

# 基于 FA-LN-BiGRU 的机械设备剩余寿命区间预测方法\*

梁伟阁<sup>1</sup>, 闫啸家<sup>1</sup>, 余博<sup>1</sup>, 张钢<sup>2</sup>, 田福庆<sup>1</sup>

(1. 海军工程大学兵器工程学院 武汉, 430033)

(2. 大连舰艇学院导弹与舰炮系 大连, 116000)

**摘要** 针对数据驱动融合模型存在前后模型不匹配、关键信息丢失等问题, 提出了一种端对端的预测方法, 即基于特征注意力机制的对数正态分布和双向门控循环单元融合 (feature attention-lognorm-bidirectional gated recurrent unit, 简称 FA-LN-BiGRU) 的剩余寿命区间预测方法。首先, 利用特征注意力机制从多维度、非线性 and 大规模的传感器信号中提取出关键特征向量; 其次, 采用 BiGRU 网络从前向和后向 2 个方向对注意力加权特征的时变特性进行建模学习, 并通过最大似然估计损失函数来训练网络参数, 获得网络隐含状态输出向量的概率分布; 最后, 计算出基于对数正态分布的概率密度函数, 实现设备剩余寿命 (remaining useful life, 简称 RUL) 不确定性的衡量。分析结果表明, 对于运行条件复杂和故障模式多变的多维监测数据, 所提方法能够深入挖掘性能退化信息, 有效提高机械设备剩余寿命点预测和区间预测的准确度和可靠性。

**关键词** 剩余寿命预测; 对数正态分布; 融合预测模型; 区间预测; 特征注意力机制

**中图分类号** TH17

## 引言

随着机械设备的结构和功能日趋复杂, 零部件之间的非线性耦合关系和运作过程中的不确定性增加了机械系统发生退化而导致失效的可能性。基于传感器数据对机械设备进行 RUL 预测, 能够保证重大机械设备的安全可靠运行, 为预测性维护提供技术支持<sup>[1-2]</sup>。数据驱动的预测模型分为机器学习模型<sup>[3-5]</sup>和统计分析模型<sup>[6-7]</sup>两大类。机器学习模型通过学习时间序列蕴含的信息实现 RUL 预测, 但只能提供 RUL 的点估计而非区间估计, 难以量化 RUL 预测过程中的不确定性; 统计分析模型通过对历史数据进行随机过程建模, 利用参数估计构造 RUL 的概率密度分布函数 (probability density function, 简称 PDF), 然后对实时传感器数据进行统计分析来实现 RUL 预测, 但难以描述多维数据的耦合关系, 存在监测数据退化信息利用不充分的问题。理论上, 融合机器学习和统计分析的 RUL 预测方法<sup>[8-10]</sup>可综合两者优势, 但存在随机退化关键信息丢失的风险和迭代计算资源消耗过大的实际问题。为此, 笔者提出一种端对端的 RUL 预测方法, 即 FA-LN-BiGRU 的机械设备剩余寿命区间预测方法。

## 1 模型原理

### 1.1 特征注意力机制

对于工作剖面复杂的机械设备, 需综合考虑多个特征的监测数据, 才能更全面地评估其健康状态和性能退化趋势, 而这些特征对 RUL 预测的贡献有多有少。为有效反映特征与 RUL 预测的关联程度, 提高预测模型特征提取能力, 运用特征注意力 (feature attention, 简称 FA) 机制对原始输入数据的关键特征进行选择, 特征注意力结构如图 1 所示。

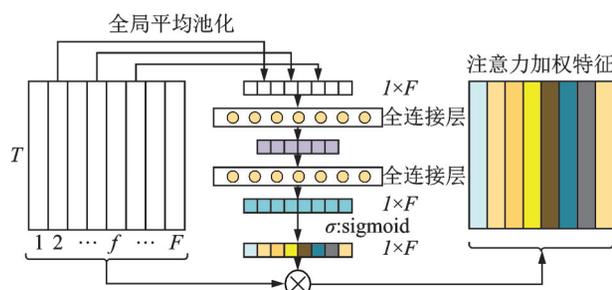


图 1 特征注意力结构图

Fig.1 Feature attention structure map

### 1.2 双向门限循环单元

剩余寿命预测的主要途径是从监测数据中学习

\* 国家自然科学基金资助项目(61640308);湖北省自然科学基金资助项目(2019CFB362)

