

DOI: 10.13382/j.jemi.B2205473

# 基于注意力机制和 CNN-BiLSTM 模型的 航空发动机剩余寿命预测

张加劲

(厦门大学航空航天学院 厦门 361005)

**摘要:**航空发动机作为飞机的主要动力源,其可靠性是保证飞机安全的关键。剩余使用寿命预测对于提高航空发动机的可用性和降低其寿命周期成本具有重要意义。针对现有的预测算法存在对航空发动机多维数据特征提取不足的问题,提出了一种基于注意力机制的卷积神经网络和双向长短期网络融合模型。首先,采用卷积神经网络提取特征和双向长短期记忆网络获取特征中的长短期依赖关系;其次,使用注意力机制来突出特征中的重要部分,提高模型预测的准确率。为验证所提出方法的有效性,在 C-MAPSS 数据集上进行了实验。实验表明,模型可以准确地预测出航空发动机的剩余使用寿命,并比传统方法有着更高的预测精度。

**关键词:**航空发动机;剩余寿命;卷积神经网络;注意力机制;双向长短期记忆网络

**中图分类号:** TN0; TH17 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Remaining useful life estimation of aeroengine based on CNN-BiLSTM and attention mechanism

Zhang Jiajing

(School of Aerospace Engineering, Xiamen University, Fujian 361005, China)

**Abstract:** As the main power source for aircrafts, the reliability of an aeroengine is critical for ensuring the safety of aircrafts. remaining useful life (RUL) prediction is of great importance for improving the availability of an aero engine and reducing its life cycle cost. For the problem of the shortcomings of existing estimation algorithms in the extraction of multi-dimensional data features, this paper proposes an attention-based CNN-BiLSTM model for RUL estimation. This model using CNN layers to extra feature and BiLSTM network can capture the short-term and long-term dependencies of the extracted feature. Afterwards, attention mechanism layer is used to highlight the important features in order to improve model performance. To evaluate the effectiveness of our approach, experiments are carried out on CMAPSS datasets and its result shows that the performance of the proposed approach is superior to other traditional approaches.

**Keywords:** aeroengine; remaining useful life; convolution neural network; attention mechanism; bidirectional long short-term memory network

## 0 引言

航空发动机内部结构复杂且工作环境非常恶劣,发动机内部零件会出现程度不一的退化。因此,航空发动机是日常航空维护作业中的重点关注对象之一。系统或设备的剩余使用寿命定义为当前时间到使用寿命结束的长度<sup>[1]</sup>。剩余寿命预测是故障检测与健康管理(prognostics and health management, PHM)中最为主要的任务之一。精确的剩余寿命预测可以提高航空发动机的

可用性和可靠性,在保障飞机安全健康地飞行的同时,尽可能减少因设备维修带来的维护成本,从而提高生产力和经济效益<sup>[2]</sup>。目前寿命预测方法主要分为基于物理模型的预测方法(physical model prognostics)和基于数据驱动的预测方法(data driven prognostics)。其中基于物理模型的预测方法需要采用代数方程和微分方程等数学描述来模拟系统的退化过程。然而,建立此类模型需要依据专家经验,且航空发动机复杂度高、部件之间相互影响大,使得建立精确的物理模型十分困难。近年来,随着传感器技术的进步,航空发动机监测数据的规模逐渐增大;

诸多学者投入到基于数据驱动的预测研究之中。如 Chen 等<sup>[3]</sup>提出改进的相似性支持向量机 (support vector machine, SVM) 方法和刘小峰等<sup>[4]</sup>提出基于灰色理论的多监测参量优化选择与融合及全阶时间幂灰色预测模型。相比于前者, 基于数据驱动的预测方法不需要大量的先验知识, 并且表现出较好的泛化能力, 在工业界得到不少的应用。

