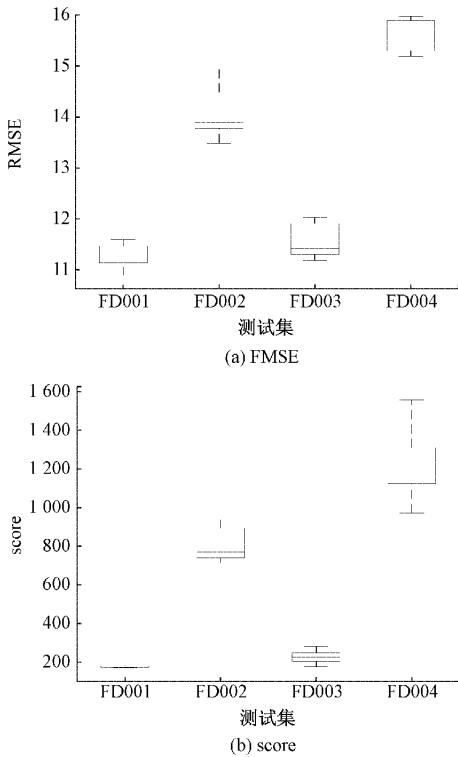


图 7 评价指标箱线图

表 4 预测结果的评价指标

测试集	评价指标	5 次预测 结果均值	5 次预测 最优值
FD001	RMSE	11.28	10.89
	score	176.26	170.21
FD002	RMSE	14.12	13.48
	score	810.43	713.50
FD003	RMSE	11.57	11.18
	score	227.15	177.76
FD004	RMSE	15.61	15.19
	score	1224.80	971.71

会造成模型对 FD002 和 FD004 的整体预测精度要低于 FD001 和 FD003。

为了进一步验证所提方法的有效性,从 FD001、FD002、FD003、FD004 这 4 个测试集中分别抽取了第 34 台、第 138 台、第 82 台和第 135 台发动机在整个测试期间的样本,并将其输入到训练好的 RUL 预测模型中进行预测,4 个测试集的 RUL 预测结果分别如图 8(a)~(d)所示。结果显示,在每个发动机的测试阶段初期,由于受到 RUL 最大阈值的限制,发动机的 RUL 预测值均小于 125;在线性退化阶段,发动机的 RUL 预测值曲线随着 RUL 实际值减小呈递减趋势,且 RUL 预测值曲线在实际值曲线附近波动,较好的表现了发动机的退化趋势。进一步分析图 8 可知,在测试阶段末期,RUL 预测值与实际值的误差明显减小,这说明该阶段预测精度有所提升。上述结果说明了所提方法对于发动机在运行期间的 RUL 预测也具有较好的泛化能力,尤其是在发动机的寿命末期,RUL 的预测值可靠性较高,该预测值可以在发动机即将发生故障时起到早期故障预警作用,为预先维护提供决策辅助。

为进一步研究注意力机制为输入特征赋予的权重分布规律,从 4 个测试集中分别选择一个样本,将其输入到训练好的模型网络中进行正向运算,将注意力机制输出的权重分布进行可视化,4 个样本的权重分布如图 9 所示。由图 9 可知 4 个测试集的 RUL 预测模型关注的特征位置有所不同,其中 FD001 预测模型重点关注了第 21 个特征向量,FD002 预测模型重点关注了第 10 和第 28 个特征向量,FD003 预测模型重点关注了第 6 个和第 28 个特征向量,FD004 测试模型重点关注了第 17 和第 35 个特征向量。这说明 RUL 预测模型在经过训练后,注意力机制可以自适应的为输入序列分配权重,且在注意力机制的作用下,输入序列中的有效信息被集中分布在了少数特征向量中,而其他向量对 RUL 预测结果的影响较小,由此突出了重要特征对 RUL 预测结果的作用,进而提升了 RUL 的预测精度。

