

文章编号: 1674-8190(2022)03-157-07

# 基于KPCA-BLSTM的航空发动机多信息融合剩余寿命预测

胡启国, 白熊, 杜春超

(重庆交通大学 机电与车辆工程学院, 重庆 400074)

**摘要:** 复杂航空发动机在运行过程中易出现多退化信息而导致寿命预测不精确的问题, 为此提出基于核主成分分析(KPCA)和双向长短时记忆(BLSTM)神经网络的多信息融合寿命预测模型。首先采用KPCA对多维退化数据集进行降维处理和信息融合, 得到能够表征设备退化的低维特征数据集; 然后利用BLSTM神经网络对带有多维退化信息的航空发动机剩余寿命进行预测, 得到监测数据与剩余寿命的映射关系; 最后采用C-MAPSS航空发动机退化数据集对提出的多信息融合寿命预测模型进行仿真验证, 并与其他三种模型结果进行对比。结果表明: KPCA-BLSTM神经网络能够对多维退化信息下的剩余寿命进行精准预测, 本文提出的预测模型的误差与得分优于其他三种模型, 而且预测精度更高。

**关键词:** 航空发动机; 剩余寿命; 多信息融合; 双向长短时记忆; 核主成分分析

中图分类号: V263.5

文献标识码: A

DOI: 10.16615/j.cnki.1674-8190.2022.03.18

开放科学(资源服务)标识码(OSID):



## Remaining Useful Life Prediction of Aero-engine Multi-information Fusion Based on KPCA-BLSTM

HU Qiguo, BAI Xiong, DU Chunchao

(School of Mechatronics and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

**Abstract:** The inaccurate life prediction caused by multiple degradation information can be easily appeared during the operation of complex aero-engine, a multi-information fusion life prediction model based on kernel principal component analysis (KPCA) and bidirectional long short-term memory (BLSTM) neural network is proposed. Firstly, the kernel principal component method is used to perform dimensionality reduction and information fusion on the multi-dimensional degraded data set to obtain a low-dimensional feature data set that can characterize equipment degradation. Then, the BLSTM neural network is used to predict the remaining useful life (RUL) of aero-engine with multi-dimensional degradation information to obtain the mapping relationship between the monitoring data and the remaining life. Finally, the C-MAPSS aero-engine degradation data set is used to simulate and verify the proposed multi-information fusion life prediction model, and the results are compared with other three models. The results show that the proposed KPCA-BLSTM neural network can predict RUL under multi-dimensional degradation information accurately, the error and score of the proposed model are better than the other three models, and the model has higher prediction accuracy.

**Key words:** aero-engine; remaining useful life; multi-information fusion; bidirectional long short-term memory; kernel principal component analysis

收稿日期: 2021-06-25; 修回日期: 2021-08-07

基金项目: 国家自然科学基金(51375519); 重庆市基础科学与前沿技术研究专项项目(cstc2015jcyjBX0133)

通信作者: 白熊, bxcqjtu@163.com

引用格式: 胡启国, 白熊, 杜春超. 基于KPCA-BLSTM的航空发动机多信息融合剩余寿命预测[J]. 航空工程进展, 2022, 13(3): 157-163, 170.

HU Qiguo, BAI Xiong, DU Chunchao. Remaining useful life prediction of aero-engine multi-information fusion based on KPCA-BLSTM[J]. Advances in Aeronautical Science and Engineering, 2022, 13(3): 157-163, 170. (in Chinese)

## 0 引言

航空发动机在正常运行中发生事故,会造成巨大的经济与社会损失,为了保证航空发动机可靠、安全地运行,利用设备监测数据对其进行剩余寿命预测显得尤为重要,可以为设备提前检修提供参考依据。

