

DOI: 10.3901/JME.2021.14.304

# 基于 1D-CNN 和 Bi-LSTM 的航空发动机 剩余寿命预测\*

车畅畅 王华伟 倪晓梅 蔺瑞管 熊明兰  
(南京航空航天大学民航学院 南京 211106)

**摘要:** 剩余寿命预测对航空发动机的预防性维修有重要指导作用,是保障飞机安全运行,提高维修保障效率的重要手段。一维卷积神经网络(1-dimensional convolutional neural network, 1D-CNN)和双向长短时记忆神经网络(Bidirectional long short memory, Bi-LSTM)被应用于航空发动机剩余寿命预测模型。首先,根据工程经验在多状态参数的主成分分析的基础上对退化过程进行随机分布拟合,得到综合性能退化量;然后将多变量时间序列样本和对应的性能退化量代入 1D-CNN 模型进行回归分析,从而得到性能退化分析模型;再通过 Bi-LSTM 对性能退化量进行时间序列预测,得到性能退化的未来趋势;最后通过设定性能退化阈值,得到剩余寿命预测结果,从而得到从多状态参数-性能退化分析-性能退化预测-剩余寿命预测的实时动态感知模型。实例分析结果表明,提出的混合模型与其他单一深度学习和传统模型相比,有更低的回归分析误差和退化预测误差,能够得到更准确可靠的剩余寿命预测结果。

**关键词:** 航空发动机; 剩余寿命; 性能退化; 一维卷积神经网络; 双向长短时记忆网络

**中图分类号:** V267

## Residual Life Prediction of Aeroengine Based on 1D-CNN and Bi-LSTM

CHE Changchang WANG Huawei NI Xiaomei LIN Ruiguan XIONG Minglan  
(School of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106)

**Abstract:** Residual life prediction plays an important role in the preventive maintenance of aeroengine, and it is an important means to ensure the safe operation of aircraft and improve the efficiency of maintenance support. A residual life prediction model of aeroengine based on 1-dimensional convolution neural network (1D-CNN) and bidirectional long short memory neural network (Bi-LSTM) is proposed. Firstly, according to the engineering experience, on the basis of the principal component analysis of multi-state parameters, the degradation process is randomly distributed and fitted to obtain the comprehensive performance degradation amount; then, the multi variable time series samples and the corresponding performance degradation amount are brought into the 1D-CNN model for regression analysis to obtain the performance degradation analysis model; then, the performance degradation amount is predicted by the Bi-LSTM time series, The future trend of performance degradation is obtained. Finally, by setting the performance degradation threshold, the residual life prediction results are obtained, and the real-time dynamic perception model from multi state parameters performance degradation analysis performance degradation prediction residual life prediction is obtained. The results show that the proposed hybrid model has lower regression analysis error and degradation prediction error compared with other single deep learning and traditional models, and can get more accurate and reliable residual life prediction results.

**Key words:** aeroengine; residual life; performance degradation; 1-dimensional convolutional neural network; bidirectional long short memory neural network

\* 国家自然科学基金和中国民航局联合资助项目(U1833110)。20200605 收到初稿, 20210415 收到修改稿

## 0 前言

航空发动机剩余寿命预测能够依据当前状态监测数据或历史数据等信息,通过特征提取和趋势预测技术,构建寿命预测模型,得到航空发动机的剩余寿命。剩余寿命预测能够用于动态感知航空发动机健康状况的未来变化,为预防性维修提供技术支撑。随着数据采集技术的不断发展,能够得到海量的多维机载传感器数据。因此如何利用数据处理和挖掘技术,构建合适的模型并从航空大数据中提取出典型特征是剩余寿命预测的研究重点。国内外目前主流的数据驱动的剩余寿命预测模型包括统计分析模型、浅层机器学习模型和深度学习模型<sup>[1]</sup>。常用的统计分析模型包括随机滤波模型和维纳过程模型<sup>[2-3]</sup>。传统的统计数据驱动方法受模型的选择影响明显,容易受到工程经验和主观因素影响。同时,对于不同的研究目标,统计分析模型的通用性也较差,需要重复建模。而机器学习具有强大的数据处理能力,并且无需确切的物理模型和专家先验知识,因而机器学习在剩余寿命预测领域表现出了广阔的应用前景。机器学习模型包括浅层机器学习模型和深度学习模型。浅层机器学习模型包括人工神经网络、极限学习机(Extreme learning machines, ELMs)、马尔可夫模型和支持向量回归<sup>[4-7]</sup>。浅层机器学习多具有较少隐层,模型结构简单,对于复杂非线性多维度样本的深层次特征提取能力较差,因此常常被用于数据的预处理,降低样本维度;或者是作为深度学习模型的输出层,用于学习已提取出的特征与样本标签的浅层映射关系。