随着深度学习的兴起, 越来越多的学者将深度学习方法应用到航空发动机剩余寿命预测当中去。早期的学者采用传统的递归神经网络 (recurrent neural network, RNN) 对时间序列进行建模研究<sup>[5]</sup>。然而 RNN 存在长期依赖问题。针对于此缺陷, 长短期记忆网络 (long short-term memory, LSTM) 被提了出来, 不少学者将 LSTM 应用到航空发动机剩余寿命预测中<sup>[6-8]</sup>。Zhang 等<sup>[9]</sup>提出了一个多目标深度置信网络集成方法, 将演化算法与传统的深度置信网络 (deep brief network, DBN) 训练技术相结合, 在满足精度和多样性的前提下同时进化多个 DBN, 最后联合这些 DBN 进行剩余寿命预测。Babu 等<sup>[10]</sup>首次将卷积神经网络应用到航空发动机剩余寿命预测当中。Yu 等<sup>[11]</sup>提出了一种将卷积神经网络和长短期记忆网络融合的剩余寿命预测模型, 充分利用卷积神经网络提取空间特征和长短期记忆网络提取时间特征的优点。Bai 等<sup>[12]</sup>采用极限学习机模型完成航空发动机剩余寿命的预测。Benker 等<sup>[13]</sup>通过贝叶斯模型实现航空发动机剩余寿命预测。然而, 在处理航空发动机这样的多特征数据时, 以上的深度学习方法都没有有效的加权输入特征的机制。并不是所有特征都富含航空发动机退化信息, 一些对剩余寿命预测贡献不大的特征权重占比过大, 将会降低模型的预测精度。

注意力机制可以突出有限输入特征中的重要部分, 因此可以提高模型的预测准确率。Liang 等<sup>[14]</sup>在文本分类中应用了注意力机制, 取得了较好的结果。陈保家等<sup>[15]</sup>提出了一种基于 NLSTM 和注意力机制的模型用于 RUL, 与未融入注意力机制的模型相比, 该模型有效提高了预测精度。袁焯等<sup>[16]</sup>通过将生成对抗网络的生成能力与门控循环单元的预测能力结合, 提出一种基于特征注意力的 GAN 和 GRU 融合剩余寿命预测模型。但这些方法存在未能充分提取退化特征的问题, 在预测准确率上仍然有提升的空间。

针对以上存在的问题和挑战, 本文提出了一种基于注意力机制的卷积神经网络与双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM) 融合模型 (CNN-BiLSTM-AM)。卷积神经网络和双向长短期记忆网络可以有效地提取序列数据中的空间特征和时间特征。注意力机制可以给相应特征分配权重, 从而筛选出重要的特征, 提高模型的预测精度。本文首次将注意力

机制应用到航空发动机剩余寿命预测问题之中, 在 CMAPSS 数据集上进行的实验验证了该模型的有效性。

## 1 剩余寿命预测方法

本文提出的剩余寿命预测模型主要由 5 部分构成, 分别是卷积神经网络层、双向长短期记忆网络层、注意力机制层、全连接层和输出层, 其结构如图 1 所示。




图 1 本文模型结构

Fig. 1 Structure of propose method

### 1.1 卷积神经网络

卷积神经网络是一种具有特殊结构的前馈型神经网络, 主要包括卷积层、池化层。卷积层是其核心部分, 其通过滑动卷积核进行卷积运算来提取特征。卷积运算是卷积核  $w$  与感受野中的元素做点积, 在激活函数的作用下产生非线性映射, 从而达到提取特征的目的。若输入信号为:

$$\mathbf{X} = [x^1, x^2, \dots, x^j] \quad (1)$$

式中:  $j$  表示特征数量。

则卷积运算可以表示为:

$$z_i = \varphi(w * \mathbf{X} + b) \quad (2)$$

式中:  $\varphi$  为激活函数, 通常选取非线性函数;  $b$  为偏置量,  $*$  为卷积运算。

池化层利用池化函数来衡量数据信息的总体特征, 忽略不重要的细微特征。池化运算能够有效减少训练参数, 增强网络的鲁棒性。

### 1.2 长短期记忆网络与双向长短期记忆网络

#### 1) 长短期记忆网络

LSTM 网络是一种用于序列学习任务的 RNN 网络, 处理包括标准的循环层。通过引入了门限机制——“记忆”控制门, 来控制信息的累积速度, 避免了 RNN 网络存在的梯度爆炸和消失问题, 具体结构如图 2 所示。图 2 中, LSTM 网络标准模块分为两部分, 即长期状态  $c_t$  和短期状态  $h_t$ , 同时沿着状态路径添加 3 个控制门: 输入门、遗忘门、输出门, 对信息进行调节, 3 个控制门的作用说明如下。