众多研究者对剩余寿命预测进行了深入研究。裴洪等<sup>[1]</sup>总结和分析了基于机器学习的设备剩余寿命(Remaining Useful Life,简称RUL)预测方法,通过分析基于机器学习的剩余寿命模型理论和模型内部结构的层数,将其分为浅层机器学习和深度学习的方法;武博等<sup>[2]</sup>提出利用主成分分析建立不同程度判断标尺构建导弹筒寿命预测模型,实现对导弹筒的全周期寿命评估;杜方舟等<sup>[3]</sup>基于航空发动机排气温度裕度数据,利用遗传算法优化基于支持向量机的剩余寿命预测模型,最终拟合出的寿命曲线与原厂数据高度切合,得到较好的预测效果;高峰等<sup>[4]</sup>通过多域特征量对数据集进行扩充,并搭建了长短时记忆(Long Short-term Memory,简称LSTM)神经网络寿命预测模型,最终利用C-MAPSS数据集验证了该方法的可靠性;马忠等<sup>[5]</sup>通过改进卷积神经网络(Convolutional Neural Networks,简称CNN)解决了航空发动机多状态变量下的非线性特征导致剩余寿命预测困难的问题,结果表明改进CNN进行寿命预测的准确性得到显著提高;牟含笑等<sup>[6]</sup>提出基于深度置信网络与BLSTM神经网络的航空推进系统剩余寿命预测方法,该方法适用于时间序列的处理;李杰等<sup>[7]</sup>等提出一种融合神经网络的剩余寿命预测方法,该方法精度高且具有良好的鲁棒性;车畅畅等<sup>[8]</sup>将一维卷积神经网络与BLSTM神经网络混合模型运用到航空发动机的剩余寿命预测中,准确地预测寿命变化的结果,相较于单一使用BLSTM或CNN网络模型的预测精度有所提高;曾慧洁等<sup>[9]</sup>通过模型对样本集正反序列的训练学习,建立了BLSTM网络模型来预测航空发动机故障,并将结果与其他神经网络模型对比,表明双向长短时记忆神经网络预测精度更高;宋亚等<sup>[10]</sup>提出了一种基于自动编码器和双向LSTM的混合模

型来预测涡轮发动机的RUL,并获得了比LSTM模型更好的预测结果。针对航空发动机寿命预测问题,国外E. L. Ntantis等<sup>[11]</sup>总结了航空发动机故障与提前维修预测方法,对比了物理建模、人工神经网络、贝叶斯神经网络、CNN等多种方法,得出基于神经网络的预测方法更加快速、准确;I. Remadna等<sup>[12]</sup>考虑航空发动机退化数据特征提取困难的问题,利用CNN对复杂退化信息进行提取,再利用BLSTM神经网络对航空发动机剩余寿命进行了预测,通过C-MAPSS数据集验证了该方法;C. Ordóñez等<sup>[13]</sup>提出一种由差分自回归移动模型与支持向量机组成的混合模型对航空发动机RUL进行预测,通过航空发动机数据集验证了该模型,并取得不错的预测效果。

虽然众多研究者所提出的RUL模型都取得了不错的预测效果,但大多研究者在预测时并未考虑数据间的非线性关系及多信息冗余问题导致模型训练时学习过多产生不必要的信息而使得预测精度大打折扣的问题。

本文提出利用核主成分分析处理非线性数据的优越性,对多维退化性息进行融合降维;针对BLSTM神经网络处理时间序列的能力提出一种基于KPCA-BLSTM神经网络的航空发动机多信息融合剩余寿命预测模型,并利用C-MAPSS航空发动机数据集进行对比验证,并与SVR、CNN、BLSTM神经网络模型的预测结果进行对比。

## 1 双向长短时记忆神经网络原理

航空发动机的退化过程是一个累积的过程,状态变化不仅与当前时刻的监测信息有关,而且某个历史时刻的信息也会影响设备的状态变化<sup>[14-15]</sup>。国内外研究者提出的LSTM神经网络,相对于普通循环神经网络(Recurrent Neural Networks,简称RNN),既可以更好地处理长时间序列的数据信息,又可以解决训练过程中的梯度消失和梯度爆炸问题。

