

DOI:10.19651/j.cnki.emt.2517810

# 基于改进 CNN-BiGRU-A 的涡扇发动机 RUL 智能预测与维护\*

董海<sup>1</sup> 吴越童<sup>2</sup>

(1. 沈阳大学应用技术学院 沈阳 110044; 2. 沈阳大学机械工程学院 沈阳 110044)

**摘要:** 针对现代工业系统大多关注其预测性能而很少同时考虑设备维护决策问题,提出一种数据驱动的动态预测性维护方法,以避免系统因故障突然停机,确保系统安全运行。首先,通过对涡扇发动机的健康状态进行实时监控,获取运行数据,以此建立基于注意力机制结合卷积-双向门控循环单元的涡扇发动机剩余使用寿命模型,利用黑鹰优化算法对该模型的超参数进行调优;其次,将监测数据输入训练好的集成网络,并根据预测的剩余使用寿命,提出一种具有不确定系统任务周期的动态预测性维护策略;最后,以 C-MAPSS 数据集为例,验证本文所提方法能够提高设备预测性能,预测后维护效果良好。

**关键词:** 预测性维护;剩余使用寿命;黑鹰优化算法;涡扇发动机

**中图分类号:** TP391.5; TN807 **文献标识码:** A **国家标准学科分类代码:** 520.2

## Intelligent prediction and maintenance strategy of turbofan engine RUL based on improved CNN-BiGRU-A

Dong Hai<sup>1</sup> Wu Yuetong<sup>2</sup>

(1. School of Applied Technology, Shenyang University, Shenyang 110044, China;

2. School of Mechanical Engineering, Shenyang University, Shenyang 110044, China)

**Abstract:** Aiming at the problem that modern industrial systems tend to focus on their predictive performance while paying little attention to equipment maintenance decision-making, a data-driven dynamic predictive maintenance method is proposed to avoid sudden system failures and ensure safe operation. First, the health status of the turbofan engine is monitored in real-time to obtain operating data, which is used to establish a turbofan engine remaining useful life model based on a convolutional neural networks-bidirectional gated recurrent unit-attention mechanism. The hyperparameters of the CNN-BiGRU-A are optimized using the black hawk optimization algorithm; second, the monitored data is input into the trained integrated network, and a dynamic predictive maintenance strategy with uncertain system task cycle is proposed based on the predicted remaining useful life; finally, the proposed method is verified by using the C-MAPSS data set to show that it can improve equipment predictive performance and perform good predictive maintenance afterward.

**Keywords:** predictive maintenance; remaining useful life(RUL); black eagle optimizer; turbofan engine

## 0 引言

飞机发动机的健康状况对飞行安全和经济效益有着深远的影响,准确预测飞机发动机的剩余使用寿命(remaining useful life, RUL),为发动机的维护和更换提供预警是十分重要的<sup>[1]</sup>。航空发动机有许多精密零件,其结构复杂,飞行环境、使用情况、飞行周期等因素都可能影响零部件的性能。由于耦合零件众多,工况多变,因此,发动

机的 RUL 难以准确的预测。

预测性维护(predictive maintenance, PdM)是一种基于数据分析和预测技术的维护策略,通过实时监控设备和机器的状态,结合数据分析技术,提前预测设备可能发生故障的时间和部位,从而实现及时的维护。其目标是避免设备故障,减少停机时间,提高设备的可靠性和效率。

迄今为止,研究人员在开发预测性维护的 RUL 预测模型方面做出了相当大的努力,并在初步应用中取得了良

收稿日期:2025-01-03

\* 基金项目:国家自然科学基金(71672117)、中央引导地方科技发展资金计划(2021JH6/10500149)项目资助

好的性能。一般来说,这些模型可以分为基于物理的模型和基于数据驱动的模型。张鑫阳等<sup>[2]</sup>针对传统方法难以同时捕捉局部特征和长时间依赖性的问题,提出一种基于并行时间卷积网络(temporal convolutional network,TCN)与双向长短期记忆网络(bidirectional long short term memory,BiLSTM)的新型混合模型。陈维兴等<sup>[3]</sup>针对航空发动机运行周期内故障数据难以采集而造成的数据失衡等问题,提出一种基于 Wasserstein 距离与梯度惩罚措施的条件生成对抗网络与卷积长短期记忆网络相结合的预测模型。Mitici 等<sup>[4]</sup>基于估计相关的不确定性,提出一个数据驱动的多部件预测性维护的端到端框架,用卷积神经网络开发概率 RUL 预测。Ture 等<sup>[5]</sup>提出一种 PdM 模型,预测准确的维护时间,开发涡扇发动机 RUL 的预测模型。郭俊锋等<sup>[6]</sup>针对多传感器长序列数据下航空发动机 RUL 方法存在预测准确度不足的问题,提出一种基于堆叠膨胀卷积神经网络的航空发动机 RUL 方法。吴嘉俊等<sup>[7]</sup>针对传统 LSTM 难以高效提取大数据所蕴含的退化信息问题,提出一种基于改进 LSTM 网络的 RUL 预测方法。Le 等<sup>[8]</sup>针对标准的深度学习工具无法考虑预测任务中固有的不确定性,提出一种不确定性感知方法,预测 RUL 同时捕获任意和认知的不确定性。Fu 等<sup>[9]</sup>提出一种新的多通道关注双

任务时间卷积神经网络(MCA-DTCN)的模型,将故障模式检测和 RUL 预测整合到一个框架中,使监测对健康期和恶化期更加敏感。

上述研究多数关注 RUL 预测,部分关注 PdM,少有兼顾两方面研究。将数据驱动的 RUL 预测整合到维护计划中已被证明可以显著降低维护成本和故障数量<sup>[10-12]</sup>。

因此,本文提出一种基于注意力机制结合卷积-双向门控循环单元的(convolutional neural networks-bidirectional gated recurrent unit-attention mechanism, CNN-BiGRU-A)的寿命预测方法,引入黑鹰优化算法(black eagle optimizer,BEO)对该模型的超参数进行调优,根据预测的 RUL,提出一种具有不确定系统任务周期的动态 PdM 策略,利用商用模块化航空推进系统仿真(commercial modular aero-propulsion system simulation,C-MAPSS)数据集对所提方法进行验证。

## 1 基础理论

本文提出的完整数据驱动的动态 PdM 策略,包括基于实时监控的状态信息预测系统,开展 RUL 预测,并根据预测信息制定最优维护策略,动态预测性维护框架如图 1 所示。

