

基于多特征融合的航空发动机剩余寿命预测^①



张晓东, 秦子轩, 李敏, 史靖文

(中国石油大学(华东) 计算机科学与技术学院, 青岛 266580)
通信作者: 秦子轩, E-mail: spello1998@s.upc.edu.cn

摘要: 针对航空发动机剩余可用寿命 (*RUL*) 预测任务中代表性特征提取不充分导致 *RUL* 预测精度较低等问题, 提出了一种基于多特征融合的航空发动机 *RUL* 预测方法. 利用指数平滑法 (ES) 降低原始数据中的噪声干扰, 得到相对平稳的特征数据. 使用双向长短期记忆网络 (Bi-LSTM) 提取特征数据的时序特征, 利用多头注意力机制 (Multi-attention) 为时序特征赋予权重; 设计卷积长短期记忆网络 (Conv-LSTM) 提取特征数据的时空特征; 提取特征数据的手工特征并使用 *Softmax* 函数计算权重. 设计一个特征融合框架将上述特征进行融合, 然后通过全连接网络回归实现最终 *RUL* 预测. 使用 C-MAPSS 数据集对模型进行仿真验证, 与 Bi-LSTM 等模型进行对比, 模型 *RUL* 预测精度更高, 适应性更好.

关键词: 指数平滑法; 卷积长短期记忆网络; 双向长短期记忆网络; 多头注意力机制; 特征融合; 深度学习

引用格式: 张晓东, 秦子轩, 李敏, 史靖文. 基于多特征融合的航空发动机剩余寿命预测. 计算机系统应用, 2023, 32(3): 95-103. <http://www.c-s-a.org.cn/1003-3254/8958.html>

Remaining Useful Life Prediction of Aeroengine Based on Multi-feature Fusion

ZHANG Xiao-Dong, QIN Zi-Xuan, LI Min, SHI Jing-Wen

(School of Computer Science and Technology, China University of Petroleum, Qingdao 266580, China)

Abstract: To solve the problems of low prediction accuracy in aeroengine remaining useful life (*RUL*) prediction due to insufficient representative feature extraction, this study proposes an *RUL* prediction method based on multi-feature fusion for aeroengines. Exponential smoothing (ES) is performed to reduce the interference noise in the original data and thereby obtain relatively stable feature data. The time series features of the feature data are extracted by the bidirectional long short-term memory (Bi-LSTM) network and then assigned weights through the multi-head attention mechanism (Multi-attention). A convolutional long short-term memory (Conv-LSTM) network is designed to extract the spatio-temporal features of the feature data. Then, the handcrafted features of the feature data are extracted, and weights are calculated from the *Softmax* functions. A feature fusion framework is designed to fuse the above features, and *RUL* prediction is finally achieved by fully connected network regression. The commercial modular aero-propulsion system simulation (C-MAPSS) dataset is used to simulate and verify the proposed model. Compared with Bi-LSTM and other models, the proposed model achieves higher prediction accuracy and better adaptability.

Key words: exponential smoothing (ES); convolutional long short-term memory (Conv-LSTM); bidirectional long short-term memory (Bi-LSTM); multi-head attention mechanism; feature fusion; deep learning

剩余可用寿命能够显示航空发动机未来的健康状态趋势, 提高操作的可靠性和安全性. 准确的 *RUL* 预

测对航空发动机的预防性维修有重要指导作用, 可以保证发动机的良好工作条件, 降低故障发生的概率和

① 基金项目: 国家自然科学基金 (61801517); 中央高校基本科研业务专项 (19CX02029A, 19CX02027A)
收稿时间: 2022-07-21; 修改时间: 2022-08-18; 采用时间: 2022-09-01; csa 在线出版时间: 2022-10-28
CNKI 网络首发时间: 2022-11-11

发动机维护成本^[1,2]。RUL 预测方法,一般可以分为基于模型和数据驱动两类^[3]。基于模型的解决方案,要求建立一个精确的航空发动机系统模型,但是随着工业科技的不断发展,航空发动机越来越精密,系统内部之间的相互联系也越来越复杂,这一解决方案难以实现。数据驱动的解决方案,不需要了解发动机的内部构造和系统之间的相互作用,只需将各类传感器数据作为数据驱动算法的输入,算法自动学习具有代表性的显著特征,用于最后的 RUL 预测^[4,5]。

数据驱动方法中,深度神经网络基于其强大的自动特征学习能力和推理分析能力,在 RUL 预测问题上展现出优异的性能。因此,基于深度神经网络的 RUL 预测方法受到越来越多学者的关注^[3]。Yang 等^[6]提出了基于双卷积神经网络(CNN)的智能 RUL 预测方法,双 CNN 分别用来识别初始故障点和进行 RUL 预测。Zhu 等^[7]提出多尺度卷积神经网络(MSCNN)进行 RUL 预测, MSCNN 可使全局和本地信息保持同步,自动学习有助于 RUL 预测的显著特征。Shao 等^[8]提出一种新型卷积深度信念网络(CDBN),先将数据压缩降维,然后使用 CDBN 网络来学习代表性特征用于最后的 RUL 预测。