### 1.1 LSTM神经网络

LSTM神经网络利用3个控制门来实现控制开关的作用,控制门单元就是一个全连接层的网

络,输入、输出是一个向量集合,选择 sigmoid 作为激活函数,函数特点为输出值在 0~1 之间。其中  $c$  值受到遗忘门、输入门的限制,遗忘门决定从  $c_{t-1}$  状态到  $c_t$  状态信息保存量;输入门负责  $x_t$  状态到  $c_t$  状态的信息保存量。另外,LSTM 用输出门来负责  $c_t$  状态的输出,即控制信息传输至  $h_t$ 。LSTM 结构示意图如图 1 所示,其中  $i_t, f_t, o_t$  分别为输入门,遗忘门和输出门的运算结果; $W_f, W_i, W_c$  分别为每个部分的权重矩阵; $\sigma$  和  $\tanh$  分别为 sigmoid 函数与双曲正切函数; $h_t$  为输出; $c'_t$  为当前单元状态的候选值; $c_t$  为更新后的单元状态值; $x_t$  为输入值。

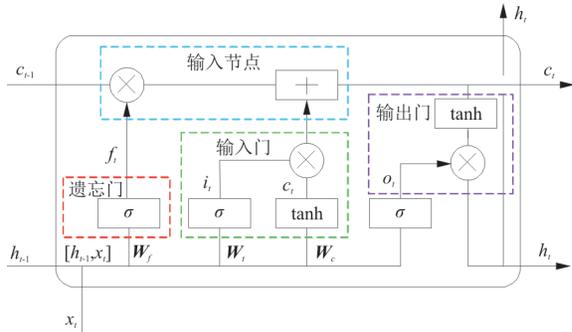


图 1 LSTM 神经单元示意图  
Fig. 1 Schematic diagram of LSTM neural unit

LSTM 模型通过使用由上一层输出的  $h_{t-1}$  和当前时间输入的  $x_t$  组成的输入向量计算遗忘门  $f_t$  来控制存储单元的状态:

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

式中:  $W_f$  为输入层的权重矩阵;  $b_f$  为偏置向量;  $\sigma(\cdot)$  为激活函数,即 sigmoid 函数。

当信息传递到输入层单元后,第一部分是通  
过 sigmoid 函数确定输入门  $i_t$  的更新值;第二部分是通  
过  $\tanh$  生成新的  $\tilde{c}_t$  值,并存入储存单元。

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

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

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (4)$$

式中:  $W_i, b_i$  分别为状态更新层的权重和偏差。

信息传递到输出层后,网络通过输出门  $o_t$  控制更新状态的输出。

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

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

式中:  $W_o, b_o$  分别为输出层的权重和偏差。

## 1.2 双向 LSTM 神经网络

双向 LSTM 神经网络由 LSTM 层的两个方向组成。在长时间序列的训练过程中,可以从正反两个方向捕获整个序列的信息,具有比 LSTM 更高的性能。双向 LSTM 结构如图 2 所示。

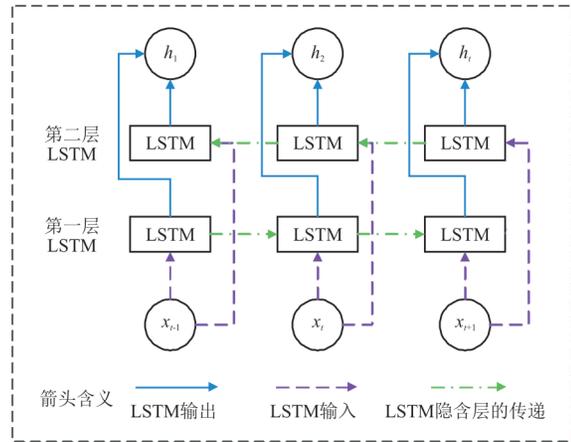


图 2 双向 LSTM 结构示意图  
Fig. 2 Schematic diagram of BLSTM structure

第一层 LSTM 结构计算当前输入的正向序列信息,第二层 LSTM 结构反向计算相同的序列,两层结构均存在相互独立的隐含层。LSTM 结构层间的隐含层输出,不仅要传递给下一层的输入层,而且通过双向 LSTM 结构还需要传递给上一层的输入结构中。在训练过程中,通过对输出单元的正反向传播,完成对神经网络的权重更新。