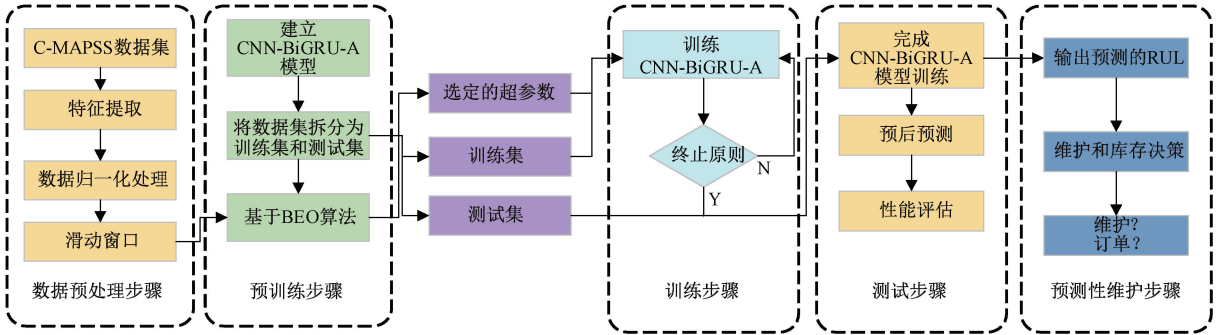


图 1 动态预测性维护框架

Fig. 1 Dynamic predictive maintenance strategy framework

本节将介绍 CNN-BiGRU-A 模型主要模块的背景知识,包括 CNN、双向门控循环单元和多头自注意力(multi-head self-attention,MHSA)。

### 1.1 CNN 网络基础理论

CNN 是一种特定类型的前馈网络,用于从多个传感器数据中提取特征。卷积层是 CNN 的核心部分,卷积层通过局部连接和权重共享对输入数据进行卷积,其功能是通过在原始数据上移动卷积滤波器来提取特征。卷积运算公式如式(1)所示。

$$f_i = \delta(w_f \otimes x_i + b_f) \quad (1)$$

式中: $f_i$  为提取的特征映射; $w_f$  定义核权值; $b_f$  表示偏置; $\delta$  表示激活方法。

### 1.2 BiGRU 网络基础理论

门控递归单元(GRU)是一种特殊的 LSTM,由 Cho

等<sup>[13]</sup>提出,用于学习长期时间模式,克服循环神经网络(recurrent neural network,RNN)中梯度消失的问题。GRU 网络有两个不同的门,包括重置门和更新门。重置门决定有多少以前状态的信息将被遗忘,更新门决定如何更新当前状态信息。

传统的 GRU 只能利用序列数据的先验信息,为了解决这种情况,采用双向 GRU 网络同时挖掘时间序列数据的过去和未来状态,将两个隐藏层连接得到网络的最终输出,如式(2)~(4)所示。

$$\vec{h}_t = f(b_{\vec{h}} + W_{\vec{h},\vec{h}} \cdot \vec{h}_{t-1} + W_{\vec{h},x} \cdot x_t) \quad (2)$$

$$\vec{h}_t = f(b_{\vec{h}} + W_{\vec{h},\vec{h}} \cdot \vec{h}_{t+1} + W_{\vec{h},x} \cdot x_t) \quad (3)$$

$$h_t = g(W_{h,\vec{h}} \cdot \vec{h}_t + W_{h,\vec{h}} \cdot \vec{h}_t) \quad (4)$$

式中: $\vec{h}_t$  和  $\vec{h}_t$  分别表示正向隐藏状态和反向隐藏状态;

$f(\cdot)$  表示 GRU 处理;  $g(\cdot)$  表示非线性激活函数。

### 1.3 注意力机制

在深度学习应用中,利用注意力机制从不同时间步长的学习特征中自动发现复杂的信息交互,目的是突出不同特征中的判别信息,减少无用信息的影响。自注意力是注意力机制的一种特殊变体,近年来被广泛应用于各个领域,以捕获有效的信息交互。自注意力的输出如式(5)所示。

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (5)$$

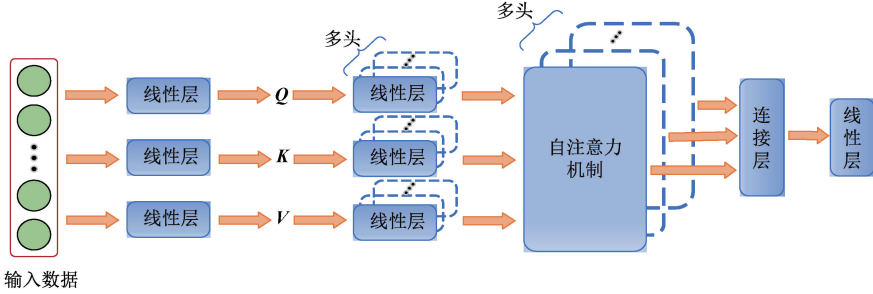


图 2 多头自注意力机制结构

Fig. 2 The structure of multi-head self-attention mechanism

## 2 基于 CNN-BiGRU-A 的 RUL 预测模型

### 2.1 CNN-BiGRU-A 结构框架

本文引入一种基于深度学习的机械系统预测框架,该

式中: $Q$ 、 $K$  和  $V$  分别表示查询、键和值的矩阵; $d_k$  表示键的维数。在自注意力中,这些矩阵由前一层的输出组成,彼此相等<sup>[14]</sup>。MHSA 是多个自注意力功能的整合,由 Vaswani 等<sup>[15]</sup>开发,用于进一步学习不同特征中的判别信息,如图 2 所示,其输出计算如式(6)所示。

$$MultiHead(Q, K, V) = \text{concat}(A_1, \dots, A_h)W^o \quad (6)$$

$$A_i = \text{Attention}(QW_i^q, KW_i^k, VW_i^v) \quad (7)$$

式中: $h$  表示多头的个数; $W^o$ ,  $W_i^q$ ,  $W_i^k$ ,  $W_i^v$  表示权重矩阵。

框架旨在通过从多个传感器获取的监测数据中提取高级特征,进行有效可靠的预测估计。提出的 CNN-BiGRU-A 模型包括具有 MHSA 机制的多尺度 CNN、双向 GRU 网络和全连接层,模型整体架构如图 3 所示。