随着传感器技术和人工智能技术的全面发展,能够采集到大量的数据用于深度学习模型的训练,因此如何将深度学习模型应用于工程领域是目前研究的重点。基于深度学习的剩余寿命预测模型主要包括深度神经网络(Deep neural network, DNN)、卷积神经网络(Convolutional neural network, CNN)、递归神经网络(Recurrent neural network, RNN)、门控神经单元(Gated recurrent unit, GRU)和长短时记忆网络(Long short term memory, LSTM)的方法。WANG等<sup>[8]</sup>将递归卷积神经网络(RCNN)用于预测机器剩余使用寿命。LIU等<sup>[9]</sup>提出了一种基于LSTM和RNN的剩余使用寿命预测方法。AN等<sup>[10]</sup>介绍了一种将CNN与叠加的双向和单向LSTM网

络相结合的混合模型,用以处理剩余使用寿命预测任务中的序列数据。REN等<sup>[11]</sup>提出了一种多尺度密集门递归单元网络,通过添加多尺度层和密集层捕获序列特征,集成不同时间尺度的信息,用于物联网系统剩余使用寿命预测。YU等<sup>[12]</sup>提出了一种基于双向RNN和自动编码器的相似性曲线匹配方法,用于机械系统剩余使用寿命的估计。DNN和CNN模型在聚类分析和回归分析的表现较好,RNN模型及其变体常被应用于时间序列预测。考虑到如今的深度学习方法常被应用于处理图像、语音或文本等高度复杂的样本,因此如何针对工程领域的状态参数数据、组合多种深度学习模型、充分发挥模型优势,从而得到准确的剩余寿命预测结果是当前研究的重点。

目前的剩余寿命预测研究多建立在性能退化分析和时间序列预测的基础上,在性能退化分析时,工程经验大多只能得到大致的退化分布,难以在一定的特征基础上得到不同时间点的性能退化量,因此不仅需要在对状态参数进行简单特征提取和分布拟合的基础上得到性能退化量,还需要充分挖掘多状态参数的深层次特征用于性能退化回归分析。在进行时间序列预测时,由于航空发动机的长寿命周期、低采样频率的数据特点,需要综合考虑长期特征和短期特征对预测结果的综合影响。综上所述,本文提出了基于1D-CNN和Bi-LSTM的航空发动机剩余寿命预测模型的主要创新点如下。

(1) 针对性能退化程度未知,只有故障时间的时间序列样本,本文在对多状态参数进行主成分分析的基础上对退化过程进行随机分布拟合,得到综合性能退化量。

(2) 使用1D-CNN模型对多状态参数进行回归分析,能够发掘出深层次非线性的特征用于表征航空发动机的性能退化程度,从而在保证预测精度的基础上,简化模型结构,提高模型训练效率。

(3) 针对数据的特点和实际需求,通过重复分割方法和滑动窗口处理方法生成训练样本,并采用Bi-LSTM对性能退化量进行时间序列预测。

## 1 航空发动机剩余寿命预测模型

航空发动机结构复杂,性能退化量难以直接测量,在剩余寿命预测时,缺乏必要的样本标签进行性能退化回归分析。为了获得性能退化量作为样本标签,本文提出了基于随机分布拟合的方法。该方法在多状态参数主成分分析的基础上,通过分布拟