## 2 多信息融合 RUL 预测模型

### 2.1 预测模型建立

航空发动机在投入到生产使用过程中受到内部因素和外界环境的影响,其性能会发生退化,各项性能指标也会相应降低,直至失效完全失去工作能力。在实际试验或运用中,会通过各种传感器获得这些设备的现场运行监测数据,这些数据可视为以设备运作为基础的时间序列。

设一组设备的监测数据  $X$  可表示为

$$X = \{X_1, \dots, X_i, \dots, X_m\} \quad (i = 1, 2, \dots, m) \quad (7)$$

式中:  $X_i$  为第  $i$  台设备的所有运行状态监测数据集。

$$X_i = \{x_{i1}, \dots, x_{ij}, \dots, x_{in}\} \quad (8)$$

式中:  $x_{ij}$  为第  $i$  台设备的第  $j$  个状态监测变量的时

间序列。

$$x_{ij} = [x_{ij}^1, \dots, x_{ij}^k, \dots, x_{ij}^q]^T \quad (k=1, 2, \dots, q) \quad (9)$$

式中:  $x_{ij}^k$  为第  $i$  台装置的第  $j$  个信息监测变量的第  $k$  个监测值。

因此, 与第  $i$  台监测设备的状态数据相对应的剩余寿命集合表示为

$$Y = \{Y_1, \dots, Y_i, \dots, Y_m\} \quad (10)$$

$$Y_i = \{y_i^1, \dots, y_i^k, \dots, y_i^q\}^T \quad (11)$$

式中:  $y_i^k$  为  $i$  台设备在  $k$  时刻寿命值。

基于以上思想, 本文提出一种针对多状态多维度退化特征的监测数据 RUL 预测模型, 整体流程如图 3 所示。

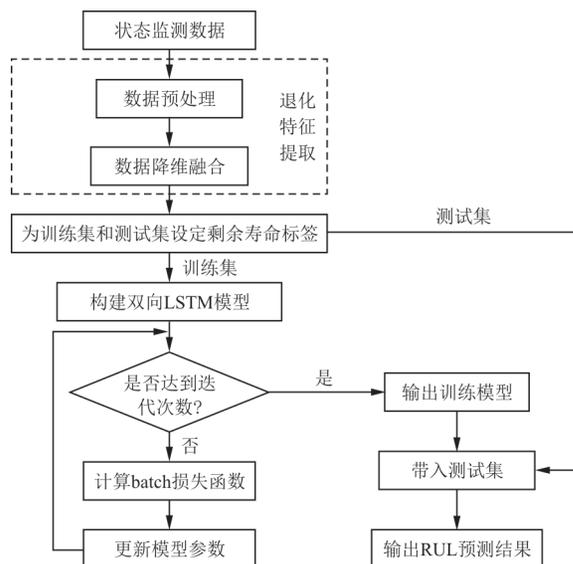


图 3 RUL 预测模型流程图

Fig. 3 RUL prediction model flowchart

由于整个模型的输入为多状态监测数据, 首先进行数据预处理, 并采用 KPCA 对预处理后的多维状态数据进行融合降维; 其次添加 RUL 标签, 按照时间窗大小对低维监测数据的时间序列进行划分, 并建立双向 LSTM 深度学习网络模型; 然后分别设置批量 (batch) 从 20 开始, 以 10 个批量为间隔数增加, 根据每个迭代次数的平均损失函数与更改模型权重参数选取最佳批量, 直至损失减小并趋于稳定; 最后将测试数据导入模型进行验证, 通过评价模型判断模型训练的效果。