收稿日期:2022-05-19;修回日期:2022-06-24

性能退化的时空信息,而长短期记忆(long short term memory, 简称 LSTM)网络可充分利用数据的时间相关特性对时域序列数据进行处理,然而其内部结构复杂,训练时间较长。通过 GRU 对 LSTM 进行优化改进,将遗忘门和输入门进行组合,在保证记忆能力的同时,提升网络的训练效率。记忆单元是 GRU 网络的核心,由更新门、重置门和候选隐藏层构成,其网络拓扑结构如图 2 所示。为了加深对原始时间序列特征提取的层次,进一步提高模型输出的准确性,将 2 个方向不同且独立的 GRU 叠加在一起构成 BiGRU 网络,其结构如图 3 所示。

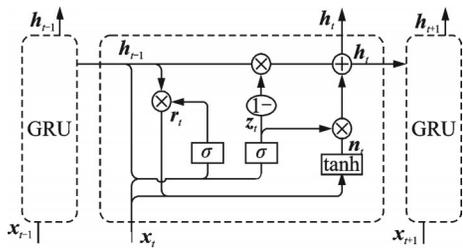


图 2 GRU 网络结构图

Fig.2 GRU network structure diagram

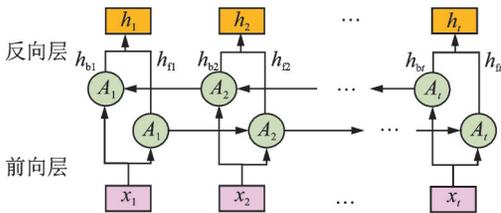


图 3 BiGRU 网络结构图

Fig.3 BiGRU network structure diagram

1.3 对数正态分布

对数正态分布(log-norm, 简称 LN)可将取值差异大的寿命数据转换为标准正态分布处理,是可靠性领域的常用寿命分布之一。假设给定一个随机变量  $Y = \ln(X)$ , 服从均值为  $\mu$ 、方差为  $\sigma^2$  的正态分布, 则随机变量  $X$  满足参数为  $(\mu, \sigma^2)$  的 LN 分布, 其对数正态分布的统计特征如表 1 所示。

LN 分布的统计特征值如图 4 所示, 其中众数的 PDF 最大。LN 分布呈现出右偏态, 样本主要集中于期望值的左侧, 而预测 RUL 应尽量小于真实

表 1 对数正态分布的统计特征

Tab.1 Statistical characteristics of lognormal distribution

统计特征	计算公式
概率密度函数	$\frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}$
期望值	$e^{\mu + \sigma^2/2}$
中位数	$e^\mu$
众数	$e^{(\mu - \sigma^2)}$

RUL 以保证设备的安全性要求, 因此 LN 分布适合描述退化过程中 RUL 的概率分布。

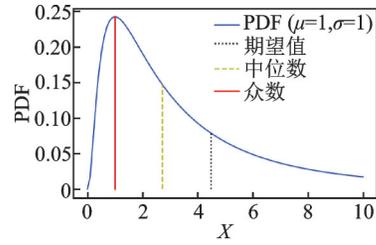


图 4 LN 分布的统计特征值

Fig.4 Statistical features of LN distribution

2 机械设备剩余寿命预测模型

2.1 预测模型概述

在机械设备剩余寿命预测中, 需要根据多方面的状态信息来评估其健康状况, 因此多维历史时间序列是性能退化的主要表现, 其包含了性能退化规律的重要信息。传统信息融合方法在处理多维传感器数据时, 通常是根据单调性或趋势性人为选取与性能退化相关的最优特征, 这种方法难以全面表征整个设备的健康状态, 增加了信息丢失的风险, 并且特征提取与随机模型建立是孤立进行的, 导致 RUL 的预测精度较低。因此, 综合统计分析模型在预测不确定性量化能力上的优势以及机器学习模型在数据处理能力上的优势, 构建基于 FA-LN-BiGRU 的 RUL 预测模型, 可有效挖掘传感器数据中丰富的特性与规律, 提高 RUL 预测精度, 并可对预测结果的不确定性进行度量。