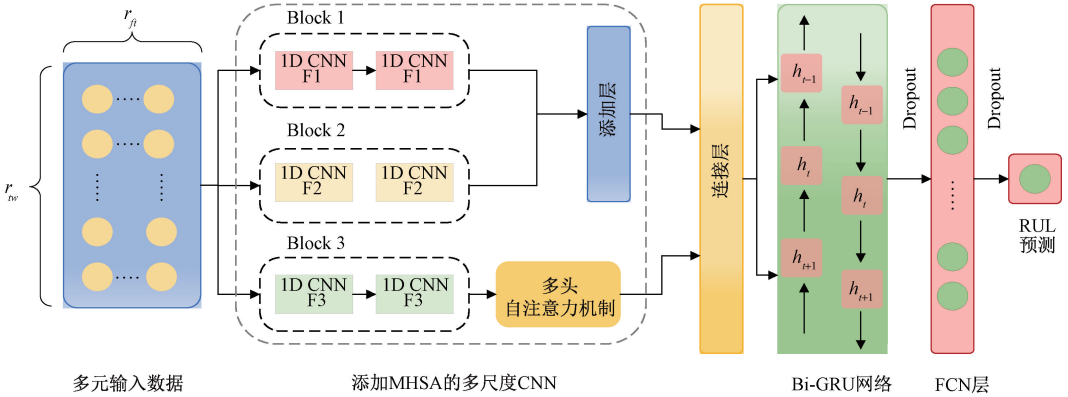


图 3 提出的 CNN-BiGRU-A 框架的总体结构

Fig. 3 The overall structure of the proposed CNN-BiGRU-A framework

首先,采用滑动窗口法从原始退化数据中获得模型的输入数据,输入大小为  $r_{tw} \times r_{ft}$ ,其中  $r_{tw}$  表示时间窗口大小,  $r_{ft}$  表示所选特征的个数。将  $r_{tw} \times r_{ft}$  大小的多元退化数据输入到网络的多尺度 CNN 部分。本文采用 3 种不同 CNN 块的多尺度过程,从故障数据中自动捕获优势模式,以提高预测精度。这些具有两个卷积层的块应用 3 种不同的核大小  $F_1, F_2, F_3$  并行构建,用于特征提取。将 Block 1 和 Block 2 学习到的特征相加,考虑到这些块的输出维相同,因此采用 CNN-BiGRU-A 方法中的添加层执行此操作。在本研究中,利用 MHSA 机制学习输出和输入之间

的依赖关系。图 3 中,Block-3 的输出被发送到 MHSA 机制中,从学习到的特征中发现判别信息。然后,将前两个多尺度 CNN 块提取的特征与 MHSA 的输出相结合,通过使用连接层来执行组合过程。

此外,每个卷积层使用  $\tanh$  激活函数处理网络的非线性,应用 BGRU 网络从多尺度 CNN 块提取的高级特征中,有效学习长期依赖关系。最后,采用两个全连通层进行预测。为了解决训练处理中的过拟合问题,在每个全连接层之前进行 dropout 操作,并进行早期停止操作。CNN-BiGRU-A 模型的每一层、输出大小以及每一层与前一层

连接的层如表 1 所示。

表 1 CNN-BiGRU-A 方法介绍

Table 1 Introduction of proposed CNN-BiGRU-A approach

图层类型	输出形状	连接到
输入层	(无,30,14)	无
Conv1D(Block-1a)	(无,30,12)	输入层
Conv1D(Block-2a)	(无,30,12)	输入层
Conv1D(Block-3a)	(无,30,12)	输入层
Conv1D(Block-1b)	(无,30,20)	Conv1D(Block-1a)
Conv1D(Block-2b)	(无,30,20)	Conv1D(Block-2a)
Conv1D(Block-3b)	(无,30,20)	Conv1D(Block-3a)
MHSA 机制	(无,30,20)	Conv1D(Block-3b)
添加层	(无,30,20)	Conv1D(Block-1b), Conv1D(Block-2b)
连接层	(无,30,40)	添加层,MHSA 机制
双向 GRU	(无,40)	连接层
Dropout	(无,40)	双向 GRU
稠密层	(无,16)	Dropout
Dropout	(无,16)	稠密层
稠密层	(无,1)	Dropout

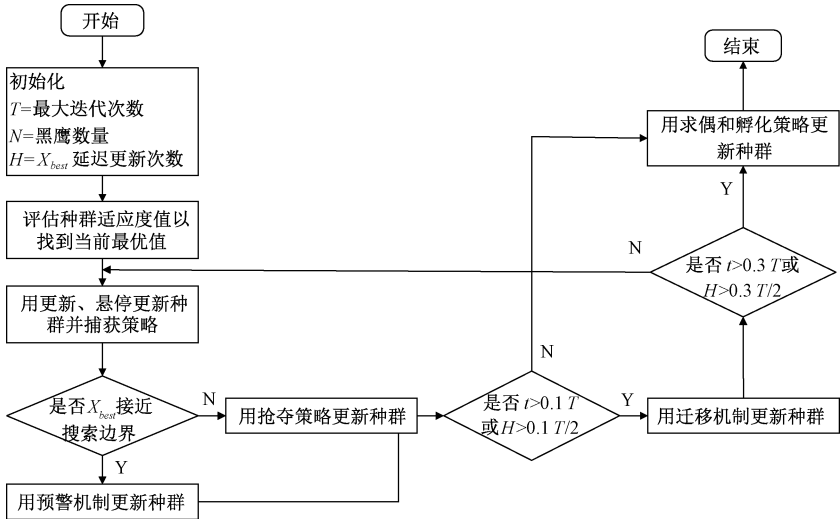


图 4 黑鹰优化算法流程图

Fig. 4 The flowchart of black eagle optimizer

部件可以实现完美的维护操作,但更换或订购的最佳时间难以确定,因此,本文假设维护策略仅在设备闲置期间执行。此外,如果涡轮风扇发动机系统在运行周期(例如第  $i$  周期)中仍在运行,则根据可用监测数据的 RUL 预测考虑是否执行维护决策。由于不能在任务执行期间进行维护,有必要知道当前 RUL 是否低于任务周期  $\Delta t$  (考虑为随机变量)。对涡扇发动机进行 PdM 的决策如式(10)所示。

$$M = \begin{cases} 1, & \widehat{RUL}_i \leq \Delta t + \delta \\ 0, & \text{其他} \end{cases} \quad (10)$$

2.2 采用 BEO 优化 CNN-BiGRU-A 模型

在本研究中,引入 BEO 对 CNN-BiGRU-A 的超参数进行调优,以提供更有效的 RUL 预测性能。BEO 是一种新型的元启发式算法,结合了黑鹰的生物规律和数学变换指导粒子的搜索行为。算法流程图如图 4 所示。