## 2.2 数据预处理

在进行预测之前, 需要对多状态监测数据进

行预处理, 为了使设备的真实值和预测值在训练时表现出差异性, 需要对数据集添加 RUL 标签。退化过程是退化量累积的过程, 在航空发动机运行初期, 退化特征并不明显, 一段时间后设备能够平稳运作, 直到运行到某一阶段, 设备开始进入加速退化阶段, 并出现故障, 因此采用分段线性模型<sup>[16]</sup>进行预测, 如图 4 所示。

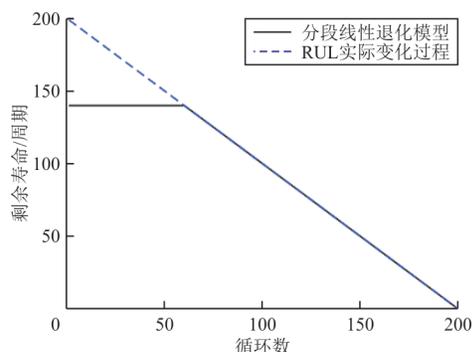


图 4 分段线性模型

Fig. 4 Piecewise linear model

为了消除传感器参数范围的差异, 对每组传感器监测的数据进行线性归一化处理, 使得处理后的参数值在  $[0, 1]$  的范围内。其表达式为

$$x' = \frac{x - \min x}{\max x - \min x} \quad (12)$$

## 2.3 模型输入

经过数据预处理后, 采用 KPCA 进行降维, 然后根据方差贡献量选择适当的维数。在模型训练过程中, 为了防止模型出现过拟合现象, 在双向 LSTM 层与全连接层中添加一个 Dropout 层, 并且设置一定的丢弃率去掉隐含层部分输出值, 确保神经元在正向传播中不被影响。根据时间步长对训练集和测试集进行分割, 并将分割后的训练集输入到双向 LSTM 模型中。选择均方误差  $e_{\text{MSE}}$  作为损失函数  $L$ , 其表达式为

$$L = e_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2 \quad (13)$$

式中:  $y'_i, y_i$  分别为预测值与真实值;  $n$  为样本总量。

## 2.4 模型评价标准

利用同样处理训练集的方法对测试集进行数据处理, 并输入到训练后的神经网络模型中, 输出 RUL 预测值。为了定量评价模型预测能力, 采用

均方根误差和非对称评分函数作为评价依据<sup>[17]</sup>。

均方根误差可以反映预测误差的大小,其表达式为

$$e_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (14)$$

非对称评分函数能够通过判断预测值是否大于或小于真实值而给出截然不同的计算结果,其中评分正比于误差,其函数表达式为

$$S = \frac{1}{N} \sum_{i=1}^N s_i \quad (15)$$

$$\begin{cases} s_i = e^{-\frac{d_i}{13}} - 1 & (d_i < 0) \\ s_i = e^{\frac{d_i}{10}} - 1 & (d_i \geq 0) \end{cases} \quad (16)$$

式中: $N$ 为测试集样本总量; $d_i$ 为剩余寿命差, $d_i = y'_i - y_i$ 。

### 3 对比验证

#### 3.1 数据集介绍

本文采用C-MAPSS数据集进行仿真验证,数据集由四个子集组成,包含6种不同的工作条件和4种故障形式,每个子集记录了在不同工作条件和故障类型下航空发动机的健康状况退化数据。C-MAPSS数据集中包含的全部信息如表1所示。

表1 航空发动机监测数据  
Table 1 Aero engine monitoring data

子集	训练集/组	测试集/组	工作条件/种	故障模式
FD001	100	100	1	1
FD002	260	259	6	1
FD003	100	100	1	2
FD004	248	248	6	2

选用FD003子集作为实验数据集,FD003数据集包括3个工作条件参数:飞行高度,马赫数和油门旋转变压器角度,它们可以组合成六个对发动机性能有重大影响的工作条件。数据还包括21个发动机传感器,例如风扇入口处的压力,燃烧器的燃料空气比和旁路比。FD003的故障模式为HPC退化和风扇退化失效。