输入门: 输入门的目的是控制在  $t$  时刻, 输入  $x_t$  以及先前短期状态  $h_{t-1}$  经过输入门限后保留在当前长期状态  $c_t$  中的信息成分。实现公式为:

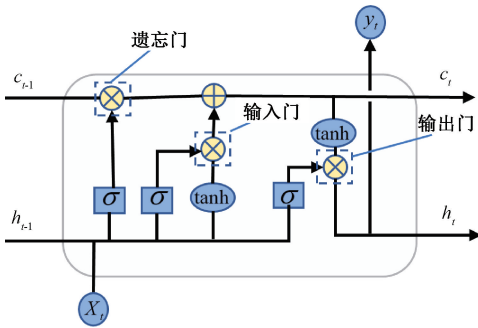


图 2 长短期记忆网络结构

Fig.2 Network structure of LSTM




图 3 双向长短期记忆网络结构

Fig.3 Network structure of BiLSTM

$$\begin{cases} i_t = \sigma(\mathbf{w}_{xi}^T x_t + \mathbf{w}_{hi}^T h_{t-1} + b_i) \\ \tilde{c}_t = \tanh(\mathbf{w}_{xc}^T x_t + \mathbf{w}_{hc}^T h_{t-1} + b_c) \end{cases} \quad (3)$$

式中:  $\sigma(\cdot)$  为 Sigmoid 函数。

遗忘门:遗忘门的目的是控制在  $t$  时刻, 先前长期状态  $c_{t-1}$  经过遗忘门后保留在当前长期状态  $c_t$  中的信息成分, 其的实现公式为:

$$f_t = \sigma(\mathbf{w}_{xf}^T x_t + \mathbf{w}_{hf}^T h_{t-1} + b_f) \quad (4)$$

输出门:输出门的目的是控制在  $t$  时刻, 当前长期状态  $c_t$  经过输出门后保留在当前短期状态  $h_t$  中的信息成分, 实现公式为:

$$\begin{cases} h_t = y_t = o_t \otimes \tanh(c_t) \\ c_t = i_t \otimes \tilde{c}_t + f_t \otimes c_{t-1} \\ o_t = \sigma(\mathbf{w}_{xo}^T x_t + \mathbf{w}_{ho}^T h_{t-1} + b_o) \end{cases} \quad (5)$$

式中:  $\otimes$  表示两个向量按元素相乘。模型构建完成后利用时间反向传播算法对 LSTM 网络模型进行训练, 得到优化参数。

## 2) 双向长短期记忆网络

BiLSTM 模型是 LSTM 模型的一个变体, 由一个前向 LSTM 模型和一个后向 LSTM 模型构成。LSTM 模型只能在一个方向上处理时间序列数据, 而 BiLSTM 模型增加了一个反方向的 LSTM 模型, 因此 BiLSTM 模型可以获取 LSTM 模型忽略的过去信息。其结构如图 3 所示。

## 1.3 注意力机制

在人类视觉观察中, 视觉系统可以筛选出有用的信息并忽略不相关信息, 这种行为称为人脑注意力。受到此启发, 专家们提出了注意力机制。注意力机制根据输入的特征对输出的影响对其分配不同的权重, 从而筛选出重要的特征, 提高模型的预测精度。具体原理如图 4 所示。

若双向长短期记忆网络层的输出为:

$$h_t = \{h_1, h_2, \dots, h_r\} \quad (6)$$

注意力机制的主要公式如下:

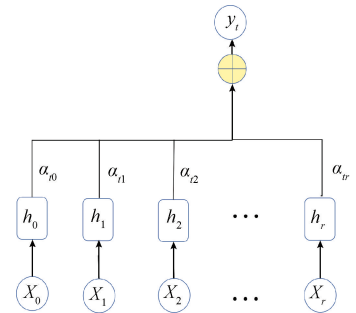


图 4 注意力机制结构

Fig.4 Network structure of attention mechanism

$$e_t = u \tanh(w h_t + b) \quad (7)$$

$$\alpha_t = \frac{\exp(e_t)}{\sum_{j=1}^r e_j} \quad (8)$$

式中:  $e_t$  为  $t$  时刻的注意力分布值,  $u, w$  表示权重,  $b$  为偏置,  $\alpha_t$  为 BiLSTM 层输出各特征的不同权重值。