2.2 FA-LN-BiGRU 模型结构

构建 FA-LN-BiGRU 网络模型, 其整体框架如图 5 所示。该模型主要分为输入层、特征加权层、特征学习层和输出层。

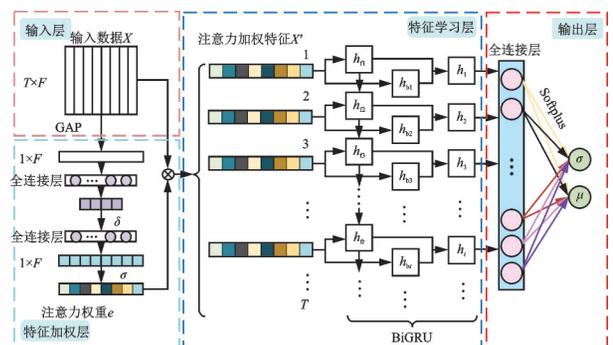


图 5 模型整体框架

Fig.5 The overall framework of the model

### 2.2.1 输入层

输入层负责将机械设备历史传感器数据输入至预测模型中。记运行工况和不同类型传感器监测数据为多维特征时间序列矩阵  $X = (x^1, x^2, \dots, x^F) = (x_1, x_2, \dots, x_T)^T$ , 展开可表示为

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^F \\ x_2^1 & x_2^2 & \dots & x_2^F \\ \vdots & \vdots & \dots & \vdots \\ x_T^1 & x_T^2 & \dots & x_T^F \end{bmatrix} \in R^{T \times F} \quad (1)$$

其中:  $x_t = [x_t^1, x_t^2, \dots, x_t^F]$  ( $1 \leq t \leq T$ ) 为在  $t$  时刻的  $F$  个特征数值序列;  $x^f = [x_1^f, x_2^f, \dots, x_T^f]$  ( $1 \leq f \leq F$ ) 为第  $f$  个多维特征在  $T$  个历史时刻的数值序列。

### 2.2.2 特征加权层

特征加权层负责提取输入时间序列的注意力权重,从而获得注意力加权特征。利用FA机制自动提取输入数据与目标建模参数之间的关联关系,通过不断循环迭代对所有时刻各个特征分别分配注意力权重,逐步提取出对RUL预测贡献率较大的关键特征。

注意力权重可表示为

$$e = \sigma(W_2 \delta(W_1 (\frac{1}{T} \sum_{t=1}^T x_t) + b_1) + b_2) \quad (2)$$

其中:  $e = [e_1, e_2, \dots, e_F] \in R^{F \times 1}$ 。

注意力加权特征为

$$X' = e \odot X = [e_1 x^1, e_2 x^2, \dots, e_F x^F] \quad (3)$$

其中:  $X'$  可记为  $[x_1^F, x_2^F, \dots, x_T^F, \dots, x_T^F]^T$ ;  $F$  为注意力加权特征的维度;  $T$  为时间长度。

### 2.2.3 特征学习层

特征加权层可以对多维特征赋予不同的权重,但难以学习具有明显时间相关性的序列信息。因此,在特征加权层后搭建BiGRU网络构成特征学习层,使得预测模型能够捕获数据的时序依赖关系。

因时间序列长度为  $T$ , 输入特征共  $F$  个, 故BiGRU层由  $T$  个顺序串联的记忆单元组成, 每个GRU单元的输入维度为  $F$ 。如图5所示, 序列数据将分时刻输入至前向层和反向层, 得到  $t$  时刻前向输出  $h_{it}$  和后向输出  $h_{bt}$ , 最终计算出单元的输出  $h_t$ ,  $t \in [1, T]$ , 而BiGRU总输出  $H$  可记为  $[h_1, h_2, \dots, h_t, \dots, h_T]$ 。

### 2.2.4 输出层

将特征学习层的输出作为输出层的输入, 通过全连接层计算出设备RUL的PDF参数预测值  $Y' = [\mu_1, \mu_2, \dots, \mu_t, \dots, \mu_T; \sigma_1, \sigma_2, \dots, \sigma_t, \dots, \sigma_T]^T$ , 即

$$y'_t = [\mu_t, \sigma_t] = w_{out} h_t + b_{out} \quad (4)$$

其中:  $y'_t$  为第  $t$  时刻模型的预测值;  $w_{out}$  为权重矩阵;  $b_{out}$  为偏置系数。

### 2.2.5 损失函数

为准确拟合设备退化过程中RUL的概率分布, 首先, 定义RUL预测的统计参数模型, 即LN分布, 从而对不确定性分布进行假设; 其次, 通过模型预测每个时刻特定分布的参数(对数均值  $\mu$  和对数方差  $\sigma$ ); 最后, 利用最大似然估计  $L(\mu, \sigma | y)$  来训练网络参数。最大似然估计计算公式为

$$L(\mu, \sigma | y) = \frac{1}{y\sigma\sqrt{2\pi}} e^{-\frac{(\ln y - \mu)^2}{2\sigma^2}} \quad (5)$$