#### 3.2 仿真实证

为了减小训练模型的复杂度,增强其稳定性,选用KPCA对发动机高维数据进行降维,KPCA是一种常用的数据融合和维数约简方法,即构造高维特征空间,把原始变量转化为空间内积矩阵,并利用原始变量空间的核函数代替内积函数。为了确定目标降维量,将累计方差贡献量作为目标降维量选取的标准,经计算得出各特征的方差贡献量如图5所示,前10维累计方差贡献量达到0.95,由此选定10维作为目标降维量。

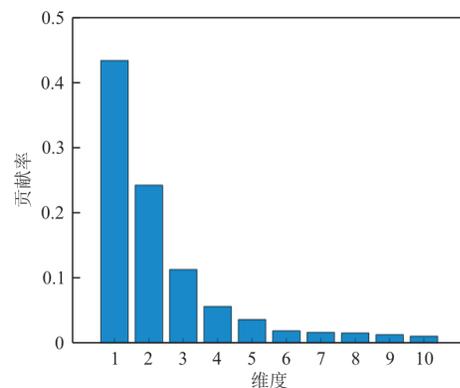


图5 KPCA方差贡献量  
Fig. 5 KPCA variance contribution

经KPCA降维后,根据时间步长对训练集和测试集的时间序列进行划分。输入模型的3D张量为(24 720, 50, 10)。在将数据输入模型之前,需要设置模型的各种参数。模型参数直接影响模型的性能,选择合适的神经网络参数对模型的训练成功与否起着至关重要的作用,经反复调试参数后,确定模型的主要参数,如表2所示。

表2 BLSTM神经网络参数设置  
Table 2 BLSTM neural network parameter settings

网络参数	数值
退化阈值	140
BLSTM第一层单元数	50
BLSTM第二层单元数	50
全连接层	1
激活层	1
Dropout层	0.2
批量	100

将输入模型的数据集以 9:1 的比例划分为训练集和验证集。设置“提前停止”的参数,如果在 10 个周期内验证集的误差无下降趋势,则将停止训练。利用验证集(即 100 组发动机)验证模型准确度,验证结果如图 6 所示,可以看出:预测值与真实值的拟合度较高,说明模型的预测效果较好。

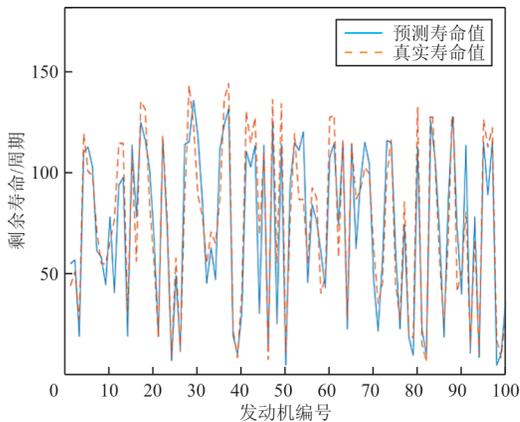
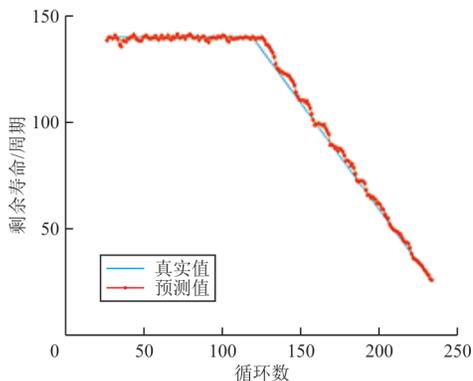
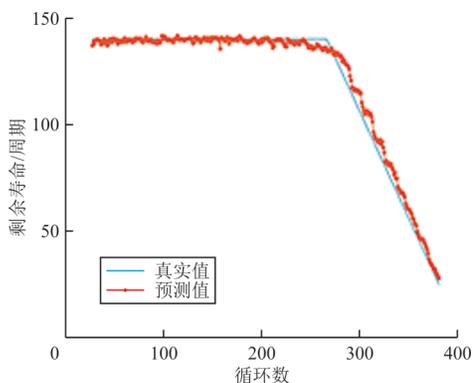