一般来说,该算法寻求在一个巨大而复杂的搜索空间中获得最小化(或最大化)预定义适应度函数的决策变量的最佳值。该算法的目标函数选择为均方根误差(RMSE)。CNN-BiGRU-A 的优化过程计算如式(8)~(9)所示。

$$Min \ RMSE_{\phi^*}(d) \quad (8)$$

$$s, t, \phi^* = \underset{\phi}{\operatorname{argmin}}(MSE_{\phi}(d)) \quad (9)$$

式中: $d$  表示真实 RUL 与预测值之差; $\phi^*$  表示 CNN-BiGRU-A 的最优超参数。引入均方误差(MSE)作为 CNN-BiGRU-A 的损失函数,采用 Adam 优化器对网络的权重项和偏置项进行优化,减小网络的 RUL 估计误差,BEO 中的决策变量被定义为整数。

3 动态预测性维护策略

3.1 基于预测后信息的维护决策

在整个 PdM 框架内,系统监控点根据现有的监控信息,做出是否维护或订购备件的基本决策。通过更换故障

式中: $M=1$  表示预测需要更换; $M=0$  表示预测不需要更换; $\widehat{RUL}_i$  代表涡扇发动机  $i$  预测的 RUL; $\delta$  表示由于高估 RUL 的一种错误变量减少意外停机的风险; $\Delta t + \delta$  表示维护报警阈值。在本文中, $\delta$  由预测 RUL 的测试样本的平均绝对误差确定,其计算公式如式(11)所示。

$$\delta = \frac{1}{N} \sum_{i=1}^N (|\widehat{RUL}_i - RUL_i|) \quad (11)$$

式中: $N$  表示测试样本数; $\widehat{RUL}_i$  和  $RUL_i$  分别表示涡扇发动机的预测 RUL 和真实 RUL。由于涡扇发动机 RUL 大



于 30 时退化特性不显著,不涉及维修和零配件操作。因此,只在涡扇发动机 RUL 低于 30 时才考虑误差变量  $\delta$ ,涡扇发动机 RUL 小于 30 是建议计算误差变量  $\delta$  的参考值。

此外,涡扇发动机 RUL 预测的目的是确定该发动机未来能执行多少任务(即可用性),以及该任务的可靠性,其计算方法如式(12)~(13)所示。

$$n^* = \lceil \widehat{RUL}_i / \Delta t \rceil^- \quad (12)$$

$$\gamma^* = \widehat{RUL}_i / \Delta t - \lceil \widehat{RUL}_i / \Delta t \rceil^-, \text{ if } \lceil \widehat{RUL}_i / \Delta t \rceil^- = 1 \quad (13)$$

式中: $n^*$  表示当前预测 RUL 的可用性变量; $\lceil \widehat{RUL}_i / \Delta t \rceil^-$  表示函数  $\widehat{RUL}_i / \Delta t$  的下整数; $\gamma^*$  为可靠性变量,表示最后一次任务执行的可靠性,其目的是保证涡扇发动机在任务执行期间的可靠性。

对于备件订单和库存管理决策,首先考虑备件订单的周期时间  $Q$ 。为了保证在涡扇发动机出现故障时及时更换,仓库一定要备货。例如,根据涡扇发动机的 RUL,在  $RUL = Q + \Delta t + \delta$  之前安排订单,确保在故障发生前及时更换涡扇发动机。备件订单决策计算如式(14)所示。

$$Order = \begin{cases} 1, & \widehat{RUL}_i \leq Q + \Delta t + \delta \\ 0, & \text{其他} \end{cases} \quad (14)$$

式中: $Order = 1$  表示涡扇发动机整机需要订购备件; $Order = 0$  表示无订购需要。

此外,在优化库存管理时还应考虑缺货成本 ( $C_{os}$ )。如果需要对涡扇发动机进行预测性更换,那  $\widehat{RUL}_i \leq \Delta t + \delta$ ,在此期间,如果没有可用的备件( $SP = 0$ ),则产生费用为  $C_{os}$ 。当涡扇发动机的寿命周期结束时,相应的成本率(以  $CR_i P$  表示)如式(15)所示。另一方面,如果  $\widehat{RUL}_i >$

$\Delta t + \delta$ ,则系统继续执行任务,直到  $\widehat{RUL}_i \leq \Delta t + \delta$ 。

$$CR_p^i = \frac{C_p + C_{os} \cdot I_{(SP=0)}}{\widehat{L}_i - (\Delta t + \delta)} \quad (15)$$

式中: $I$  表示指示函数,当  $SP = 0$  时, $I = 1$ ,否则  $I = 0$ ; $SP = 0$  表示与备件可用性相关的库存状态; $C_p$  表示 PdM 成本; $\widehat{L}_i$  表示预测涡扇发动机  $i$  的最大 RUL, $L_i$  表示对应涡扇发动机  $i$  的实际寿命。

此外,如果涡扇发动机系统出现故障,则需要进行故障更换,产生故障更换成本  $C_f$ 。与 PdM 一样,纠正性维护也会考虑备件可用性,相应的成本率以  $CR_f^i$  表示,如式(16)所示。经过纠正性维护后,结束当前涡扇发动机的生命周期,开始新的生命周期。

$$CR_f^i = \frac{C_f + C_{os} \cdot I_{(SP=0)}}{L_i} \quad (16)$$

式中: $C_f$  表示纠正性维护成本。一般情况下,纠正性维护成本比 PdM 成本更昂贵,即: $C_f > C_p$ 。

一种基于理想的预测性维护(IPM)策略,该策略基于预测 RUL 值等于实际 RUL 值的假设,即  $\widehat{RUL}_i = RUL_i$ 。在这种情况下,完美预测 RUL 的成本率最小,涡扇发动机 RUL 可以得到充分利用。同时,在这种理想情况下不存在缺货成本。成本率最小的计算如式(17)所示。

$$CR_{IPM}^i = \frac{C_p}{L_i} \quad (17)$$

本文提出的基于预测 RUL 的动态 PdM 策略框架如图 5 所示。从图 5 中,可以根据当前预测的 RUL 和系统运行工况确定是否进行 PdM。同时,可以根据预测的 RUL 和库存确定是否购买订单。从图 5 可以看出,提出的动态 PdM 策略是可行的。