其中:  $y$  为RUL的实测值。

将损失函数定义为

$$E_L = - \sum_{t=t_1}^T \ln L(\mu, \sigma | y) \quad (6)$$

对数均值  $\mu_t$  由模型输出的映射函数直接求得, 即

$$\mu_t = w_\mu y_t \quad (7)$$

其中:  $w_\mu$  为与  $\mu$  相关的输出权重;  $\mu_t$  为  $t$  时刻的对数均值。

对于预测不确定性的衡量, 对数方差  $\sigma_t$  应该是一个正值, 因此由激活函数 softplus 得出, 其计算公式为

$$\sigma_t = \ln(1 + e^{(w_\sigma y_t)}) \quad (8)$$

其中:  $w_\sigma$  为与  $\sigma$  相关的输出权重;  $y_t$  为  $t$  时刻RUL的实测值;  $\sigma_t$  为  $t$  时刻的对数方差。

## 3 验证与分析

### 3.1 数据集介绍

采用NASA提供的航空发动机仿真状态监测公开数据集——C-MAPSS<sup>[11]</sup>对方法进行验证, 该数据集包含了不同故障模式和工作条件下涡扇发动机从正常运行到故障失效的4组传感器监测数据(FD001~FD004), 并且将21种传感器作为能够表征发动机运行状况的典型指标。

### 3.2 数据预处理

#### 3.2.1 特征选择

以FD001监测数据为例展示特征选择的过程, 这里仅展示训练集4个传感器数据特征的分布。FD001前12个特征分布见图6, 其中: 深蓝色点表示退化数据; 红色点表示最终失效点; 横坐标为发动机的全寿命周期内运行的时间, 单位为周期; 纵坐标为不同传感器的测量值。由图6可知, T2传感器的方差为0, 表明传感器的监测数据在整个生命周期中并未产生显著变化, 应予以剔除。本研究最终选取14个传感器数据作为输入特征的数据集, 分别为: T24, T30, T50, P30, Nf, Nc, Ps30, Phi, NRf, NRc,

BPR, htBleed, W31和W32。

### 3.2.2 数据归一化及RUL标签设置

由于多维监测数据具有不同的量纲,所以在模型构建前须进行归一化预处理以消除特征之间的影响。选用最小-最大标准化方法将数据统一至[0,1]范围内,即

$$\tilde{x}_i^j = (x_i^j - x_{\min}^j) / (x_{\max}^j - x_{\min}^j) \quad (9)$$

其中: $\tilde{x}_i^j$ 为归一化后的数据; $x_{\max}^j$ 和 $x_{\min}^j$ 分别为第 $j$ 个传感器监测数据的最大值和最小值。

考虑到发动机在运行初期状态良好,性能退化量可忽略不计,但使用末期其性能会随着时间的延长而急剧下降。如果将发动机性能迅速劣化之前监测数据的标签设置为总运行周期减去当前运行周期数,会增加RUL预测结果的滞后性。因此,可认为发动机开始急速退化之前的RUL保持不变,即为训练集的RUL标签设置阈值,使之成为分段线性函数。RUL标签设置如图7所示。

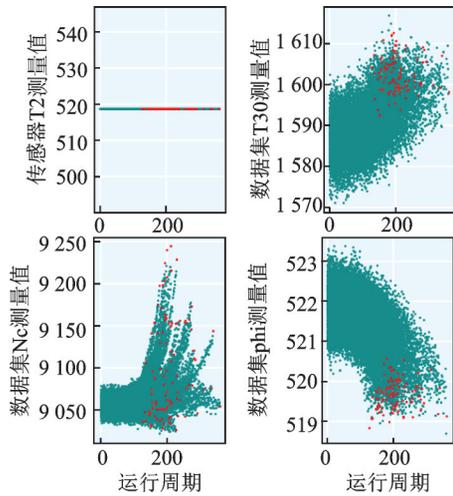


图6 FD001前12个特征分布图

Fig.6 Distribution map of the top 12 features of FD001

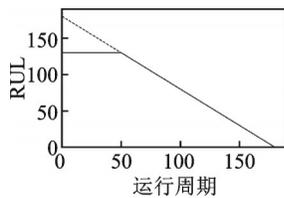


图7 RUL标签设置

Fig.7 RUL label setting

### 3.2.3 滑动窗口处理

为利用有限的时间序列深入挖掘性能退化规律,同时将时间序列转化成BiGRU网络擅长处理的3维输入格式,采用滑动时间窗分割方法对归一化后的数据进行处理,这样既可以充分保留相邻序列之间的时间相关性,又可以提高训练集样本的数量,使模型具有更高的鲁棒性和泛化能力。记发动机原始时间序列长度为 $T$ ,特征维度为 $N$ ,利用窗宽为 $S$