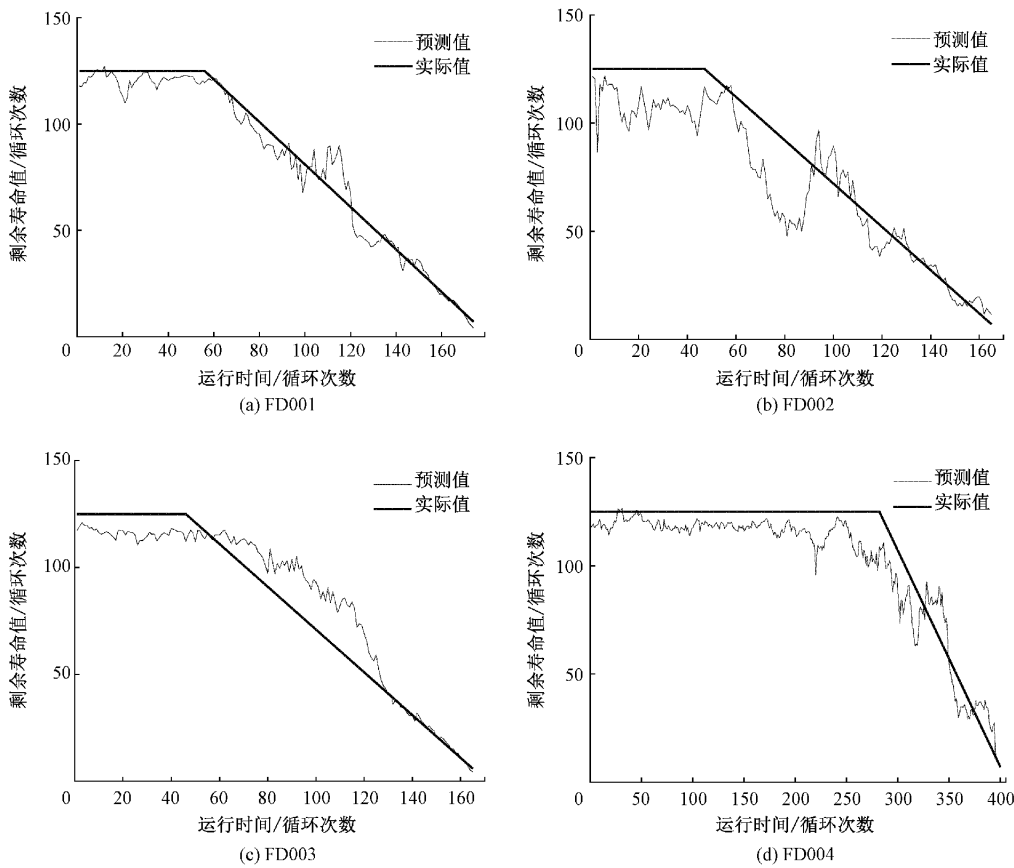


图 8 全测试阶段的 RUL 预测结果

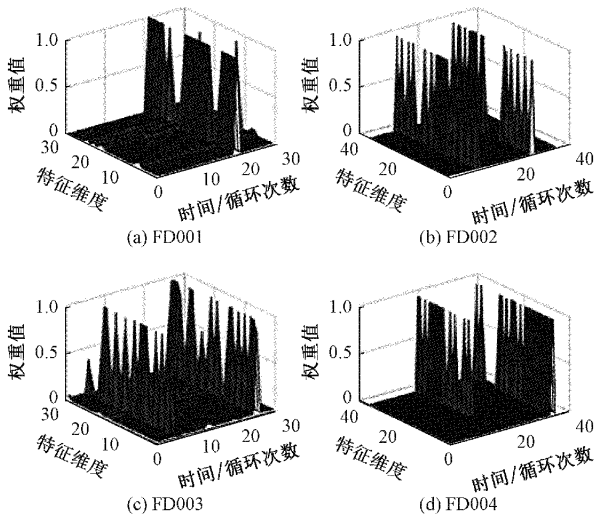


图 9 自注意力机制的权重分布

3.2 多预测方法结果对比

将所提方法与其他文献中的多种预测方法进行比较,其中参与比较的文献均采用 C-MAPSS 数据集建立预测模型,且采用相同的评价指标对结果进行评价,具体对比结果如表 5 所示。

由表 5 可知,与文献[10]所提的基于 LSTM Encoder-

Decoder 方法相比,本文方法对 FD002、FD003、FD004 预测结果的 RMSE 分别降低了 5.27、2.25、6.39;与文献[24]所提的基于广义 LSTM 方法相比,本文方法对 4 个测试集的 RMSE 分别降低了 1.17、1.24、1.8、0.63;与文献[25]所提的基于改进 CNN 的预测方法相比,4 个测试集的 RMSE 分别降低了 1.33、5.49、1.44、3.8。上述对比结果可以说明所提的 RUL 预测方法是一种有效的方法,且达到的预测精度较高。