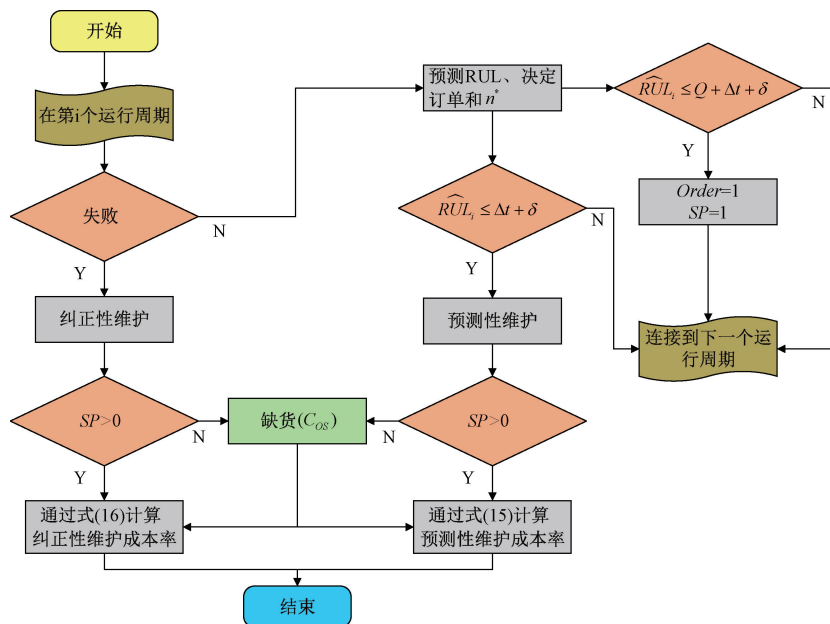


图 5 基于预测 RUL 的动态预测性维护策略

Fig. 5 Dynamic predictive maintenance strategy based predicted RUL

在本节中,维护、订单和库存管理活动与  $\Delta t$  相关。但  $\Delta t$  是一个随机变量,不是固定的。因此,将在下一节中重点优化  $\Delta t$ ,其目的是充分利用涡扇发动机 RUL 并降低与维护活动相关的成本。

### 3.2 任务周期 $\Delta t$

在实践中,通常需要长期的预测信息计划不同的经营活动(如维护、生产或库存等)。因此本节开发一种不确定任务周期的动态 PdM 策略。

在任务周期内不能预先更换涡扇发动机,然而,随着时间的推移,涡扇发动机会发生退化,最终导致故障。因此,应制定有效的 PdM 策略,使其在任务周期  $\Delta t$  内可靠。一般来说,飞机在执行任务过程中,执行任务的时间等于到达目的地并返回到起点所需的时间的总和,其中到达目的地或返回起点所需的时间可以被看作是一个指数分布  $F(t) = 1 - e^{-(\lambda t)}$  ( $t \geq 0$ )。

涡扇发动机的任务周期服从指数分布在本文是一个假设。那么,两者之间的累积时间,即任务周期  $\Delta t$ ,可以认为服从 Gamma 分布,其密度函数如式(18)所示。

$$f(t) = \frac{\lambda^k t^{k-1} e^{-(\lambda t)}}{\Gamma(k)} \quad (18)$$

式中: $\lambda$  和  $k$  是与 Gamma 分布相关的参数,Gamma 分布中的参数  $k$  类似于涡扇发动机的飞行路线数。此外,根据历史数据,可以知道涡扇发动机需要执行的任务次数以及各参数的大小,从而得到任务周期的平均值。在充分利用涡扇发动机 RUL 的同时,计划在飞机任务周期  $\Delta t$  之前对涡扇发动机进行预测性更换,以确保飞机执行任务的可靠性。同时选择较大的任务周期值以保证涡扇发动机在执行任务时不会出现故障。根据任务周期  $\Delta t$  的分布,如果已知参数  $\lambda$  和  $k$ ,则可以得到具体的概率分布,Gamma 分布的概率密度函数如图 6 所示。




图 6 Gamma 分布的概率密度函数

Fig. 6 Probability densityfunction of Gamma distribution

从图 6 中可以计算出  $k=2$  和  $\lambda=2$  时最优,任务周期  $\Delta t=2.94$ ,概率高达 98%。当  $k=3,4,5$  时,最优任务周期对应的概率在 98% 以内,  $\Delta t$  分别为 3.77、4.55、5.30。

## 4 实验与结果

本节中,通过 C-MAPSS 基准数据集评估 CNN-BiGRU-A 方法的预测能力。为了验证所提出的框架的可靠性,将本文提出框架的实验结果与使用不同性能指标的基准方法进行比较。

### 4.1 数据集描述

在本研究中,采用 NASA 开发的 C-MAPSS 数据集,即涡扇发动机退化数据,对 CNN-BiGRU-A 方法进行性能分析<sup>[16]</sup>。本研究使用 C-MAPSS 的第一个子数据集 FD001 进行实验。FD001 数据集中的一些传感器具有恒定值,对 RUL 预测没有任何贡献。因此,这些传感器值被舍弃,传感器 2、3、4、7、8、9、11、12、13、14、15、17、20 和 21 被确定为 CNN-BiGRU-A 方法的输入数据<sup>[17]</sup>。

在实验研究中,采用 Min-Max 缩放技术,将所有选中的特征和 FD001 数据集的整个训练子集用于 CNN-BiGRU-A 方法的训练阶段。标签归一化到  $[0,1]$  范围内,如式(19)所示。

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (19)$$

本文采用评分函数(SCORE)和均方根误差(RMSE)两个指标评估模型的性能准确性,如式(20)~(21)所示。

$$Score = \begin{cases} \sum_{i=1}^N \exp(-\frac{h_i}{13}) - 1, h_i < 0 \\ \sum_{i=1}^N \exp(\frac{h_i}{10}) - 1, h_i \geq 0 \end{cases} \quad (20)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N h_i^2} \quad (21)$$

式中: $N$  为数据样本总数; $h_i$  为预测误差。

### 4.2 实验设置及比较方法

在本研究中,引入 BEO 优化 CNN-BiGRU-A 的超参数,以提高 RUL 预测性能。这些超参数包括每个卷积层中的滤波器数量、BGRU 层中的神经元数量、dropout 率和第一个 FCL 中的神经元数量。此外,确定每个块中的过滤器数量相等。滤波器个数和神经元个数的参数范围设置为 8~64 的整数,drouout 设置为 0.1~0.4,BEO 得到的超参数和其他参数列于表 2。

考虑到 RUL 估计精度与计算时间之间的权衡,确定 BEO 系数为:惯性  $w=0.9$ ,加速度  $c_1=0.5$  和  $c_2=0.3$ ,种群大小=10,迭代次数=20。此外,Adam 函数使用的学习率设置为前 50 个 epoch 为 0.000 1。