合获得性能退化分布模型参数。然后在每一个时间点,通过添加随机噪声得到综合性能退化量作为回归分析的标签。随机分布拟合后的性能退化量能模拟在真实工作状况下,由于因环境影响、测量误差、系统耦合等因素而造成的与状态参数同步的性能退化量波动性变化。在得到多状态参数对应的性能退化量后,本文使用了一维卷积神经网络模型用于性能退化回归分析,该模型与传统二维卷积神经网络相比有更简单的输入和运算速度,与以神经网络模型为代表的回归分析模型相比有更少的模型参数。为了预测性能退化趋势,本文使用 Bi-LSTM 对性能退化量进行时间序列预测,该模型在 LSTM 模型的基础上增加了反向计算层,从而将长期记忆和短期记忆相结合,得到准确的预测结果。根据工程经验和可靠性要求,确定性能退化阈值,从而得到剩余寿命预测结果,用于指导预测性维修工作。

本文提出的基于 1D-CNN 和 Bi-LSTM 的剩余寿命预测模型流程如图 1 所示。首先对多状态参数进行主成分分析,并通过随机分布拟合从分析结果得到性能退化量;然后将多状态参数和性能退化量构建样本带入到 1D-CNN 模型中进行回归分析,得到性能退化分析模型;再将时间序列化的性能退化量作为样本带入到 Bi-LSTM 模型中进行性能退化预测;最后通过设定性能退化阈值从性能退化曲线中得到失效时间点,并计算剩余寿命,从而实现状态参数—性能退化分析—性能退化预测—剩余寿命预测的分析流程。

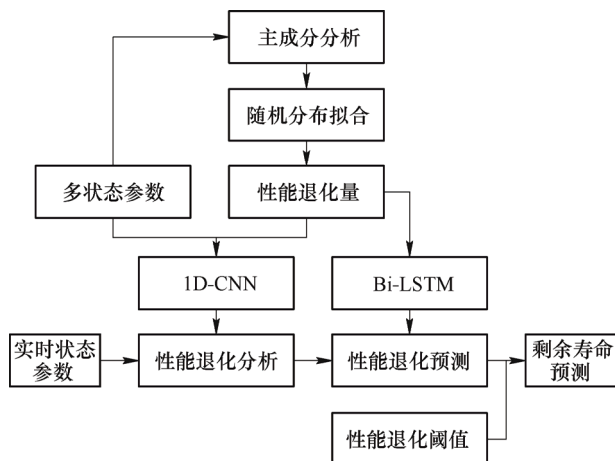


图 1 基于 1D-CNN 和 Bi-LSTM 的剩余寿命预测模型流程图

## 2 基于 1D-CNN 的回归分析

CNN 模型能够将数据的简单特征通过卷积和

池化操作映射到更复杂的高维模式。不同维度的 CNN 都具有相同的特点和相同的处理方法。关键区别在于输入数据的维数以及卷积核如何在数据之间滑动。1D-CNN 能够直接从状态参数样本入手,通过调整卷积核尺寸和移动方向直接实现样本的特征提取和回归分析,从而避免了构建和处理多维样本所需的复杂操作。1D-CNN 和 2D-CNN 的样本处理方式如图 2 所示。其中选取状态参数的一个片段作为样本,该样本有 36 维,定义卷积核的维度为 2,移动步长为 1,可以看出在 1D-CNN 中,卷积核尺寸为  $2 \times 1$ ,只沿着时间序列增加的方向移动;而 2D-CNN 的卷积核尺寸为  $2 \times 2$ ,分别沿着矩阵的横向和纵向以步长为 1 移动。1D-CNN 可以很好地应用于传感器数据的时间序列分析;同样也可以很好地用于分析具有固定长度周期的信号数据。针对本文要处理的性能退化量一维时间序列数据,本文采用 1D-CNN 模型进行时间序列预测<sup>[13]</sup>。