上述文献中的前馈神经网络结构无法有效分析具有整体逻辑特征的时序输入,然而航空发动机的各类传感器数据具有时序性,RUL 预测是一个典型的时序问题。循环神经网络(RNN)在网络结构中添加自反馈神经,可以很好地处理时序输入。Aggarwal 等^[9]提出深度 Weibull 模型(DW-RNN)和多任务学习(MTL-RNN)。DW-RNN 来学习潜在的故障动力学,MTL-RNN 来学习底层分布。

RNN 在反向传播的过程中会出现梯度爆炸或消失等问题,很难处理长期依赖关系的时序输入。LSTM 引入细胞状态来存储长期记忆,可以很好地缓解梯度爆炸和消失的问题^[10]。Zheng 等^[11]提出一种用于估计的 LSTM 方法,性能明显优于传统的 RUL 估计方法以及 RNN。Miao 等^[12]设计了双任务深度 LSTM,用于联合学习航空发动机退化评估和剩余使用寿命预测。

Bi-LSTM 可以从数据中捕捉到更多代表性显著特征,得到更精确,更可靠的预测结果^[13]。车畅畅等^[1]建立一种基于一维卷积神经网络(1D-CNN)和 Bi-LSTM 的混合模型,1D-CNN 得到性能退化分析模型,Bi-

LSTM 进行 RUL 预测。牟含笑等^[14]提出基于 CDBN 与 Bi-LSTM 的剩余寿命预测方法,CDBN 提取反应隐含深层次特征的健康指标,Bi-LSTM 挖掘时序特征(TF)和退化趋势,进行 RUL 预测。但是上述深度神经网络都将重点放在最后一个时间步长得到的学习特征,学习特征的利用率较低,而且每个时间步长得到的学习特征对 RUL 预测有着不同的贡献。同时一些手工特征(HF)和空间特征(SF)也可以为 RUL 预测提供额外信息,提高模型预测精度。

综上所述,本文建立了一种基于多特征融合的航空发动机 RUL 预测模型。模型使用 Bi-LSTM 从特征数据中提取时序特征,再采用 Multi-attention 为时序特征分配权重,捕获时序特征相互关联信息的多重特征,充分利用模型构建中学习到的特征,提高学习特征的利用率。设计 Conv-LSTM 模块将输入数据的简单特征通过卷积映射到更复杂的高维模式,挖掘输入数据深层次非线性的时空特征。提取特征数据的手工特征,并使用 Softmax 函数分配权重,为 RUL 预测提供不同程度额外信息。构建一个特征融合框架将时空特征,时序特征和手工特征进行融合用于最终 RUL 预测。

1 RUL 预测模型

1.1 模型总体结构

基于多特征融合的航空发动机 RUL 预测模型如图 1 所示。

如图 1 所示,首先利用指数平滑法为原始数据降噪,得到稳定性较高的特征数据。然后通过滑动窗口方法将特征数据分割为输入时间窗时间序列。提取各个时间窗的手工特征,并使用 Softmax 函数为同一时间窗口下的手工特征赋予不同的权重;设计 Conv-LSTM 提取每个时间窗的时空特征;双层 Bi-LSTM 自动学习输入时间窗时间序列的时序特征,学习到的时序特征序列作为 Multi-attention 的输入,Multi-attention 为每个时序特征分配权重。上述 3 种特征经过全连接网络获取抽象特征后,通过特征融合框架实现融合。最后融合特征作为全连接网络的输入,通过全连接网络回归实现航空发动机 RUL 预测。