的滑动窗沿着时间序列滑动,将每滑动一个步长所截取的时间序列叠加至第3个维度,形成 $(T-S, S, N)$ 的3维张量。其计算过程为

$$\mathbf{X}_{1:T-S} = x_{1:1+S} \oplus x_{2:2+S} \oplus \dots \oplus x_{i:i+S} \dots \oplus x_{T-S:T} \quad (10)$$

其中: $\mathbf{X}_{1:T-S}$ 为转换后的3维张量; $x_{i:i+S}$ 为从第 $i$ 个时间周期开始长度为 $S$ 的序列; $\oplus$ 表示窗口内数据在第3个维度的连接,从而形成3维张量。

### 3.3 评价指标

从点预测评价指标、区间预测评价指标两方面来量化预测模型的性能。其中:前者用于评估模型的准确度和泛化能力;后者用于衡量预测区间的质量和覆盖率。

#### 3.3.1 点预测评价指标

1) 均方根误差(root mean square error, 简称RMSE)。其用于衡量预测值与真实值间的偏差,即

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (11)$$

其中: $y_i$ 为第 $i$ 个发动机的实际RUL值; $\hat{y}_i$ 为第 $i$ 个发动机的RUL预测值; $m$ 为发动机总数。

2) 评分函数(scoring function, 简称SF)。从安全性角度考虑,早期预测比滞后预测更可取,SF对RUL滞后预测情况施加更高的惩罚,即

$$\text{Score} = \begin{cases} \sum_{i=1}^m e^{-\frac{\hat{y}_i - y_i}{a_1}} - 1 & (\hat{y}_i - y_i < 0) \\ \sum_{i=1}^m e^{\frac{\hat{y}_i - y_i}{a_2}} - 1 & (\hat{y}_i - y_i \geq 0) \end{cases} \quad (12)$$

其中: $a_1 = 13$ ;  $a_2 = 10$ 。

$a_1$ 和 $a_2$ 控制SF对预测滞后性的惩罚程度,从而实现非对称预测偏好。SF分数越低,表明模型的预测性能越好。

#### 3.3.2 区间预测评价指标

1) 预测区间覆盖率(predict interval coverage probability, 简称PICP)。PICP反映实际RUL值 $y_i$ 落入预测值 $\hat{y}_i$ 波动区间 $[L_a(\hat{y}_i), U_a(\hat{y}_i)]$ 的概率,可用于评估预测区间的可靠性,即

$$\kappa(y_i) = \begin{cases} 1 & (y_i \in [L_a(\hat{y}_i), U_a(\hat{y}_i)]) \\ 0 & (y_i \notin [L_a(\hat{y}_i), U_a(\hat{y}_i)]) \end{cases} \quad (13)$$

$$\text{PICP} = \frac{1}{m} \sum_{i=1}^m \kappa(y_i) \quad (14)$$

其中: $L_a(\hat{y}_i)$ ,  $U_a(\hat{y}_i)$ 分别为 $\hat{y}_i$ 在额定置信水平 $(1 - \alpha)$ 下预测区间的上下边界。

PICP越大表示有越多的真实值落入预测区间内,模型的预测结果越可靠。PICP应尽可能超过给定的置信度,否则在实际维修决策中将被判定为预测无效。

2) 预测区间平均带宽(predict interval normalized average width,简称PINAW)。仅追求PICP会导致预测区间过宽,难以精确获得RUL预测的不确定性信息,因此还需要考虑区间宽度以提高决策价值。PINAW表示预测区间宽度的平均值,可以用来评估预测区间的清晰度,即

$$PINAW = \frac{1}{m(y_{max} - y_{min})} \sum_{i=1}^m (U_{\alpha}(\hat{y}_i) - L_{\alpha}(\hat{y}_i)) \quad (15)$$

其中: $y_{max}$ 和 $y_{min}$ 为实际RUL的最大值和最小值。

当PICP一定时,越小的PINAW对应越窄的预测区间,模型的预测效果越好。

### 3.4 模型结果

#### 3.4.1 可视化分析

为验证点预测的有效性,以FD001数据集为例,将预处理后的高维时间序列输入至FA-LN-BiGRU模型,RUL预测结果如图8所示。测试集的预测结果如图8(a)所示,为比较RUL大小对模型预测的影响,将FD001测试集中所有的发动机根据真实RUL值从大到小进行重新排序,结果如图8(b)所示。由图8(a)可知:RUL的真实值和预测值非常接近,表明本方法点预测的有效性;当RUL值较大时,发动机处于健康状态,表明设备运行状况良好。由图8(b)可知:发动机刚开始运行时,RUL预测误差较大,同时波动较为剧烈且表现出明显的滞后性;运行后期的RUL预测收敛于实际RUL,预测性能显著增强。因此,设备历史信息越充分,性能退化信息越明显,模型的预测误差越小。