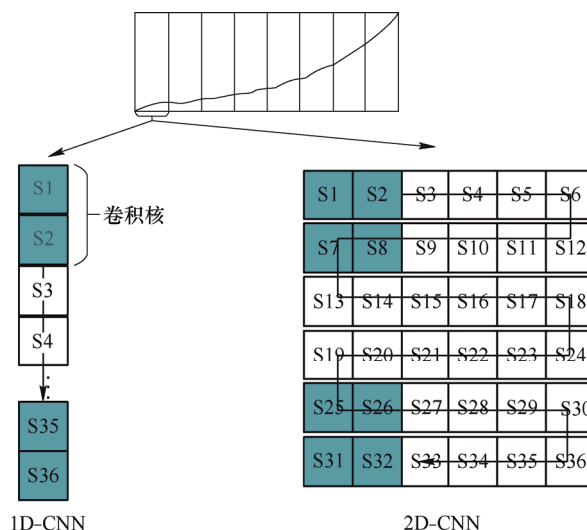


图 2 1D-CNN 和 2D-CNN 的样本处理方式

典型的包含两个隐层的 1D-CNN 模型结构如图 3 所示<sup>[14]</sup>。假设输入数据的大小为  $20 \times 1$ , 首先经过卷积操作后,变为大小为  $2 \times 20 \times 1$  的两个特征图;然后经过核尺寸为 2 的最大值池化操作后,得到  $2 \times 10 \times 1$  的第 1 个隐层的输出;其次经过第 2 个隐层的卷积核和池化操作后,得到大小为  $4 \times 5 \times 1$  的隐层的输出;再次将隐层输出层节点展开为全连接层,并与模型降维层节点全连接,通过激活函数可以得到模型输出;最后通过求解模型输出和真实输出的误差得到损失函数,使用反向传播算法和随机梯度下降法反向微调整个模型,可以得到训练好的 1D-CNN 并用于时间序列预测。




图3 1D-CNN 的模型结构图

### 3 基于 Bi-LSTM 的时间序列预测

传统的循环神经网络(Recurrent neural network, RNN)在训练的过程中会有长期依赖的问题,这是由于 RNN 模型在训练时会遇到梯度消失或者梯度爆炸的问题。针对过拟合问题,可以采用 Dropout 方法在训练的过程中按照一定的概率随机的将网络节点暂时从网络中丢弃。而针对长时间序列存在的梯度消失的问题, LSTM 能够通过门控单元来学习长期记忆。在 LSTM 的基础上,将长期记忆单元和短期记忆单元相结合,本文提出了双向长短时记忆神经网络用于得到更准确的时间序列预测结果。Bi-LSTM 内部节点与 LSTM 相同,包括输入门、遗忘门、输出门,其原理如图 4 所示<sup>[15]</sup>。

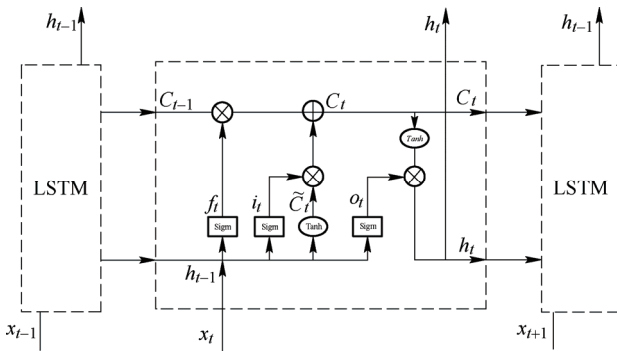


图4 Bi-LSTM 节点原理图

输入门  $f_t$ 、遗忘门  $i_t$  和输出门  $o_t$  的定义如下

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

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

$$o_t = \text{Sigmoid}(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

式中,  $h_{t-1}$  为上一时间序列的信息,  $x_t$  为当前时刻的输入,  $h_t$  为当前时间序列的输出信息,  $w$  为重置门权重,  $b$  为偏置项, 激活函数的公式是

$$\text{Sigmoid}(x) = 1/(1 + \exp(-x)) \quad (4)$$

$$\text{Tanh}(x) = (\exp(x) - \exp(-x)) / (\exp(x) + \exp(-x)) \quad (5)$$

长期记忆  $c_t$  和短期记忆  $h_t$  的输出结果为

$$c_f = f_t \otimes c_{t-1} \oplus i_t \otimes (\text{Tanh}(w_c \cdot [h_{t-1}, x_t] + b_c)) \quad (6)$$