1.2 Bi-LSTM 时序特征提取

航空发动机传感器数据属于时序数据,因此利用航空发动机传感器数据进行 RUL 预测可以看作是时序数据预测问题。Bi-LSTM 基于整个时间序列学习时

序数据之间的双向长期依赖关系,可以提取更加具有代表性的时序特征,有利于提高 *RUL* 预测精度^[2,14],所以本文采用 Bi-LSTM 进行时序特征提取。

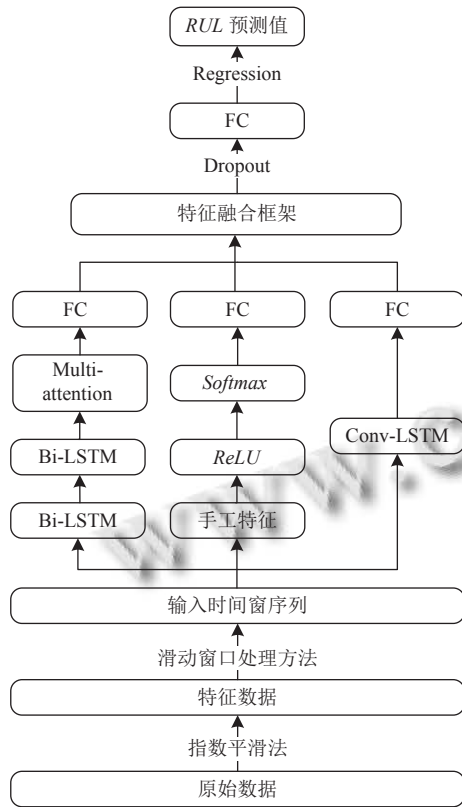


图1 *RUL* 预测模型总体结构图

Bi-LSTM 内部节点与 LSTM 相同,均由遗忘门,输入门,输出门 3 个门结构和一个用来存储长期记忆的细胞状态构成。遗忘门 f_t 决定前一时间刻细胞状态 C_{t-1} 中信息的保留或丢弃。输入门 i_t 决定当前时刻输入 x_t 和前一时间刻隐藏输出 h_{t-1} 中的哪些信息可以被记录到细胞状态中。遗忘门和输入门共同决定细胞状态 C_t 的更新。输出门 o_t 决定当前隐藏状态的输出 h_t ^[2]。数学表达式如下^[1,15]:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

其中, f_t, i_t, o_t 是一个 0-1 之间的数值, σ 代表 Sigmoid

函数, \tilde{C}_t 为新的状态候选向量, \tanh 代表 \tanh 函数。 W_f, W_i, W_c, W_o 为权重项。 b_f, b_i, b_c, b_o 为偏置项。

Bi-LSTM 是在正时间输入的 LSTM 网络结构上又添加了一个独立的负时间输入的 LSTM 网络层。时序信息以正时间输入到第 1 层 LSTM 中,得到当前时刻的时序信息 h_t^R , 以负时间输入第 2 层 LSTM 中,得到当前时刻的逆序信息 h_t^L 。将两个输出信息进行结合后形成当前时刻的隐藏输出 h_t 。所以当前时刻的输出就同时包括过去和未来的时序信息,是上下文相关的。Bi-LSTM 结构隐藏输出数学表达如下^[1,15]:

$$h_t^R = f^R(W_1 x_t + W_2 h_{t-1}^R) \quad (7)$$

$$h_t^L = f^L(W_3 x_t + W_4 h_{t+1}^L) \quad (8)$$

$$h_t = f(W_5 h_t^R + W_6 h_t^L) \quad (9)$$

1.3 Multi-attention 分配权重

Bi-LSTM 每个时间步长都会有一个学习特征。假设某个样本经过 Bi-LSTM 学习的特征表示为:

$$H = \{h_1, h_2, \dots, h_N\}^T \quad (10)$$

但是 Bi-LSTM 将重点放在最后一个时间步长上学习到的特征^[5], 存在对学习特征利用率较低的问题,而且每个时间步长的学习特征对神经网络最后的结果都有着不同的贡献。所以使用 Multi-attention 为 Bi-LSTM 各时间步长学习特征分配权重,然后再与 H 进行残差连接得到加权时序特征。充分利用每个时间步长的学习特征并解决权重矩阵退化问题,进而提高 *RUL* 预测精度。具体流程如图 2 所示。

图 2 中查询矩阵 Q , 键矩阵 K , 值矩阵 V 均为 H 的线性映射, n 为子空间个数。Scaled dot-product attention 是 Multi-attention 的重要组成部分,其数学表达式如下:

$$Attention(Q_-, K_-, V_-) = Softmax\left(\frac{Q_- K_-^T}{\sqrt{d_k}}\right) V_- \quad (11)$$

其中, Q_-, K_-, V_- 分别为 Q, K, V 的线性映射, K 的维度为 d_k 。

Multi-attention 将输入特征线性映射到多个不同的子空间,然后计算每个子空间的注意力分数,最后将这些注意力分数拼接到一起。这使得模型可以共同关注不同位置的不同表示子空间的信息^[16],数学表达式如下:

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_n)W$$

where $head_i = Attention(Q_- W_i^{Q_-}, K_- W_i^{K_-}, V_- W_i^{V_-})$ (12)

其中, $head_i$ 表示第 i 个子空间的注意力分数. W_i^{Q-} , W_i^{K-} , W_i^{V-} 分别为第 i 个子空间下 $Q-$, $K-$, $V-$ 的权重矩阵. W^o 为 n 个子空间计算结果拼接后对应的权重矩阵.