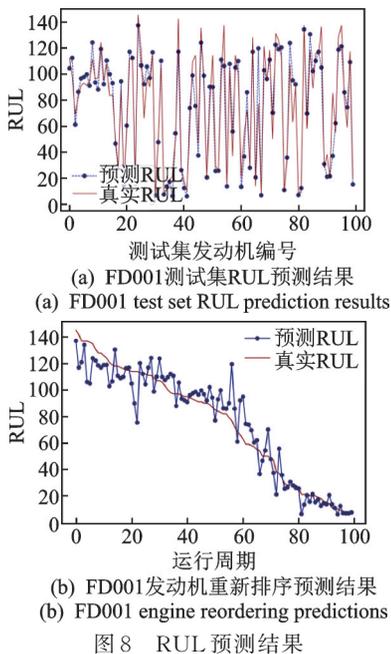
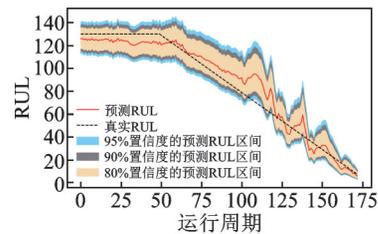
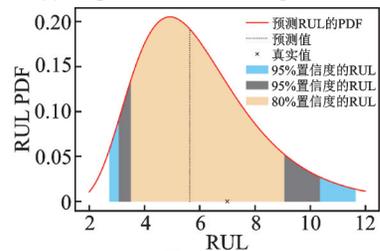


图8 RUL预测结果

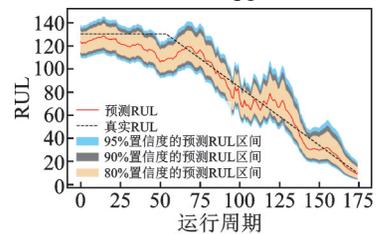
Fig.8 RUL prediction results



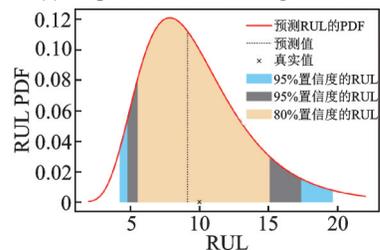
(a) Engine 34 RUL interval prediction results



(b) PDF of the final monitoring point RUL for engine 34



(c) Engine 76 RUL interval prediction results



(d) PDF of the final monitoring point RUL for engine 76

图9 2台发动机RUL区间预测结果

Fig.9 Prediction results of RUL interval for 2 engines

为了进一步研究区间预测的有效性,在数据集中随机选取2个引擎在80%~95%置信度的RUL区间预测结果与各个引擎最终监测点RUL的PDF曲线,2台发动机RUL区间预测结果基于表1中位数求得,如图9所示。由图可以看出:FA机制使得模型专注于包含引擎关键退化信息的重要特征,即使引擎刚开始运转时历史数据较少,难以预测RUL大小,模型预测值也较为接近临界值130;区间宽度在引擎退化引起的点估计波动期间变宽,但随着真实RUL的变小逐渐变窄,且后期点预测精度较高,这是因为随着运行周期的增加,发动机的性能退化量逐渐积累,模型能够逐渐捕获时间序列前后的退化信息,有效提升运行后期的预测精度。

#### 3.4.2 对比分析

为了研究所提方法进行发动机RUL点预测和

区间预测的性能,采用相关评价指标来评估不同模型在测试集上的准确度和泛化能力。表2为不同模型点预测结果对比:①对比了单一模式下FD001数据集和多种模式下FD004数据集;②利用不同循环神经网络(recurrent neural networks,简称RNN)的训练效果对比了不同种类的注意力机制,即自注意力机制(self-attention,简称SA)和FA机制的特征提取效果;③对比了可以进行区间预测的蒙特卡洛模型<sup>[9]</sup>和利用Bootstrap(BS)法改进LSTM(LSTMBS)<sup>[10]</sup>模型的点预测准确度。