$$h_t = o_t \otimes \text{Tanh}(c_t) \quad (7)$$

式中,  $\otimes$  是元素相乘,  $\oplus$  是元素相加。

Bi-LSTM 在 LSTM 模型结构正向层的基础上添加了反向层, 通过拼接前后向隐藏层向量用于充分考虑上下文信息, 提高了时间序列预测的有效性。其网络结构如图 5 所示。在前向层中, 从 1 时刻到  $t$  时刻正向计算一遍, 得到并保存每个时刻向前隐含层的输出。在后向层中, 沿着时刻  $t$  到时刻 1 反向计算一遍, 得到并保存每个时刻向后隐含层的输出。最后在每个时刻结合前向层和后向层的相应时刻输出的结果得到最终的输出, 数学表达式如下所示<sup>[16-17]</sup>

$$h_t^R = f^R(w_1 x_t + w_2 h_{t-1}^R) \quad (8)$$

$$h_t^L = f^L(w_3 x_t + w_4 h_{t+1}^L) \quad (9)$$

$$h_t = f(w_5 h_t^R + w_6 h_t^L) \quad (10)$$

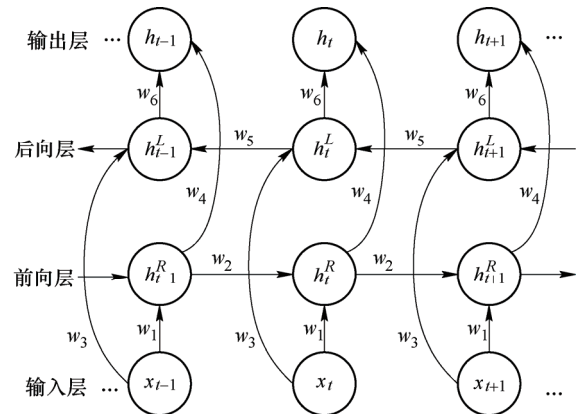


图5 Bi-LSTM 模型结构图

为了充分挖掘有限的性能退化时间序列样本的

深层次规律,避免由于样本不足而造成的难以完成深度学习模型训练,本文使用了重复分割方法和滑动窗口处理方法相结合的样本生成方法。一方面通过重复分割采用有重叠的样本分割策略,既可以尽可能多的保留相邻元素之间的相关性,也可以提高参与模型训练的样本数量,使模型尽可能学习到更具有鲁棒性的特征用于时间序列预测;另一方面通过滑动窗口法能够将时间序列样本转化为 Bi-LSTM 模型擅长处理的三维样本格式,从而得到更加准确的时间序列预测结果。同时,通过将预测的结果重新构成样本进行反复迭代,还能够得到多步长的预测结果。样本生成过程如图 6 所示。假设有 S1-S10 的时间序列。其中 {S1, S2, S3, S4} 构成样本 1 的状态参数, S5 是样本 1 的标签; {S2, S3, S4, S5} 是样本 2 的状态参数, S6 是样本 2 的样本标签。通过重复分割时间序列得到训练样本并获取相应的样本标签,可以构成大量的样本用于深度学习时间序列预测。




图 6 时间序列样本生成示意图

## 4 实例分析

### 4.1 数据采集与预处理

为了验证本文提出方法的有效性,本文使用 NASA 的 C-MAPSS 航空发动机仿真数据集进行试验。该数据集由训练集和测试集组成,其中训练集记录了航空发动机的多个状态参数从正常到故障的完整周期内每个时间序列的采样值;测试集则包含了故障前某一时间点之前的状态参数值以及对应的剩余寿命<sup>[18-19]</sup>。本文选取了部分训练集和测试集进行实例分析,选取的 14 个状态参数包括低压压缩机进气道总温度、高压压缩机进气道总温度、低压涡轮进气道总温度、高压压缩机出口处总压力、物理风机转速、物理核心速度、高压压缩机出口静压、燃料流量与高压压缩机出口处总压力的比率、修正风机转速、修正核心转速、涵道比、放气热含量、高压涡轮冷却剂释放速度、低压涡轮冷却剂释放速度。在文中用编号 F1~F14 来表示 14 个状态参数。