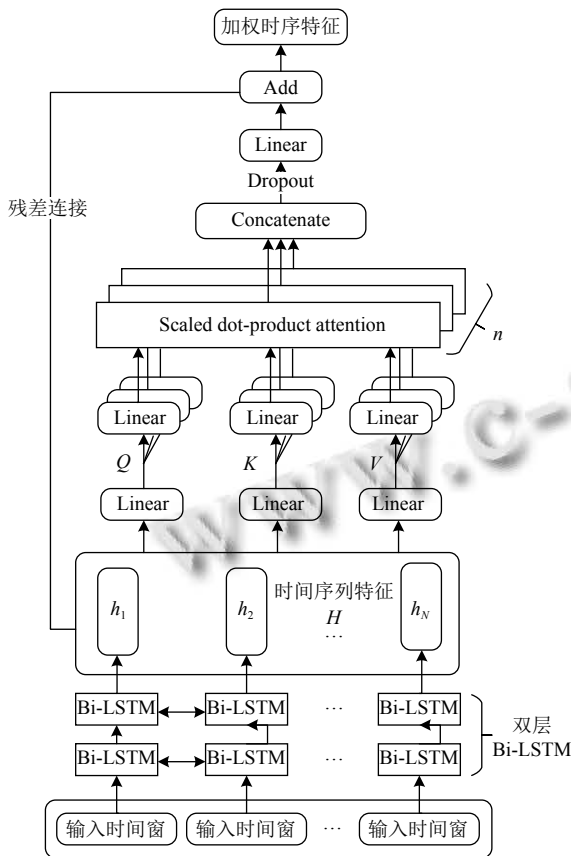


图2 Bi-LSTM 和 Multi-attention

1.4 提取手工特征

手工特征是一种根据领域知识人为设计的特征, 它的每一维度往往都具有一定的物理或数学含义, 具有很强的针对性和可解释性. 本文提取的手工特征包括均值特征和趋势系数特征, 均值表示传感器参数量级的大小, 趋势系数代表传感器参数未来的退化潜力. 手工特征能够为 RUL 预测提供一些额外的有意义的信息, 可以提高 RUL 预测精度^[3]. 如图1所示, 手工特征经过激活函数 $ReLU$ 后, 使用 $Softmax$ 函数计算相应权重, 然后内积合并得到加权手工特征, 最后经过一层全连接网络提取更加抽象的特征. 数学表达式如下:

$$y_h = x_h \otimes \text{Softmax}(\text{ReLU}(x_h)) \quad (13)$$

$$Y_h = W_h y_h + b_h \quad (14)$$

其中, y_h 为加权手工特征, x_h 为手工特征输入矩阵, \otimes 为矩阵内积操作. Y_h 为全连接网络输出, W_h 为权重矩阵,

b_h 为偏置项.

1.5 Conv-LSTM 提取时空特征

如图3所示. 本文设计的 $Conv-LSTM$ 模块主要由卷积神经网络和 $LSTM$ 网络组成. 卷积神经网络包含两个一维卷积层, $LSTM$ 网络包含一个 $LSTM$ 层. 卷积神经网络将输入数据映射到更复杂的高维模式进行空间特征提取, 提取到的空间特征作为 $LSTM$ 层的输入进一步提取时序特征, 两种特征经过全连接层获取抽象特征后, 通过 $concatenate$ 函数实现特征融合, 得到输入数据的时空特征. 不同于独立使用卷积神经网络和 $LSTM$ 网络分别提取空间特征和时序特征, $Conv-LSTM$ 整体处理输入信息, 更有效地捕获时空特征, 有利于提高 RUL 预测精度.

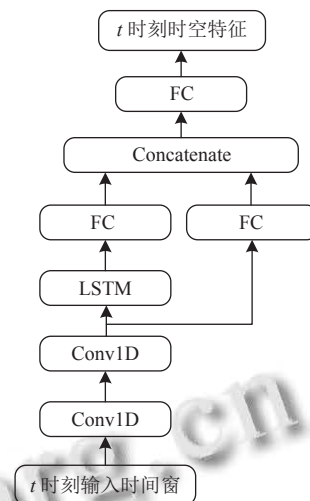


图3 Conv-LSTM 模块图

1.6 特征融合框架

本文构建的特征融合框架如图4所示. 加权时序特征和加权手工特征经过全连接网络获取抽象特征后通过 $concatenate$ 函数实现特征融合, 然后融合特征再经过一层全连接网络来获取抽象特征. 时空特征通过一层全连接网络获取抽象特征后, 使用 $concatenate$ 函数实现与时序特征和手工特征的融合.

2 实验及结果分析

2.1 数据集

模型使用由 NASA 提供的商用模块化航空推进系统仿真 (C-MAPSS) 数据集进行仿真验证. C-MAPSS 数据集模拟了航天发动机的退化过程, 被广泛用于以

往的 *RUL* 预测研究中^[1,3,12]. C-MAPSS 数据集由 4 个不同工作条件和故障模式下的子数据集组成, 每个子数据集又可以进一步分为训练集和测试集. 训练集记录了一定数量的航空发动机从正常到发生故障的全部飞行周期内的传感器状态参数. 测试集记录了一定数量的发动机在特定运行周期内的传感器状态参数, 测试集主要用于评估模型的 *RUL* 预测能力. C-MAPSS 数据集基本信息如表 1 所示.