由表2可知,与其余7种方法相比,除了蒙特卡洛模型之外,本研究方法的RMSE和SF指标均为最小。对于FD001数据集:RMSE=13.13,与其他方法相比平均降低了9%;SF=238,平均降低了30%。对于FD004数据集:RMSE=20.29,与其他方法相比平均降低了18%;SF=3395,平均降低了33%。

由于LN分布的不对称性,使用中位数、期望值和众数来评估点预测精度时存在细微差异。相较于另外2个统计特征,期望值为RMSE提供了更好的结果,但考虑到滞后预测的危害及综合RMSE值的大小,选取SF值更小的中位数作为点预测的结果。进一步分析可知:BiGRU能够捕捉双向长时间依赖特性,较单向网络FD001数据的RMSE和Score分别下降约4%和10%,FD004数据的RMSE和Score下降约7%和16%,达到预测精度更优的效果;由于FA机制的概率权重不同于SA机制的加权归一化权重,可以对不同特征进行重要性打分,而非对某一重要特征进行筛选,进一步提升了模型预测精度。尽管本研究方法在离线训练阶段的平均耗时为349s,但是在线测试阶段仅耗时1.3s,与其他方法应用于FD001的平均耗时相比仅相差0.13s,但点预测精度更高,可以补偿复杂模型所带来的时间损失。

表2 不同模型点预测结果对比

Tab.2 Comparison results of point forecasts of different models

模型	FD001				FD004			
	RMSE	SF	训练时间/s	测试时间/s	RMSE	SF	训练时间/s	测试时间/s
RNN	15.96	382.0	261	1.2	26.54	6 592	784	2.5
LSTM	14.92	342.0	297	1.3	25.16	5 127	916	2.4
GRU	15.14	356.0	265	0.8	26.17	5 550	803	1.9
BiGRU	14.53	321.0	322	1.0	24.26	4 630	965	2.2
SA+BiGRU	13.86	291.0	343	1.2	23.45	4 886	983	2.5
蒙特卡洛模型	12.51	219.5	365	1.5	21.13	3 457	1 096	2.9
LSTMBS模型	14.46	481.1	334	1.2	27.11	5 200	971	2.6
FA-LN-BiGRU(中位数)	13.13	238.0	349	1.3	20.29	3 395	996	2.6
FA-LN-BiGRU(期望值)	12.76	249.0	349	1.3	19.75	3 442	996	2.6
FA-LN-BiGRU(众数)	13.75	254.0	349	1.3	21.54	3 484	996	2.6

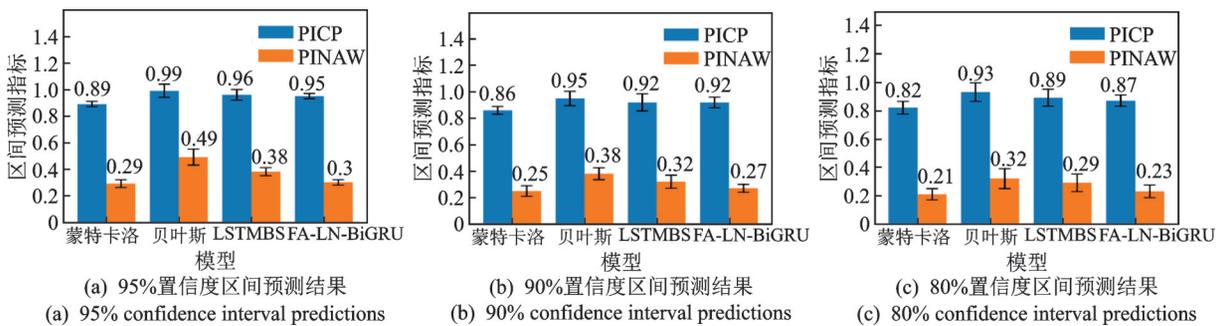


图10 不同置信度下区间预测结果

Fig.10 Interval prediction results under different confidence levels

为了进一步验证本研究方法进行区间预测的优势,分别构建蒙特卡洛模型、贝叶斯模型<sup>[7]</sup>和LSTMBS模型作为对比模型,在FD001数据集进行10次试验,不同置信度下区间预测结果如图10所示。

对比表2和图10可知:蒙特卡洛模型在点预测的效果最好,但所使用的Dropout操作难以描述设备性

能退化的不确定性,过于追求神经网络的性能而导致置信区间的平均宽度过窄,PICP难以满足对应置信度的要求;贝叶斯模型作为传统的统计分析模型,面对高维特征时大数据的波动性和稀疏性导致PINAW过宽;LSTMBS模型区间覆盖率与本研究方法相差不大,但是平均带宽PINAW在置信度为95%,90%