## 1.4 剩余寿命预测方法

为了充分发挥 CNN 和 BiLSTM 有效提取空间和时间特征的能力, 本文提出了一种基于注意力机制的卷积神经网络与双向长短期记忆网络融合模型 (CNN-BiLSTM-AM)。CNN-BiLSTM-AM 的层级结构如表 1 所示, N/A 表示无该数据, 主要由 5 个部分组成。更多神经网络层的层数可能会更好地拟合数据, 但是也会导致模型过拟合问题和计算时间的增加。经过多次实验, 卷积神经网络层包含 3 层, 其中第 1、3 层为卷积层, 每层卷积层均包含 10 个卷积核, 第 2 层为最大池化层。若航空发动机传感器的一次采样数据为:  $x_i$ , 则长度为  $a$  的感受区域矩阵为:

$$X_i = [x_i, x_{i+1}, \dots, x_{i+a}]^T \quad (9)$$

$X_i$  为输入到 CNN-BiLSTM-AM 的一个样本, 其大小设置为  $30 \times 14$ , 其中 30 是时间长度, 14 是选择的特征数量, 具体阐述将在 3.2 节中讲到。利用卷积层多个卷积核提取发动机中隐藏的特征, 再通过最大池化层放大这些特征。若卷积神经网络层在  $t$  时刻的运算为:

$$g_i = conv(X_i) \tag{10}$$

得到主要特征后传输给 BiLSTM 层。BiLSTM 层的层数设置为 1 层, 含有 16 个神经元。BiLSTM 层对卷积神经网络层的输出  $g_i$  从两个方向上提取时间特征, 可表示为:

$$\begin{cases} \vec{h}_i = \overrightarrow{lstm}(g_i) \\ \overleftarrow{h}_i = \overleftarrow{lstm}(g_i) \end{cases} \tag{11}$$

则 BiLSTM 层在  $t$  时刻的输出为:

$$h_i = (\vec{h}_i \oplus \overleftarrow{h}_i) \tag{12}$$

BiLSTM 层后加入了注意力机制层进行优化。因为不同的特征对于剩余寿命预测的贡献程度不同, 增大重要特征对 RUL 预测的权重, 以提高模型预测精度。则  $t$  时刻注意力机制层的输出为:

$$S_i = \sum_{j=1}^i \alpha_j h_j \tag{13}$$

式中:  $\alpha_j$  为式(8)的计算结果。

注意力机制层后使用平滑层展开, 再用全连接层对预测结果作映射输出, 得到最终的剩余使用寿命预测结果。

表 1 模型结构及参数设置

Table 1 parameter settings of proposed method

网络层	层参数
卷积层 1	单元数 10, 卷积核尺寸 (10, 1)
最大池化层	N/A
卷积层 2	单元数 10, 卷积核尺寸 (10, 1)
BiLSTM 层 1	单元数 16
Attention 层	N/A
Flatten 层	N/A
Dense 层 1	单元数 50, 激活函数 tanh
输出层	单元数 1, 激活函数 tanh

CNN-BiLSTM-AM 的算法流程如图 5 所示。剩余寿命预测流程主要分为 3 个阶段, 分别是数据预处理、模型训练和模型测试阶段。首先在数据预处理阶段, 将数据集进行归一化处理, 设置剩余使用寿命标签。剩余寿命预测属于时间序列问题, 其数据是一维形式的; 而 CNN 的输入通常要求是二维数据, 如 RGB 三通道图像。因此本文将航空发动机退化数据转换为二维形式。将数据集都经过时间窗口的划分后, 采集的一维数据转换为二维数据, 在模型训练阶段, 将训练集输入到 CNN-BiLSTM-AM 中进行训练, 为防止模型过拟合, 采取了随机丢失策略 (Dropout), 模型经过多次迭代训练, 根据损失函数更新网络中的权重, 得到训练好的模型。在测试阶段, 将处理过后的测试集输入到训练好的模型, 得到航空发动机剩余寿命预测结果。