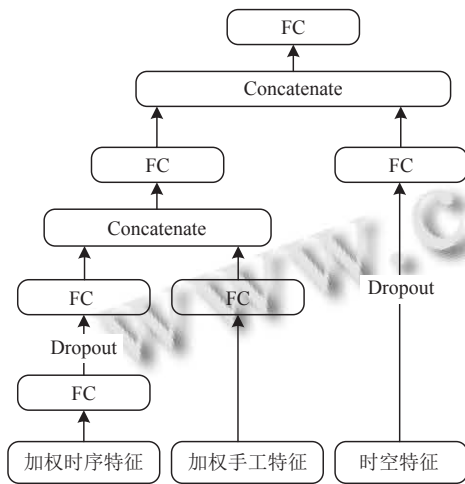


图 4 特征融合模块图

表 1 C-MAPSS 数据集基本信息

数据集	训练集	测试集	工作条件	故障模式
FD001	100	100	1	1
FD002	260	259	6	1
FD003	100	100	1	2
FD004	248	248	6	2

数据集中每条数据由发动机编号、当前飞行循环数、3 个操作条件和的 21 个传感器状态参数组成. 传感器状态参数包括低压压缩机进气道总温度、高压压缩机出口处总压力、物理风机转速、核心机物理转速、高压压缩机出口静压等各种航空发动机状态信息.

2.2 数据预处理

对于 21 个传感器状态参数, 传感器编号为 1, 5, 6, 10, 16, 18 和 19 在运行到故障的全过程中具有恒定的值, 这些传感器状态参数与发动机退化无关, 所以将这些传感器状态参数移除^[17]. 剩余的 14 个传感器状态参数稳定性差, 噪声多, 使用指数平滑法对其进行降噪. 指数平滑法数学表达式如下^[18]:

$$\alpha = \frac{2}{1+s} \quad (15)$$

$$\begin{cases} y_0 = x_0, & t = 0 \\ y_t = \frac{\sum_{i=0}^t (1-\alpha)^i x_{t-i}}{\sum_{i=0}^t (1-\alpha)^i}, & t > 0 \end{cases} \quad (16)$$

其中, α 为衰减因子, s 为范围跨度, y_t 为 t 时刻观测值, x_t 为 t 时刻真实值, y_{t-1} 为 $t-1$ 时刻观测值.

图 5 为指数平滑法效果图, 数据来源为 FD001 数据集中 1 号发动机的 9 号传感器前 70 次运行周期.




图 5 指数平滑法降噪效果图

由图 5 可知, 指数平滑法不仅可以保留原始数据的变化趋势, 还可以对原始数据进行降噪平滑处理, 是一种有效的时序数据降噪技术^[18].

各类传感器状态参数具有不同的量纲, 会影响到 *RUL* 预测结果, 为了提高模型的收敛速度和预测精度, 使用 *max-min* 归一化法对传感器状态参数进行归一化处理. 采用窗口大小为 30, 步长为 1 的滑动窗口方法对数据集进行数据分割得到输入时间窗序列^[3]. 然后为每个窗口添加 *RUL* 标签, 时间窗 *RUL* 标签定义为:

$$RUL_i^j = \min \{ m^j - m_i^j, 130 \} \quad (17)$$

其中, RUL_i^j 代表第 j 个发动机的第 i 个窗口的剩余可用寿命, m^j 代表第 j 个发动机的整个生命周期, m_i^j 代表第 j 个发动机的第 i 个窗口的最后一周期. 由于早期航空发动机退化并不明显, *RUL* 的最大值设置为 130^[3,18]. 计算每个窗口的手工特征并使用 *Softmax* 函数分配权重, 然后对其进行标准化处理.

2.3 评价指标和损失函数

本文采用两个常用的评价指标: 均方根误差 (*RMSE*)

和非对称评分函数 (Score) 来评估模型的性能. 均方根误差可很好地反映预测的精密程度. 数学表达式如下^[19,20]:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{r}_i - r_i)^2} \quad (18)$$

其中, N 为样本总个数, \hat{r}_i 为预测值, r_i 为真实值.

非对称评分函数是一个保守且安全的评价函数, 能够对早期预测和后期预测产生不同的惩罚结果. 如果预测 RUL 大于真实 RUL , 惩罚将更大, 因为这种情况会导致更严重的后果. 相反, 当预测 RUL 小于真实 RUL 时, 惩罚会更小. 数学表达式如下^[19,20]:

$$Score = \begin{cases} \sum_{i=1}^N (e^{-\frac{\hat{r}_i - r_i}{13}} - 1), & \text{if } \hat{r}_i - r_i < 0 \\ \sum_{i=1}^N (e^{\frac{\hat{r}_i - r_i}{10}} - 1), & \text{if } \hat{r}_i - r_i \geq 0 \end{cases} \quad (19)$$

本文采用的损失函数为 MSE , MSE 可以反映预测数据和真实数据之间的差异程度, 数学表达式如下:

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{r}_i - r_i)^2 \quad (20)$$

2.4 使用 FD001 数据集进行对照实验和消融实验

使用 FD001 数据集进行对照实验和消融实验, 训练集和测试集经过预处理后可以获得 17 731 个训练样本和 100 个测试样本.

本文模型通过提取特征数据的时序特征 (TF), 手工特征 (HF) 和时空特征 (TSF) 这 3 种特征来提高 RUL 预测精度. 不同的特征融合顺序对 RUL 预测结果有着不同的影响, 建立 4 种不同特征融合顺序模型进行对照实验, 实验结果如表 2 所示.