为验证注意力机制和残差网络在模型中的作用,采用消融实验的方法设置以下两种模型与文中模型进行对比: 1)在原来模型基础上去除注意力机制层,直接将多源传感器序列输入到分离卷积网络中实现原始序列到 RUL 的映射,结果如表 5 中 Res-DSCN 的预测结果,与引入注意力机制层相比,4 个测试集的 RMSE 分别升高了 1.86、2.51、1.99、2.23,这说明在引入注意力机制后,模型能够有效地关注到输入序列中的重要特征,进而提升 RUL 的预测精度;2)在原有模型的基础上断开了每个卷积层的残差连接,预测结果如表 5 中的 DSCN,与文中所提方法相比,4 个测试集的 RMSE 分别升高了 1.26、3.64、1.74、3.82,这也证明了残差网络有助于提升预测模型的预测精度。

通过分析表 5 进一步发现,本文对于 FD002 和 FD004 的预测结果精度明显高于要其他预测方法。其原因是

表 5 多种预测方法对比结果

数据集	FD001		FD002		FD003		FD004	
	RMSE	score	RMSE	score	RMSE	score	RMSE	score
LSTM Encoder-Decoder <sup>[10]</sup>	11	164	20	3 012	14	372	22	4 800
残差 Nested-LSTM <sup>[20]</sup>	12.53	265	20.51	1 195	12.15	284	22.36	2 692
GRU-GAN <sup>[21]</sup>	13.12	249.32	—	—	—	—	21.86	3 361.14
集成学习 <sup>[22]</sup>	17.879	177	—	—	—	—	—	—
DCNN <sup>[23]</sup>	11.81	223	18.34	2 550	13.08	280.5	19.88	2 982.31
BLSN <sup>[24]</sup>	12.45	279	15.36	4 250	13.37	356	16.24	5 220
CNN-XGB <sup>[25]</sup>	12.61	224.73	19.61	2 525.99	13.01	279.36	19.41	2 930.65
ANN-EN <sup>[26]</sup>	14.39	337	29.09	—	15.42	533	34.74	—
DSCN	12.54	349	17.76	1 837.69	13.31	527.13	19.43	2 087.96
Res-DSCN	13.14	243.76	16.63	1 107.29	13.56	304.19	17.84	1 233.64
本文方法均值	11.28	176.26	14.12	810.43	11.57	227.15	15.61	1 124.80

FD002 和 FD004 两数据集中样本数量较多,大样本学习要求预测模型在训练过程中学习更为复杂的映射关系,而本文所采用的深度残差网络能有效缓解模型在训练过程中存在的梯度消失的问题,进而提升深度网络的学习能力,在大样本训练时具有优势,因此对 FD002 和 FD004 的预测精度会明显高于其他方法。

#### 4 结 论

本文针对 C-MAPSS 发动机数据集提出了一种基于注意力机制和残差深度分离卷积的 RUL 预测模型。主要结论如下:

对 4 个测试集的 RUL 预测结果的 RMSE 分别为 11.28、14.12、11.57 和 15.61。通过与其他文献中基于 GRU、LSTM、CNN、集成学习等多种方法相比较,可知本文所提方法在预测精度上具有优势,是一种有效的 RUL 预测方法。

通过对发动机在整个测试阶段的 RUL 进行预测,结果显示 RUL 的预测值在实际值附近波动,尤其是当发动机接近寿命末期时,RUL 预测值可靠性较高。这表明所提方法对于发动机在运行期间的 RUL 预测也具有良好的泛化能力,且能够在故障即将发生时发挥预警作用。

为验证注意力机制和残差网络与 RUL 预测精度的影响,设置了消融实验进行验证。结果表明,未引入注意力机制使 4 个测试集的预测 RMSE 分别增加了 1.86、2.51、1.99、2.23;断开残差网络使 4 个测试集的 RMSE 分别增加了 1.26、3.64、1.74、3.82。该结果证明了注意力机制和残差网络对于提升 RUL 预测精度的作用。

#### 参考文献

- [1] 李洪松,刘永葆,贺星,等.非对称循环加载下燃气轮机叶片材料疲劳寿命预测[J].振动与冲击,2022,41(12):152-158,237.
- [2] 白高俊,雷基林,邓伟,等.基于流固耦合传热的柴油机

铝活塞疲劳寿命预测与优化设计[J].昆明理工大学学报(自然科学版),2022,47(2):142-150.