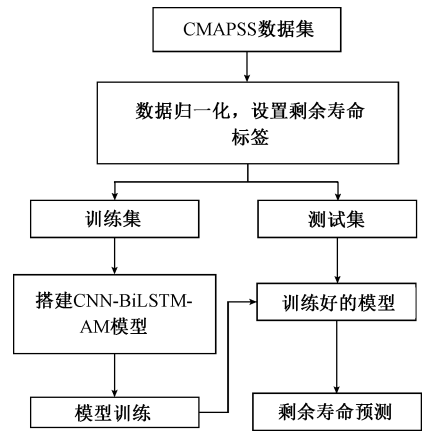


图 5 本文模型流程

Fig. 5 Flow chart of proposed method

## 2 实验验证

为了验证所提出模型对航空发动机剩余寿命预测的有效性和精确性, 在 CMAPSS 数据集进行了实验。本文的算法是在 Anacond3 和 Python3. 8. 8 上运行的。计算设备是 Intel Core i5-9400U ( 2. 9GHz ) CPU, 8 GB RAM 计算机。

### 2.1 实验数据

C-MAPSS 数据集是由 NASA 发布的民用模块化航空推进系统仿真软件模拟涡扇发动机的退化过程得到。

考虑到不同的操作条件和故障模式, CMAPSS 数据集共有 4 个子集, 如表 2 所示。每个子数据集进一步划分为训练集和测试集。训练集和测试集都来自不同的涡扇发动机, 且从不同的初始磨损状态开始记录。训练集中包含了发动机从运行到故障的完整信息; 而测试集中的数据则在观察到故障之前的某个时间终止, 此实验的目标便是预测测试集中每个发动机的剩余使用寿命。4 个数据集中, FD001 和 FD003 是在一种故障模式和一种工况运行条件下得到的, 而 FD002 和 FD004 则是在两周故障模式和 6 种不同工况运行条件下获得的数据。数据集都是包含 26 种信息的时间序列数据, 分别为发动机的编号、发动机运行时间、3 个操作参数和 21 个传感器的监测值。

表 2 CMAPSS 数据集介绍

Table 2 Description of CMAPSS dataset

数据集	FD001	FD002	FD003	FD004
训练集	100	260	100	249
测试集	100	259	100	248
故障模式种类	1	1	2	2
工况	1	6	1	6

### 2.2 数据预处理

尽管 CMAPSS 数据集有 21 种传感器返回的监测数据,但并不是所有数据都包含可用于剩余寿命预测的特征信息,例如 FD001 训练集中 1、5、6 等几列信息都是不变的。参考 LIM<sup>[17]</sup> 等的做法,选取 14 列富含健康退化信息的传感器信号,序号分别为 2、3、4、7、8、9、11、12、13、14、15、17、20 和 21。

由于发动机的多个传感器返回的监测数据的量纲不同,采用线性函数(max-min normalization)对数据进行归一化处理。

数据归一化处理将原始数据限定在 [0,1] 范围内,具体公式为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x} \quad (14)$$

式中:  $x'$  表示归一化后的数据,  $x$  是原始数据,  $x_{\min}$ ,  $x_{\max}$  分别代表原始数据中的最小值和最大值。

训练集中的数据只有从初始状态一直到出现故障所运行的周期,所以需要给训练集中的航空发动机添加剩余使用寿命标签。Wu 等<sup>[18]</sup> 选择添加线性下降的标签,认为航空发动机的性能退化随着时间线性发展。但是在实际情况中,航空发动机在早期阶段的零部件性能仍然是良好的,其性能退化问题可以忽略不记。因此,在航空发动机早期阶段就对其进行剩余使用寿命预测是不必要的,在这阶段可以把剩余使用寿命设定为一恒定值。本文将早期阶段的航空发动机剩余寿命标签阈值设为 125,在运行一段时间后可将剩余使用寿命设定为线性下降状态,如图 6 所示。为了便于研究,本文选取 FD001 和 FD003 数据集进行验证。