表 2 不同特征融合顺序模型实验结果

特征融合顺序	标准	第1次迭代	最优结果	迭代次数
先将TF和HF融合, 再与TSF融合	RMSE	17.98	12.38	8
	Score	453.77	235.52	
先将TF和TSF融合, 再与HF融合	RMSE	21.65	12.76	13
	Score	539.28	246.79	
先将TSF和HF融合, 再与TF融合	RMSE	15.49	13.20	3
	Score	318.27	249.90	
TF, HF和TSF一起 融合	RMSE	16.51	12.84	6
	Score	358.81	279.68	

由表 2 可知, 4 种不同特征融合顺序模型在第一次迭代时 $RMSE$ 值和 $Score$ 值差距较大, 但是最优结果差距相对较小. 对照实验 1 具有较高的 RUL 预测精度和较少的迭代次数, 所以将对照实验 1 的特征融合顺

序确定为本文模型特征融合顺序.

为了更好地评价 ES 降噪模块, Multi-attention 模块, Bi-LSTM 模块和 Conv-LSTM 模块的有效性, 对本文模型进行消融实验, 实验结果如表 3 所示.

表 3 消融实验结果

实验	RMSE	Score	迭代次数
去除ES降噪模块	12.52	228.63	23
去除Multi-attention模块	12.97	324.15	10
去除Bi-LSTM模块	12.59	227.37	18
去除Conv-LSTM模块	12.74	288.47	15
本文模型	12.38	235.32	8

由表 3 可知 5 种模型预测精度差距较小, 均有着较高的预测精度. 通过模型之间对比可知, ES 模块和 Bi-LSTM 模块可以显著减少模型构建所需的迭代次数, 提高了模型的收敛速度, 对提升模型预测精度具有积极意义. Multi-attention 模块有利于提升模型的预测精度, 但是对于减少模型构建所需迭代次数的效果并不明显. Conv-LSTM 模块不仅可以减少模型构建所需的迭代次数, 还可以提升模型预测精度.

使用 FD001 数据集对模型进行 30 次迭代训练, 模型训练过程中测试集 $RMSE$ 值和 $Score$ 值的变化情况如图 6 所示.

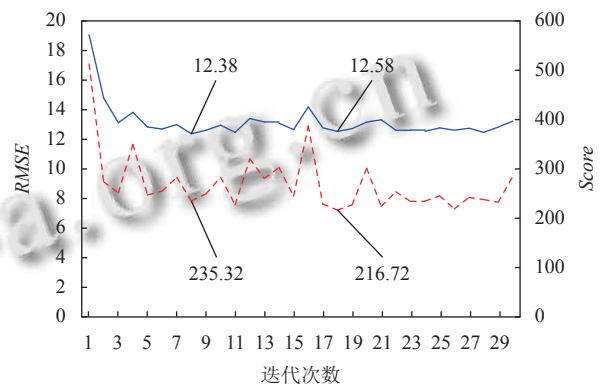


图 6 FD001 数据集训练损失和测试误差曲线图

由图 6 可知, 测试集 $RMSE$ 值在模型第 8 次迭代后获得最小值, 值为 12.38, 在之后的迭代过程中虽有波动, 但总体趋于平稳. 测试集 $Score$ 值在模型第 18 次迭代后获得最小值, 值为 216.72, 在之后的迭代过程中变化较为曲折.

2.5 参数设置

模型中 Conv-LSTM 模块和 Bi-LSTM 模块的具体结构和参数设置如表 4 所示. 表 4 中 K 和 N 分别代表卷积核的大小和个数.

表4 Conv-LSTM 模块和 Bi-LSTM 模块参数设置

模块	网络层名称	参数设置
Conv-LSTM模块	卷积层1	K: 3, N: 128
	激活函数1	ReLU
	卷积层2	K: 3, N: 128
	激活函数2	ReLU
	LSTM层	100
	Flatten层	卷积层2结果扁平化
	全连接层	10
	激活函数3	ReLU
	Flatten层	LSTM层结果扁平化
	全连接层	10
	激活函数4	ReLU
	特征融合层	20
	丢弃层	丢弃率: 0.1
	全连接层	10
Bi-LSTM模块	Bi-LSTM层1	100
	Bi-LSTM层2	100
	注意力层	Multi-attention
	Flatten层	注意力层结果扁平化
	全连接层	50
	激活函数	ReLU
	丢弃层	丢弃率: 0.2
	全连接层	10