和80%时分别缩小19.8%,13.9和16.9%,说明本研究方法可以更准确、更稳定地量化性能退化的不确定性,其点预测精度也优于LSTMB模型,具有更强大的特征提取能力和数据处理能力。综上所述,本研究方法能够从高维、稀疏的大数据中提取更为准确的性能退化趋势特征,有效衡量设备退化过程中的不确定性,实现RUL的精准预测。

## 4 结 论

1) FA机制使得端到端的预测模型更多地专注于重要特征,无需人工干预就可以实现多维特征重要性的动态加权。LN-BiGRU可以深入挖掘时间序列前后的退化信息,同时基于LN分布衡量设备退化过程中的不确定性,有效提高机械设备剩余寿命点预测和区间预测的准确度和可靠性。

2) 利用FA-LN-BiGRU融合模型对运行条件复杂和故障模式多变的多维机械设备监测数据进行处理,可生成兼顾可靠性和准确性的RUL预测区间,有利于后续运行规划、维修决策等健康管理措施。

## 参 考 文 献

- [1] RODRIGUES L R. Remaining useful life prediction for multiple-component systems base on a system level performance indicator [J]. IEEE/ASME Transactions on Mechatronics, 2017, 23(1):141-150.
- [2] 李天梅,司小胜,刘翔,等. 大数据下数模联动的随机退化设备剩余寿命预测技术[J]. 自动化学报, 2022, 48(9):2119-2141.  
LI Tianmei, SI Xiaosheng, LIU Xiang, et al. Data-model interactive remaining useful life prediction technologies for stochastic degrading devices with big data[J]. Acta Automatica Sinica, 2022, 48(9):2119-2141. (in Chinese)
- [3] 苏向敬,山衍浩,周汶鑫,等. 基于GRU和注意力机制的海上风机齿轮箱状态监测[J]. 电力系统保护与控制, 2021, 49(24):141-149.  
SU Xiangjing, SHAN Yanhao, ZHOU Wenxin, et al. GRU and attention mechanism-based condition monitoring of an offshore wind turbine gearbox[J]. Power System Protection and Control, 2021, 49(24):141-149. (in Chinese)
- [4] 袁烨,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.  
YUAN Ye, HUANG Hong, CHENG Cheng, et al. Remaining useful life prediction of the aircraft engine based on the GRU-GAN network with a feature atten-
- tion mechanism[J]. Scientia Sinica Technologica, 2022, 52(1):198-212. (in Chinese)
- [5] CAO Y, JIA M, DING P, et al. Transfer learning for remaining useful life prediction of multi-conditions bearings based on bidirectional-GRU network[J]. Measurement, 2021, 178(5):109287.
- [6] KUNDU P, DARPE A K, KULKARNI M S. Weibull accelerated failure time regression model for remaining useful life prediction of bearing working under multiple operating conditions[J]. Mechanical Systems and Signal Processing, 2019, 134(1):1-19.
- [7] 赵申坤,姜潮,龙湘云. 一种基于数据驱动和贝叶斯理论的机械系统剩余寿命预测方法[J]. 机械工程学报, 2018, 54(12):115-124.  
ZHAO Shenkun, JIANG Chao, LONG Xiangyun. Remaining useful life estimation of mechanical systems based on the data-driven method and bayesian theory[J]. Journal of Mechanical Engineering, 2018, 54(12):115-124.(in Chinese)
- [8] HU C H, PEI H, SIX S, et al. A prognostic model based on DBN and diffusion process for degrading bearing[J]. IEEE Transactions on Industrial Electronics, 2020, 67:8767-8777.
- [9] 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(2):325403.  
MOU 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(2):325403. (in Chinese)
- [10] YUAN L, LIN X Z, CHONG D L. Uncertainty prediction of remaining useful life using long short-term memory network based on bootstrap method[C]//2018 IEEE International Conference on Prognostics and Health Management (ICPHM). Seattle, WA, USA: IEEE, 2018:1-8.
- [11] SAXENA A, KAI G, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation[C]//2008 International Conference on Prognostics and Health Management. Denver, CO, USA:IEEE, 2008:1-9.



**第一作者简介:**梁伟阁,男,1985年4月生,博士、硕士生导师。主要研究方向为机械装备可靠性、测试性与剩余寿命预测。

E-mail:1312021010@nue.edu.cn