为了评估 BEO-CNN-BiGRU-A 的性能,利用不同的深度学习方法进行对比实验。基准方法包括 LSTM、CNN-GRU 以及采用粒子群算法(particle swarm optimization, PSO)优化 CNN-BiGRU-A 的 PSO-CNN-BiGRU-A。此外,每种比较技术的前三层都使用了 tanh 激活函数。为公平比较,除上述实验设置外,其余设置均与 BEO-CNN-

BiGRU-A 方法相同。

表 2 CNN-BiGRU-A 的参数

Table 2 Parameters of the CNN-BiGRU-A	
超参数	量值
过滤器数量( $N_{f1}, N_{f2}$ )	32/64
BGRU 中的神经元( $N_g$ )	16
FCL 中的神经元( $N_{fc}$ )	16
Dropout rate	0.6
时间窗大小	30
内核大小( $F_1, F_2, F_3$ )	3/5/8
激活函数	tanh
批量大小	100
时期数	150
学习速率(0~50 时期)	0.001
MHSA 的头数	2

4.3 实验结果

在这一部分中,介绍综合实验研究的结果,以检验本文所提方法与各种基准方法的预测性能。首先,FD001 测试数据集中按 RUL 排序的发动机 RUL 预测结果如图 7 所示。




图 7 FD001 中按 RUL 排序的测试发动机的 RUL 估计结果  
Fig. 7 RUL estimation outcomes for test engines sorted by RUL in FD001

从图 7 中可以清楚地看到,本文所提方法预测的 RUL 能够很好地跟踪测试发动机的实际 RUL。总的来说,在 RUL 值较低的测试发动机上,本文所提方法获得了更准确和更敏感的预测性能。

在 FD001 的测试数据上,比较 BEO-CNN-BiGRU-A 与 LSTM、CNN-GRU 和 PSO-CNN-BiGRU-A 的 RUL 预测效果,如图 8 所示。

其中,LSTM 是一种流行的深度学习模型,被广泛应用于 RUL 预测中。与 CNN-BiGRU-A 方法类似,CNN-GRU 是所提出框架中使用的深度学习方法的集成。由 LSTM 和 CNN-GRU 组成的基准结构中没有使用注意机制。从图 8 中可以看出本文所提方法得到的预测结果与真实 RUL 值更接近,预测准确度更高。




图 8 4 种方法在 FD001 中的 RUL 预测结果对比图  
Fig. 8 Comparison chart of RUL prediction results of four methods in FD001

表 3 为不同方法在 FD001 上的性能比较,从表 3 中可以清楚地看到,与基准方法相比,本文方法提供了更好的结果,其 RMSE 和 Score 值分别为 16.86 和 180.93,远小于其他对比方法。特别是,本文所提方法显著提高了与 Score 标准相关的预测性能。与 LSTM 和 CNN-GRU 方法相比,本文所提方法的分值分别提高了 39.22% 和 57.48%。

表 3 不同方法在 FD001 上的性能比较

方法	FD001	
	RMSE	Score
LSTM	22.07	297.67
CNN-GRU	24.95	425.47
PSO-CNN-BiGRU-A	17.30	218.59
BEO-CNN-BiGRU-A	<b>16.86</b>	<b>180.93</b>

4.4 动态 PdM 过程

为了更好地评估涡扇发动机 RUL 运行状态的变化,本文进一步将训练集中的 100 台涡扇发动机按 8:2 的比例分成两部分。第一部分以前 80 台涡扇发动机作为训练集,第二部分以 81~100 台涡扇发动机作为测试集,用于预测涡扇发动机在运行周期中的状态变化。从测试集中随机选择的 4 台涡扇发动机的预测结果如图 9 所示。

根据图 9 的预测结果,首先,将 RUL 预测结果作为 PdM 策略的决策依据;其次,基于涡扇发动机执行任务周期  $\Delta t$  和误差变量  $\delta$  确定是否执行 PdM 策略,根据预测的 RUL 值进行备件订购和库存管理决策;最后,利用预测的 RUL 判断任务周期已知时涡扇发动机所能完成的任务数  $n^*$ ,以及最后一次任务执行的可靠性变量  $\gamma^*$ 。

已知  $C_p=100$ 、 $C_f=100$ 、 $Q=20$ <sup>[18]</sup>,并根据 3.2 节可知,当  $k=3$ 、 $\lambda=2$  时, $\Delta t=3.77$ 。为了演示所提出的动态的 PdM 框架,表 4 显示了 4 个涡扇发动机(ID82、ID90、ID92 和 ID98)的部分维护策略。在表 4 中,第 1 列和第 2 列分别表示发动机的运行周期和真实 RUL,第 3 列是每个

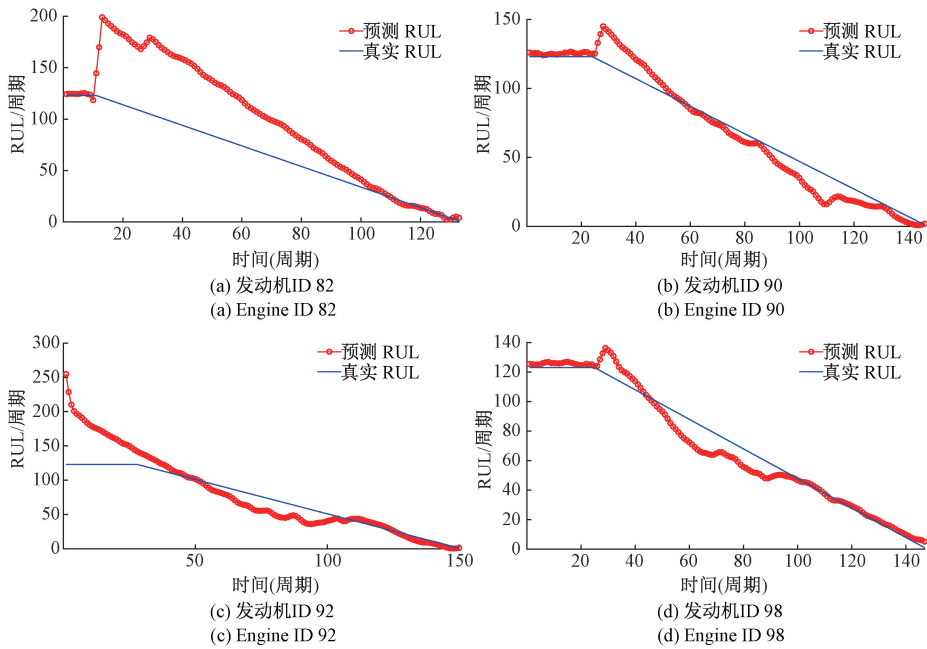


图 9 4 台涡扇发动机 RUL 预测结果

Fig. 9 RUL prediction results for four turbofan engines

表 4 任务周期  $\Delta t=3.77$  的动态预测性维护策略比较

Table 4 Dynamic predictive maintenance strategy with mission cycle  $\Delta t=3.77$