模型中使用的 Multi-attention 模块主要超参数设置如表5所示。

3 实验结果

图7展示了该模型在 C-MAPSS 的4个子集上的

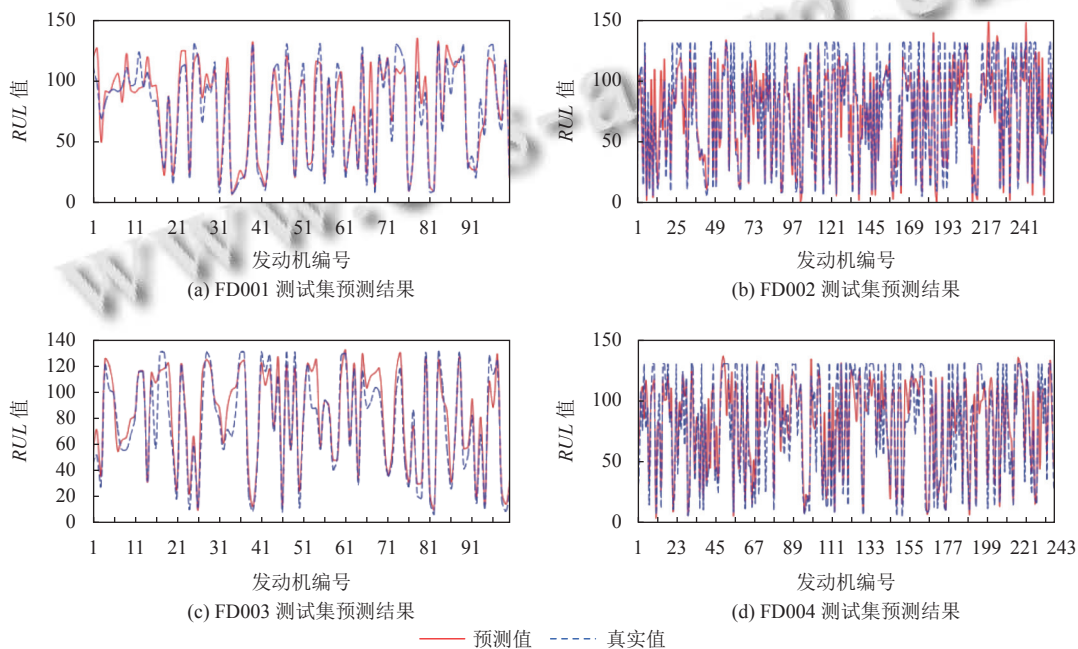


图7 C-MAPSS 各测试子集 RUL 预测结果对比图

RUL 预测结果对比. 如图7所示, 发动机 RUL 预测值分布在真实值附近, 预测精度较高. 尤其在 RUL 真实值较小的点, 预测值与真实值更加贴近, 差距更小. 这意味着当发动机临近故障时, 该模型能够更加充分的提取故障特征, 可以更准确捕捉到提前预测的相关特征, 具有较强的预测能力和较高的可行性.

表5 Multi-attention 主要超参数设置

参数	值	参数含义
numHeads	5	Multi-attention子空间个数
numUnits	200	隐藏层神经元数量
Dropout	0.1	丢弃率

对该模型进行 10 次实验, 获得 RMSE 和 Score 的平均实验结果, 然后与其他模型进行比较, 对比结果如表6所示. 由表6可知, 在 FD001, FD002 和 FD004 三个数据集中, 本文模型的 RMSE 和 Score 均要优于所有对比模型. 在 FD002 和 FD004 数据集上 RMSE 和 Score 有着显著降低, 这表明本文模型在复杂环境下仍然可以精确预测航空发动机 RUL, 模型适应性更好. 在 FD003 子集中 RMSE 略差于 MODBNE, Score 差于 Bi-LSTM, 但是模型仍表现出较高预测精度. 该模型通过对原始数据降噪平滑处理和引入 Multi-attention 提高学习特征的利用率, 减少了模型构建所需迭代次数, 缩短了模型训练时间, 得到误差较低, 精度较高的预测结果. 表明该方法能自适应学习航空发动机退化序列的特点, 提高航空发动机 RUL 预测准确性.

表6 RUL预测中不同算法的性能比较

模型	标准	FD001	FD002	FD003	FD004
RF+LSTM ^[21]	RMSE Score	17.51 —	25.32 —	19.66 —	30.40 —
LSTM ^[11]	RMSE Score	15.42 410.60	24.49 4450	16.18 852	28.17 5550
DBN ^[18]	RMSE Score	15.21 417.59	27.12 9031.64	14.71 442.43	29.88 7954.51
MODBNE ^[18]	RMSE Score	15.04 334.23	25.05 5585.34	12.51 421.91	28.66 6557.62
LSTM+ Attention ^[3]	RMSE Score	14.53 322.44	— —	— —	27.08 5649.14
Bi-LSTM ^[22]	RMSE Score	13.65 295	23.18 4130	12.74 317	24.86 5430
本文模型	RMSE Score	12.42 254.93	17.35 1554.08	12.62 347.58	18.93 2449.02

4 结论与展望

本文提出一种基于多特征融合的航空发动机RUL预测模型。模型利用ES对原始数据进行降噪平滑处理,提高了模型对航空发动机数据中显著特征的敏感性,减少了模型迭代次数。使用Multi-attention为Bi-LSTM各个时间步长中获得的学习特征分配权重,充分利用模型构建中学习到的特征,解决了学习特征利用率较低的问题。设计Conv-LSTM模块挖掘高维模式下航空发动机数据的时空特征,提高了模型RUL预测精度。根据传感器数据特点进行预处理,提取航空发动机数据的手工特征为RUL预测提供不同重要程度的额外信息。使用C-MAPSS数据集对模型进行仿真验证,并与其他模型进行比较,实验结果表明该模型预测精度更高,适应性更好,综合性能优于其他模型,有着更好的应用前景。