图 6 模型预测结果  
Fig. 6 Model prediction results

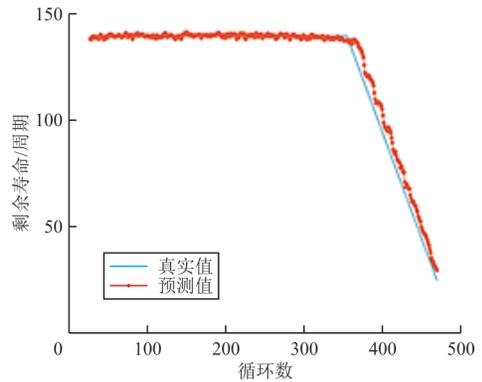
为了进一步验证所建立模型的预测效果,对 C-MAPSS 数据集的 FD003 中 1、9、24、35 号发动机剩余寿命进行预测拟合,其中部分发动机数据拟合结果如图 7 所示。



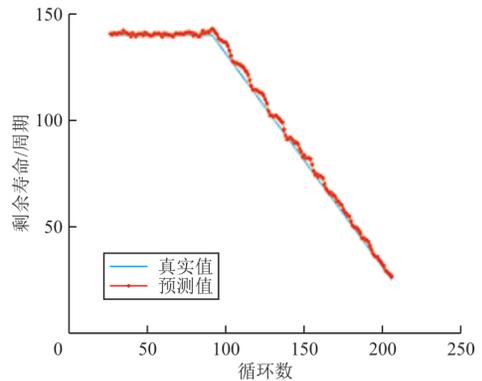
(a) FD003 第 1 号发动机



(b) FD003 第 9 号发动机



(c) FD003 第 24 号发动机



(d) FD003 第 35 号发动机

图 7 不同型号发动机预测对比  
Fig. 7 Comparison of predictions for different types of engines

从图 7 可以看出:无论发动机处于循环周期的前、中、后期,该模型得到的预测值和真实值的拟合程度都较为准确,预测值分布在真实值附近。由此可以得出本模型针对发动机这类复杂设备具有较高的预测精度,为提升发动机的可靠性和安全性提供了依据。

### 3.3 多模型预测结果对比

为了证明模型的准确度,选用 FD003 中 1 号发动机数据,分别搭建支持向量机回归(SVR), CNN, LSTM 以及 BLSTM 预测模型,并与 KPCA-BLSTM 预测结果相对比,对比结果如表 3 所示。

表 3 多模型预测结果对比  
Table 3 Comparison of multi-model prediction results

模型	均方根误差	得分
SVR	25.69	1 380.0
LSTM	22.91	1 982.0
CNN	19.82	1 290.0
BLSTM	16.38	317.0
KPCA-BLSTM	13.54	225.6

从表3可以看出:KPCA-BLSTM模型在误差和得分上均优于单个模型,三种深度学习模型预测结果优于传统机器学习方法SVR;BLSTM比LSTM具有更好的性能,这表明BLSTM在处理较长时间序列时可以结合历史和将来的信息来充分表征状态监视数据的内部关系。