运行周期	真实 RUL	预测 RUL	$n^*$	O	S	M
涡扇发动机 ID82(L=134)						
110	24	24.116	6	1	0	0
115	19	16.192	4	1	0	0
120	14	13.731	3	1	0	0
125	9	7.032	1	1	0	0
130	4	2.408	0	1	1	1
涡扇发动机 ID90(L=147)						
125	22	15.068	3	1	0	0
130	17	14.375	3	1	0	0
135	12	7.500	1	1	0	0
140	7	2.452	0	1	0	1
145	2	1.190	0	1	1	1
涡扇发动机 ID92(L=151)						
130	21	17.575	4	1	0	0
135	16	10.214	2	1	0	0
140	11	7.756	2	1	0	0
145	6	5.236	1	1	0	1
150	1	1.162	0	1	1	1
涡扇发动机 ID98(L=148)						
125	23	23.535	6	1	0	0
130	18	19.433	5	1	0	0
135	13	15.013	3	1	0	0
140	8	9.998	2	1	0	0
145	3	6.809	1	1	1	0

涡扇发动机的预测 RUL,第 4 列  $n^*$  表示涡扇发动机可以执行的任务数量,第 5~7 列 O、S 和 M 分别表示订单、库存和维护所处的相应状态,L 表示涡扇发动机的真实失效时间。此外,表 4 中涡轮发动机预测的 RUL 每 5 个运行周期检查一次。

对于表 4 中的 ID92 涡扇发动机,当检测周期  $T=130$  时,当任务周期为 3.770 时,涡扇发动机可以执行 4 次任务。当检查周期  $T=145$  时,预测 RUL 小于  $\Delta t+\delta$ (即 7.408),此时预测需要更换涡扇发动机。但是,由于预测误差和检验周期的原因,订购的备件还没有到达仓库。此时,不能及时对涡扇发动机进行维护。因此,在计算 ID92 涡轮发动机的维修成本率时,应考虑其缺货成本。

对于表 4 中的 ID82 涡扇发动机,可以看到不存在缺货成本。因为涡扇发动机需要在检查周期  $T=130$  时进行维护,并且库存中已经有备件。

采用图 10 进一步说明 ID82 涡扇发动机的订货、库存和维护情况。由图 10(a)中可知,当  $T=110$  时, $RUL \leq Q+\Delta t+\delta$ ,需要订购备件。订购的备件将在交货周期  $Q=20$  后发货。同样,在图 10(b)  $T=125$  中,最优决策无需进行任何维护工作。最后,订购的备件到货,由于图 10(c)  $T=130$  中  $RUL \leq \Delta t+\delta$ ,最优决策是进行 PdM,从而保证任务的执行。

最后一次任务的涡扇发动机的可靠性  $\gamma^*$  可根据表 4 对应于执行任务次数  $n^*=1$  的 RUL 来计算。表 5 报告了最后一次任务中涡扇发动机的可靠性。

从表 5 可以看出,当最后一次执行任务的可靠性较小,即小于 0.8 时,在表 4 中进行 PdM(如 ID92 中  $T=$



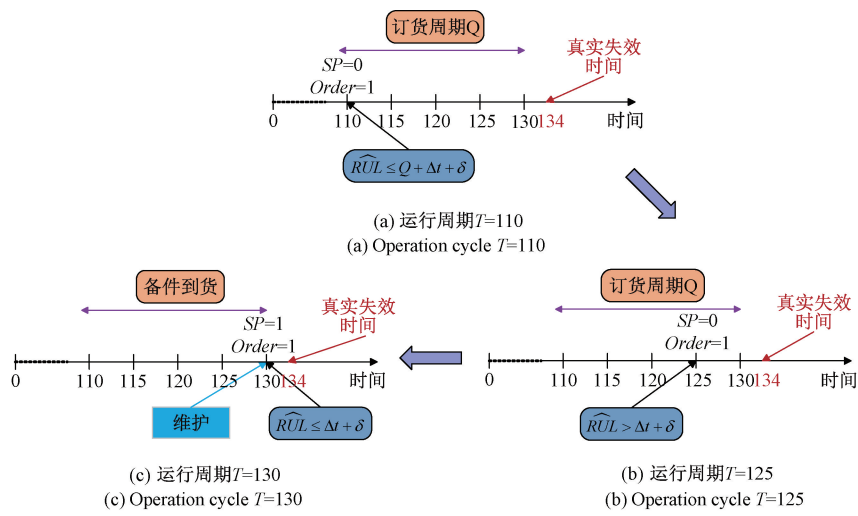


图 10 涡扇发动机 ID82 的订单,库存和维护决策  
Fig. 10 Order, stock, and maintenance decisions for turbfan engine ID82

表 5 涡扇发动机在最后一次任务中的可靠性	
Table 5 Reliability of the turbfan engine on its last mission	
涡扇发动机	$\gamma^*$
ID82	0.865
ID90	0.989
ID92	0.389
ID98	0.806

145,  $n^*=1, M=1$ ), 从而预防任务期间涡扇发动机的故障。此外, 当执行任务的可靠性较大, 即大于 0.8 时, 可以考虑继续执行任务。

因此, 涡扇发动机最后一次任务的可靠性可以作为涡扇发动机早期维修的标准之一。如果决策者希望追求  $\gamma^*=0.8$  这样的高可靠性, 则可以使用式 (22) 提前维护涡扇发动机。

$$M = \begin{cases} 1, & \gamma^* \leq 0.8, \\ 0, & \text{其他} \end{cases} \quad (22)$$

最后, 考虑误差变量  $\delta$  对相应维护策略的影响。如 3.1 节所述, 可以将  $\delta$  视为一个误差变量, 以降低由于 RUL 估计过高而导致故障发生的风险。