该模型虽然迭代次数较少,但是每次迭代运行时间较长,未来工作将在保证RUL预测精度的基础上,通过简化模型缩减每次迭代运行时间,并且尝试减少神经元之间复杂的共适应关系,提高模型的泛化能力。

参考文献

- 车畅畅,王华伟,倪晓梅,等.基于1D-CNN和Bi-LSTM的航空发动机剩余寿命预测.机械工程学报,2021,57(14):304-312.
- 曾慧洁,郭建胜.双向LSTM神经网络的航空发动机故障预测.空军工程大学学报(自然科学版),2019,20(4):26-32.
- Chen ZH, Wu M, Zhao R, et al. Machine remaining useful life prediction via an attention based deep learning approach.

- IEEE Transactions on Industrial Electronics, 2021, 68(3): 2521-2531. [doi: 10.1109/TIE.2020.2972443]
- 易顺民,谢林柏,彭力.基于VF-DW-DFN的锂离子电池剩余寿命预测.储能科学与技术,2022,11(7):2305-2315.
- 刘月峰,张小燕,郭威,等.基于优化混合模型的航空发动机剩余寿命预测方法.计算机应用,2022,42(9):2960-2968.
- Yang BY, Liu RN, Zio E. Remaining useful life prediction based on a double-convolutional neural network architecture. IEEE Transactions on Industrial Electronics, 2019, 66(12): 9521-9530. [doi: 10.1109/TIE.2019.2924605]
- Zhu J, Chen N, Peng WW. Estimation of bearing remaining useful life based on multiscale convolutional neural network. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3208-3216. [doi: 10.1109/TIE.2018.2844856]
- Shao HD, Jiang HK, Zhang HZ, et al. Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network. IEEE Transactions on Industrial Electronics, 2018, 65(3): 2727-2736. [doi: 10.1109/TIE.2017.2745473]
- Aggarwal K, Atan O, Farahat AK, et al. Two birds with one network: Unifying failure event prediction and time-to-failure modeling. Proceedings of 2018 IEEE International Conference on Big Data (Big Data). Seattle: IEEE, 2018. 1308-1317.
- Wu JY, Wu M, Chen ZH, et al. Degradation-aware remaining useful life prediction with LSTM autoencoder. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3511810.
- Zheng S, Ristovski K, Farahat A, et al. Long short-term memory network for remaining useful life estimation. Proceedings of 2017 IEEE International Conference on Prognostics and Health Management. Dallas: IEEE, 2017. 88-95.
- Miao HH, Li B, Sun C, et al. Joint learning of degradation assessment and RUL prediction for aeroengines via dual-task deep LSTM networks. IEEE Transactions on Industrial Informatics, 2019, 15(9): 5023-5032. [doi: 10.1109/TII.2019.2900295]
- Kim B, Chung K, Lee J, et al. A Bi-LSTM memory network for end-to-end goal-oriented dialog learning. Computer Speech & Language, 2019, 53: 217-230.
- 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.航空学报,2022,43(7):301-312.
- Saxena A, Goebel K, Simon D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation. Proceedings of 2008 International Conference on Prognostics and Health Management. Denver: IEEE, 2008. 1-9.

- 16 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. 电子测量技术, 2021, 44(24): 153–160. [doi: [10.19651/j.cnki.emt.2107902](https://doi.org/10.19651/j.cnki.emt.2107902)]
- 17 Zhang C, Lim P, Qin AK, *et al.* Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2306–2318. [doi: [10.1109/TNNLS.2016.2582798](https://doi.org/10.1109/TNNLS.2016.2582798)]
- 18 赖儒杰, 范启富. 基于指数平滑和 XGBoost 的航空发动机剩余寿命预测. 化工自动化及仪表, 2020, 47(3): 243–247, 250. [doi: [10.3969/j.issn.1000-3932.2020.03.010](https://doi.org/10.3969/j.issn.1000-3932.2020.03.010)]
- 19 Ruan DW, Wu YH, Yan JP. Remaining useful life prediction for aero-engine based on LSTM and CNN. Proceedings of 2021 33rd Chinese Control and Decision Conference (CCDC). Kunming: IEEE, 2021. 6706–6712.
- 20 Badu GS, Zhao PL, Li XL. Deep convolutional neural network based regression approach for estimation of remaining useful life. Proceedings of 21st International Conference on Database Systems for Advanced Applications, Dallas: Springer, 2016. 214–228.
- 21 Tang JX, Xiao L. The improvement of remaining useful life prediction for aero-engines by classification and deep learning. Proceedings of 2020 11th International Conference on Prognostics and System Health Management. Jinan: IEEE, 2020. 130–136.
- 22 Wang JJ, Wen GL, Yang SP, *et al.* Remaining useful life estimation in prognostics using deep bidirectional LSTM neural network. Proceedings of the 2018 Prognostics and System Health Management Conference (PHM-Chongqing). Chongqing: IEEE, 2018. 1037–1042.

(校对责编: 孙君艳)