- [3] 许显晖,舒俊清,宋亚,等.基于多时间尺度相似性的涡扇发动机寿命预测[J].浙江大学学报(工学版),2021,55(10):1937-1947.
- [4] 张妍,王村松,陆宁云,等.基于退化特征相似性的航空发动机寿命预测[J].系统工程与电子技术,2019,41(6):1414-1421.
- [5] 李军星,黄嘉鸿,邱明,等.基于广义 Wiener 过程的滚动轴承剩余寿命预测[J/OL].计算机集成制造系统,2022. <http://kns.cnki.net/kcms/detail/11.5946.TP.20220613.0818.002.html>.
- [6] 李天梅,司小胜,张建勋.多源传感监测线性退化设备数模联动的剩余寿命预测方法[J].航空学报,2023,44(8):94-112.
- [7] 马海龙.基于主元特征融合和 SVM 的轴承剩余寿命预测[J].工矿自动化,2019,45(8):74-78.
- [8] 王付广,李伟,郑近德,等.基于多频率尺度模糊熵和 ELM 的滚动轴承剩余寿命预测[J].噪声与振动控制,2018,38(1):188-192.
- [9] 焦晓璇,景博,李娟,等.基于 ADEGWO-SVM 的机载燃油泵寿命预测研究[J].仪器仪表学报,2018,39(8):43-52.
- [10] 赵志宏,李晴,李乐豪,等.LSTM Encoder-Decoder 方法预测设备剩余使用寿命[J].交通运输工程学报,2021,21(6):269-277.
- [11] 陈倩倩,林天然.基于 DRN-BiGRU 模型的滚动轴承剩余寿命预测[J].机电工程,2022,39(11):1575-1581.
- [12] 车昱娇,陈云霞,崔宇轩.KPCA 和改进 LSTM 在滚动轴承剩余寿命预测中的应用研究[J].电子测量与仪器学报,2021,35(2):109-114.
- [13] 杨小东,纪国宜.基于融合 CNN 的滚动轴承剩余寿命预测[J].国外电子测量技术,2021,40(3):62-67.



- [14] 吕德峰,胡煜雯. 基于主成分分析和一维卷积神经网络的航空发动机剩余寿命预测(英文)[J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2021, 38(5): 867-875.
- [15] 陈保家,陈正坤,陈学良,等. 基于注意力 TCN 的滚动轴承剩余使用寿命预测方法[J]. 电子测量技术, 2021, 44(24): 153-160.
- [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.
- [17] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251-1258.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [19] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. ArXiv Preprint, 2014, ArXiv:1409.0473.
- [20] 陈保家,郭凯敏,陈法法,等. 基于残差 NLSTM 网络和注意力机制的航空发动机剩余使用寿命预测[J]. 航空动力学报, 2023, 38(5): 1176-1184.
- [21] 袁焯,黄虹,程骋,等. 基于特征注意力机制的 GRU-GAN 航空发动机剩余寿命预测[J]. 中国科学:技术科学, 2022, 52(1): 198-212.
- [22] 张一鸣,刘晓锋,崔宝,等. 基于集成学习的涡扇发动机剩余寿命预测模型[J]. 热能动力工程, 2022, 37(4): 64-70.
- [23] MUNEER A, TAIB S M, FATI S M, et al. Deep-learning based prognosis approach for remaining useful life prediction of turbofan engine [J]. Symmetry, 2021, 13(10): 1861.
- [24] WANG X, HUANG T, ZHU K, et al. LSTM-based broad learning system for remaining useful life prediction[J]. Mathematics, 2022, 10(12): 2066.
- [25] ZHANG X, XIAO P, YANG Y, et al. Remaining useful life estimation using CNN-XGB with extended time window [J]. IEEE Access, 2019, 7: 154386-154397.
- [26] LAREDO D, CHEN Z, SCHÜTZE O, et al. A neural network-evolutionary computational framework for remaining useful life estimation of mechanical systems[J]. Neural Networks, 2019, 116: 178-187.

#### 作者简介

兰杰, 硕士, 主要研究方向为机械设备的故障诊断与健康管理。

E-mail: ssyyqq0713@163.com

李志宁(通信作者), 博士生导师, 教授, 主要研究方向为机械测试与故障诊断。

E-mail: lyza146@126.com