## 4 结 论

(1) 利用KPCA对航空发动机多监测信息进行降维与融合,通过方差贡献量判断10维为最佳目标降维量,最终得到一个低维信息融合数据集。

(2) 搭建了BLSTM神经网络预测模型,利用信息融合后的数据集对其进行训练,最终模型预测值对真实值拟合程度较高,表明模型的预测效果较好。

(3) 选取所提出的剩余寿命预测模型,将预测结果与SVR、CNN以及双向LSTM预测模型进行对比,KPCA-BLSTM模型的均方根误差与得分皆优于其他三种模型。

### 参 考 文 献

- [1] 裴洪,胡昌华,司小胜,等.基于机器学习的设备剩余寿命预测方法综述[J].机械工程学报,2019,55(8):1-13.  
PEI Hong, HU Changhua, SI Xiaosheng, et al. Review of machine learning based remaining useful life prediction methods for equipment[J]. Journal of Mechanical Engineering, 2019, 55(8): 1-13. (in Chinese)
- [2] 武博,靳冬,杨积东,等.基于检测数据主成分分析的筒弹寿命评估预测模型[J].导弹与航天运载技术,2021(6):60-63.  
WU Bo, JIN Dong, YANG Jidong, et al. Remaining useful life prediction of aeroengine based on fusion neural network[J]. Missiles and Space Vehicles, 2021(6): 60-63. (in Chinese)
- [3] 杜方舟,孙有朝,郭媛媛,等.基于数据的航空发动机排气温度裕度及剩余寿命计算方法[J].航空动力学报,2020,35(11):2456-2464.  
DU Fangzhou, SUN Youchao, GUO Yuanyuan, et al. Calculation method of aero-engine exhaust gas temperature margin, and remaining life based on data[J]. Journal of Aerospace Power, 2020, 35(11): 2456-2464. (in Chinese)
- [4] 高峰,曲建岭,袁涛,等.基于改进差分域特征和深度学习优化的航空发动机剩余寿命预测算法[J].电子测量与仪器学报,2019,33(3):21-28.  
GAO Feng, QU Jianling, YUAN Tao, et al. Research on random error identification and denoising method of MEMS gyroscope[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(3): 21-28. (in Chinese)
- [5] 马忠,郭建胜,顾涛勇,等.基于改进卷积神经网络的航空发动机剩余寿命预测[J].空军工程大学学报(自然科学版),2020,21(6):19-25.  
MA Zhong, GUO Jiansheng, GU Taoyong, et al. A remaining useful life prediction for aero engine based on improved convolution neural networks[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(6): 19-25. (in Chinese)
- [6] 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/OL].航空学报:1-13 [2021-05-11]. <http://gffiy3066c973e9140a1hw0unkcoxwubq6uw0.ffff.suse.cwkeji.cn:999/kcms/detail/11.1929.v.20210510.1354.004.html>.  
MOU Hanxiao, ZHENG Jianfei, HU Changhua, et al. Remaining useful life prediction of multivariate degradation equipment based on CDBN and BiLSTM [J/OL]. Acta Aeronautica et Aeronautica Sinica: 1-13 [2021-05-11]. <http://gffiy3066c973e9140a1hw0unkcoxwubq6uw0.ffff.suse.cwkeji.cn:999/kcms/detail/11.1929.v.20210510.1354.004.html>. (in Chinese)
- [7] 李杰,贾渊杰,张志新,等.基于融合神经网络的航空发动机剩余寿命预测[J].推进技术,2021,42(8):1725-1734.  
LI Jie, JIA Yuanjie, ZHANG Zhixin, et al. Remaining life prediction of aero-engine based on fusion neural network[J]. Journal of Propulsion Technology, 2021, 42(8): 1725-1734. (in Chinese)
- [8] 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[J].机械工程学报,2021,57(4):304-312.  
CHE Changchang, WANG Huawei, NI Xiaomei, et al. Remaining life prediction of aero-engine based on 1D-CNN and Bi-LSTM[J]. Journal of Mechanical Engineering, 2021, 57(4): 304-312. (in Chinese)
- [9] 曾慧洁,郭建胜.双向LSTM神经网络的航空发动机故障预测[J].空军工程大学学报(自然科学版),2019,20(4):26-32.  
ZENG Huijie, GUO Jiansheng. Aeroengine fault prediction based on two-way LSTM neural network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(4): 26-32. (in Chinese)
- [10] 宋亚,夏唐斌,郑宇,等.基于Autoencoder-BLSTM的涡扇发动机剩余寿命预测[J].计算机集成制造系统,2019,25(7):1611-1619.