4.5 动态 PdM 策略的性能比较

本节通过与一般性 PdM 策略的比较, 体现本文提出的动态 PdM 策略的优越性。其中, 该一般性 PdM 策略被命名为策略 I, 该策略核心思想是根据系统 RUL 和检测间隔来确定涡扇发动机是否需要维护, 详见文献[19]。此外, 本文比较了理想的预测性维护策略, 以进一步说明所提出的动态 PdM 策略的性能。根据式 (17) 提出的理想预测性维护策略, 命名为策略 II。相应地, 式 (15) 和 (16) 可以作为所提出的动态 PdM 策略的评价指标。此外, 将可用性  $n^*$  和可靠性  $\gamma^*$  也作为本文提出的动态 PdM 的评价指标。

根据给出的  $C_p=100, C_f=100, C_{os}=10$  和预测的 RUL, 可以计算出 3 种维护策略的成本率、可用性和可靠性。图 11 显示了基于策略 I、策略 II 和本文所提策略的 ID81~ID100 的 20 台涡扇发动机的不同维护策略的性能比较。其中, 图 11 所提出的策略采用表 4 中  $\Delta t=3.77$  的任务周期。




图 11 20 台涡扇发动机的不同维护策略的性能比较  
Fig. 11 Performance comparison of different maintenance policies for the 20 turbfan engines

从图 11 可以看出, 策略 II 是最好的, 因为策略 II 使用了理想的维护策略, 其次是本文提出的 PdM 策略, 而策略 I 是相对最差的。不仅如此, 本文所提出的 PdM 策略与理想的维护策略 II 相差很小, 这表明本文所提出的维护策略是有效的。

5 结 论

现代工业系统通常侧重于提升预测性能, 而较少同时考虑设备预测和维护决策的综合优化效能。因此, 本文提出了一种基于数据驱动的动态 PdM 方法, 以 C-MAPSS 数

据集为例验证综合优化的有效性,得到结论如下:

建立一种基于 CNN-BiGRU-A 整体架构,该框架利用故障数据自动捕获优势模式,通过引入 BEO 对 CNN-BiGRU-A 模型的超参数进行调优,有效提高模型的预测精度;将本文所提方法与其他方法在 FD001 测试数据集中开展测试,测试结果验证了本文提出的方法能很好地跟踪测试发动机的实际 RUL,可以实现更高精度和更稳定的网络预测和训练;结合 RUL 模型,提出一种具有不确定系统任务周期的动态 PdM 策略,该策略考虑备件订单的周期时间和缺货成本,同时考虑具有成本效益的订单和库存管理决策,有效确定系统执行任务的数目,保证执行任务的可靠性。

## 参考文献

- [1] XIA J, FENG Y, LU C, et al. LSTM-based multi-layer self-attention method for remaining useful life estimation of mechanical systems[J]. *Engineering Failure Analysis*, 2021, 125:105385.
- [2] 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. Turbofan engine remaining life prediction based on parallel TCN-SE-BiLST model [J]. *Electronic Measurement Technology*, 2024, 47(24):179-187.
- [3] 陈维兴,常东润,李宗帅.基于改进生成对抗网络与 ConvLSTM 的航空发动机剩余寿命预测方法[J]. *电子测量与仪器学报*, 2023, 37(3): 211-221.  
CHEN W X, CHANG D R, LI Z SH. Aircraft engine remaining life prediction method based on improved generative adversarial network and ConvLSTM[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(3): 211-221.
- [4] MITICI M, DE P I, BARROS A, et al. Dynamic predictive maintenance for multiple components using data-driven probabilistic RUL prognostics: The case of turbofan engines [J]. *Reliability Engineering & System Safety*, 2023, 234: 109199.
- [5] TURE B A, AKBULUT A, ZAIM A H, et al. Stacking-based ensemble learning for remaining useful life estimation[J]. *Soft Computing*, 2024, 28(2): 1337-1349.
- [6] 郭俊锋,刘国华,刘国伟.基于长序列的航空发动机剩余使用寿命预测方法[J]. *北京航空航天大学学报*, 2024, 50(3): 774-784.  
GUO J F, LIU G H, LIU G W. A remaining useful life prediction method for aircraft engines based on long sequences[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2024, 50(3): 774-784.
- [7] 吴嘉俊,苏春,张玉茹.基于双重自注意力机制和长短时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 J J, SU CH, ZHANG Y R. Residual life prediction based on dual self-attention mechanism and short-duration memory network [J]. *Systems Engineering and Electronics*, 2024, 46(6): 1986-1994.
- [8] LE X Q, ADHISANTOSO Y G, MUNDERLOH M, et al. Uncertainty-aware remaining useful life prediction for predictive maintenance using deep learning[J]. *Procedia CIRP*, 2023, 118: 116-121.
- [9] FU S, LIN L, WANG Y, et al. MCA-DTCN: A novel dual-task temporal convolutional network with multi-channel attention for first prediction time detection and remaining useful life prediction [J]. *Reliability Engineering & System Safety*, 2024, 241: 109696.
- [10] ALASWAD S, XIANG Y. A review on condition-based maintenance optimization models for stochastically deteriorating system [J]. *Reliability Engineering & System Safety*, 2017, 157:54-63.
- [11] DE P I, REIJNS A, MITICI M, et al. Alarm-based predictive maintenance scheduling for aircraft engines with imperfect remaining useful lifeprognostics[J]. *Reliability Engineering & System Safety*, 2022, 221: 108341.
- [12] LEE J, MITICI M. Deep reinforcement learning for predictive aircraft maintenance using probabilistic remaining-useful-life prognostics [J]. *Reliability Engineering & System Safety*, 2023, 230: 108908.
- [13] CHO K, MERRIENBOER V B, CAGLAR G, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. *ArXiv preprint ArXiv:1406.1078*, 2014.
- [14] XU D, QIU H, GAO L, et al. A novel dual-stream self-attention neural network for remaining useful life estimation of mechanical systems [J]. *Reliability Engineering & System Safety*, 2022, 222: 108444.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5998-6008.
- [16] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation [C]. *International Conference on Prognostics and Health Management*. IEEE, 2008: 1-9.

[17] 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.

[18] NGUYEN K T P, MEDJAHHER K. A new dynamic predictive maintenance framework using deep learning for failure prognostics [J]. Reliability Engineering & System Safety, 2019, 188: 251-262.

[19] CHEN CH, ZHU ZH H, SHI J T, et al. Dynamic

predictive maintenance scheduling using deep learning ensemble for system health prognostics [J]. IEEE Sensors Journal, 2021, 21(23): 26878-26891.

作者简介

董海,教授,硕士生导师,主要研究方向为网络化制造。

E-mail:donghaizhxh@163.com

吴越童(通信作者),硕士研究生,主要研究方向为装备可靠性。

E-mail:3186518830@qq.com