图 6 分段剩余寿命标签

Fig. 6 Piece-wise RUL labeling

### 2.3 性能评价指标

本文采用均方根误差(RMSE)和评分函数(Score)对剩余使用寿命的预测性能做评价。在剩余寿命预测领域,性能评价指标最重要的一点便是反映模型超前或滞后预测的程度<sup>[19]</sup>。超前预测是预测寿命小于真实寿命,使得航空发动机提前退役,经济效益没有达到最佳。而

滞后预测是预测寿命大于真实寿命,若航空发动机继续使用则存在极大的安全隐患。如果预测的误差越小,Score 和 RMSE 的值均会越小。但两个指标的惩罚机制不一样, RMSE 在超前预测和滞后预测的惩罚是一样的; Score 对滞后预测的惩罚更大。其定义分别如下式所示:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (15)$$

$$Score = \sum_{i=1}^n s_i \quad (16)$$

$$s_i = \begin{cases} e^{\frac{y_i - \bar{y}_i}{10}} - 1, & \bar{y}_i > y_i \\ e^{\frac{\bar{y}_i - y_i}{13}} - 1, & \bar{y}_i < y_i \end{cases} \quad (17)$$

式中:  $n$  表示预测样本的总数,  $\bar{y}_i$  是发动机剩余寿命的预测值,  $y_i$  是发动机剩余寿命的真实值。

### 2.4 预测结果与分析

采用 FD001 和 FD003 测试集进行实验验证,并与文献[8]、[11]、[15]、[18]和[20]所提方法的预测结果比较, RMSE 结果如表 3 所示, Score 结果如表 4 所示。由表 3 和 4 可得本文所提方法在两个子集上的 RMSE 值和 Score 值均小于文献[8]、[11]、[18]和[20],相比于其最优结果,本文所提方法的 RMSE 值分别降低 4.75% 和 0.395%、Score 值分别降低 5.24% 和 21.94%。与同样使用了注意力机制的文献[15]对比,其在 FD003 的 RMSE 值要小于本文方法,但在 FD001 数据集上本文方法则表现更好;在 Score 评价指标上,本文方法在两个数据集上分别比文献[15]的结果提高 18.88% 和 10.94%。相比于传统的卷积神经网络、LSTM 网络或自编码器方法,使用注意力机制的模型有着更好的预测精度。同时,本文所提方法采取的 CNN-BiLSTM 架构的网络具有强大的航空发动机退化特征提取和数据处理能力,预测精度更高。

表 3 不同剩余寿命方法 RMSE 结果对比

Table 3 Comparison of the RMSE results of different methods

方法	FD001	FD003
Deep LSTM <sup>[8]</sup>	16.14	16.18
CNN-LSTM <sup>[11]</sup>	14.41	14.36
Nested-LSTM-attention <sup>[15]</sup>	12.50	11.94
Auto-Encoder <sup>[18]</sup>	13.58	19.16
DCNN <sup>[20]</sup>	12.61	12.64
Proposed Method	12.01	12.49
Proposed method without attention	12.35	13.23

表 4 不同剩余寿命方法 Score 结果对比

Table 4 Comparison of the Score results of different methods

方法	FD001	FD003
Deep LSTM <sup>[8]</sup>	338	852
CNN-LSTM <sup>[11]</sup>	228	321
Nested-LSTM-attention <sup>[15]</sup>	257	249
Auto-Encoder <sup>[18]</sup>	220	1727
DCNN <sup>[20]</sup>	273.1	284.1
Proposed Method	208.47	221.75
Proposed method without attention	278.55	244.4

另外,本文做了控制变量实验来探索注意力机制的作用。相比没有注意力机制的模型,有注意力机制的模

型的 RMSE 和 Score 相比未应用注意力机制的模型分别下降了 2.75% 和 5.59%、25.15% 和 9.26%,充分说明了注意力机制的能够突出富含退化信息特征的作用。

从 FD001 测试集中选取 24、34、52 和 100 号测试样本,得到的预测结果如图 7 所示。可以注意到,在 4 个测试样本的早期阶段,所提出方法的预测值接近设定的常数阈值。随后,预测值可近似认为随着时间线性下降,直到可用测试样本结束。尽管在某些时间节点预测值与实际的剩余寿命值之间存在较大的误差,但当发动机接近退役时,预测值的准确率是较高的,具备一定的工业价值。因为航空发动机服役期间的后期阶段对于健康管理至关重要,该时期对发动机状态的良好评估可以提高运行的可靠性和安全性,降低维护成本。

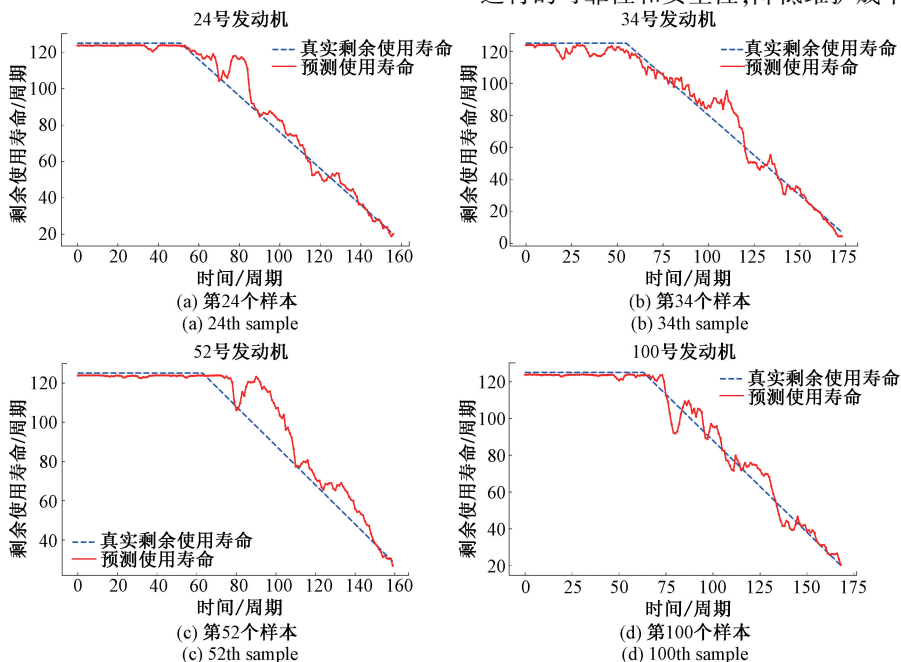


图 7 FD001 数据集中 4 个发动机剩余寿命预测结果

Fig. 7 Four example of life-time RUL predictions for testing engine units in FD001

### 3 结 论

本文提出了一种基于注意力机制的卷积神经网络和双向长短期记忆网络的融合模型用于航空发动机剩余寿命预测。卷积神经网络和双向长短期记忆网络能够有效地提取数据中的空间特征和时间特征,注意力机制能动态加权不同的输入特征,从而突出重要的特征,提高 RUL 预测精度。通过实验验证了本文所提方法的有效性,可以很好地预测航空发动机的剩余寿命,尤其是接近故障的后期。

### 参 考 文 献

[ 1 ] SI X S, WANG W, HU C H, et al. Remaining useful life estimation-a review on the statistical data driven approaches [ J ]. European Journal of Operational Research, 2011, 213(1) : 1-14.

[ 2 ] 金晓航, 李建华, 孙毅. 基于二元维纳过程的轴承剩余寿命预测[J]. 仪器仪表学报, 2018, 39(6) :89-95. JIN X H, LI J H, SUN Y. Bearing remaining useful life prediction based on two-dimensional wiener process[J]. Chinese Journal of Scientific Instrument, 2018, 39(6) : 89-95.

[ 3 ] CHEN Z, CAO S, MAO Z. Remaining useful life estimation of aircraft engines using a modified similarity

- and supporting vector machine (SVM) approach [J]. *Energies*, 2017, 11(1): 28.
- [4] 刘小峰, 叶榕婷, 柏林, 等. 基于灰色理论的航空发动机剩余寿命预测 [J]. *电子测量与仪器学报*, 2021, 35(1): 74-81.  
LIU X F, YE R T, BAI L, et al. Remaining useful life estimation for aero-engines based on grey theory [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(1): 74-81.
- [5] MALHI A, YAN R, GAO R X. Prognosis of defect propagation based on recurrent neural networks [J]. *IEEE Transactions on Instrumentation and Measurement*, 2011, 60(3): 703-711.
- [6] WU Y, YUAN M, DONG S, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks [J]. *Neurocomputing*, 2018, 275: 167-179.
- [7] CHENG Y, WU J, ZHU H, et al. Remaining useful life prognosis based on ensemble long short-term memory neural network [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 70: 1-12.
- [8] ZHENG S, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation [C]. 2017 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2017: 88-95.
- [9] ZHANG C, LIM P, QIN A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 28(10): 2306-2318.
- [10] BABU G S, ZHAO P, LI X L. Deep convolutional neural network based regression approach for estimation of remaining useful life [C]. *International Conference on Database Systems for Advanced Applications*. Springer, Cham, 2016: 214-228.
- [11] YU S, WU Z, ZHU X, et al. A domain adaptive convolutional LSTM model for prognostic remaining useful life estimation under variant conditions [C]. 2019 Prognostics and System Health Management Conference (PHM-Paris). IEEE, 2019: 130-137.
- [12] BAI J M, ZHAO G S, RONG H J. Novel direct remaining useful life estimation of aero-engines with randomly assigned hidden nodes [J]. *Neural Computing and Applications*, 2020, 32(18): 14347-14358.
- [13] BENKER M, FURTNER L, SEMM T, et al. Utilizing uncertainty information in remaining useful life estimation via Bayesian neural networks and Hamiltonian Monte Carlo [J]. *Journal of Manufacturing Systems*, 2021, 61: 799-807.
- [14] LIANG Q, WU P, HUANG C. An efficient method for text classification task [C]. *Proceedings of the 2019 International Conference on Big Data Engineering*, 2019: 92-97.
- [15] 陈保家, 郭凯敏, 陈法法, 等. 基于残差 Nested-LSTM 和注意力机制的航空发动机剩余寿命预测 [J/OL]. *航空动力学报*: 1-10 [2022-07-27]. DOI: 10.13224/j.cnki.jasp.20210728.  
CHEN B J, GUO K M, CHEN F F, et al. Prediction of remaining useful life of aero-engine based on residual Nested-LSTM and attention mechanism [J/OL]. *Journal of Aerospace Power*, 2022: 1-10 [2022-07-27]. DOI: 10.13224/j.cnki.jasp.20210728.
- [16] 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: 198-212.  
YUAN Y, HUANG H, CHENG CH, et al. Remaining useful life prediction of the aircraft engine on the GRU-GAN network with a feature attention mechanism [J]. *Scientia Sinica Technologica*, 2022, 52: 198-212.
- [17] LIM P, GOH C K, TAN K C, et al. Estimation of remaining useful life based on switching Kalman filter neural network ensemble [C]. *Annual Conference of the PHM Society*. 2014.
- [18] YU W N, KIM Y I I, MECHEFSKE C. An improved similarity-based prognostic algorithm for RUL estimation using an RNN autoencoder scheme [J]. *Reliability Engineering & System Safety*, 2020, 199: 106926.
- [19] WU Q, DING K, HUANG B. Approach for fault prognosis using recurrent neural network [J]. *Journal of Intelligent Manufacturing*, 2020, 31(7): 1621-1633.
- [20] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. *Reliability Engineering & System Safety*, 2018, 172(APR.): 1-11.

## 作者简介



张加劲(通信作者), 2019年于广州大学获得学士学位, 现为厦门大学航空航天学院自动化系硕士研究生, 主要研究方向为航空发动机建模、故障诊断和剩余寿命预测。  
E-mail: zhangjiajing00@163.com

**Zhang Jiajing** (Corresponding author) received his B. Sc. degree from Guangzhou University in 2019. Now he is a M. Sc. candidate in Department of Automation, Xiamen University. His main research interests include aeroengine modeling, fault diagnosis and remaining useful life estimation.