将选用的 14 个状态参数进行平滑处理和最大最小值归一化处理后可以得到如图 7 所示的变化曲

线。可以看出状态参数的特征复杂多变,很难通过人工直接提取出相关特征。




图 7 状态参数变化曲线

主成分分析方法能够通过提取特征值和特征矢量,从而评估不同状态参数的权重,在充分保留状态参数信息的基础上通过加权组合实现样本的降维处理。因此,将 F1~F14 共 14 个多个状态参数进行主成分分析,可以得到第一主成分贡献率为 97.47%。如图 8 所示,由第一主成分对应向量作为权重可以得到主成分回归曲线,在将主成分回归曲线进行分布拟合后,为了模拟真实环境下的噪声干扰,在分布拟合曲线中添加随机噪声可以得到性能退化曲线。




图 8 基于随机分布拟合的航空发动机性能退化量

由于在状态实时监测过程中不能得到最大值和最小值,因此本文采用 z-score 归一化法对实时状态参数进行归一化,如式(11)所示

$$z = \frac{(x - \mu)}{\delta} \quad (11)$$

式中,  $x$  是样本,  $\mu$  是样本均值,  $\delta$  是样本方差,  $z$  是归一化后的样本值。

### 4.2 基于 1D-CNN 的性能退化分析

在得到样本状态参数和样本标签基础上,可以



构建时间序列样本, 带入到 1D-CNN 模型中进行性能退化回归分析。1D-CNN 的参数设置如表 1 所示。

表 1 1D-CNN 模型参数

| 层定义         | 层参数            | 层输出尺寸    |
|-------------|----------------|----------|
| 卷积层 1       | 节点数 128, 核尺寸 2 | (13,128) |
| 卷积层 2       | 节点数 128, 核尺寸 2 | (12,128) |
| Dropout 层 1 | 节点丢失概率为 0.5    | (12,128) |
| 池化层 1       | 核大小为 2         | (6,128)  |
| 卷积层 3       | 节点数 256, 核尺寸 2 | (5,256)  |
| 池化层 2       | 核大小为 2         | (2, 256) |
| Dropout 层 2 | 节点丢失概率为 0.5    | (2, 256) |
| 全连接层        | 多维输入一维化        | (512)    |
| 降维层 1       | 网络结构为(512,256) | (256)    |
| 降维层 2       | 网络结构为(256,128) | (128)    |
| 降维层 3       | 网络结构为(128,64)  | (64)     |
| 降维层 4       | 网络结构为(64,1)    | (1)      |

样本训练过程使用测试平均绝对误差(Mean square error, MAE)和决定系数  $R$  来评估, 其定义如下

$$R = 1 - \frac{\sum_i (y_i - f_i)^2}{\sum_i \left( y_i - \frac{1}{n} \sum_{i=1}^n y_i \right)^2} \quad (12)$$

式中,  $f_i$  是模型预测值,  $y_i$  是真实值。  $R$  系数的取值范围为[0,1],  $R$  系数越大, 回归模型的效果越好。

在训练过程中的测试误差与训练误差变化情况如图 9 所示; 测试  $R$  系数和训练  $R$  系数变化情况如图 10 所示。其中一个训练周期指代所有的数据送入网络中完成一次前向计算及反向传播的过程。可以看出, 测试与训练的评价指标相差不大, 测试误差随着训练周期的增加逐渐减小到 0.016, 测试  $R$  系数逐渐升高到 0.992, 说明模型用于回归分析的误差较小、效果较好。




图 9 训练误差与测试误差曲线图




图 10 训练  $R$  系数和测试  $R$  系数的曲线图

图 11 展示了一组测试集的模型输出和实际值的对比结果, 可以看出模型输出值和实际值之间的误差极小, 能够满足性能退化分析的精度要求。




图 11 模型输出和实际值的对比

#### 4.3 基于 Bi-LSTM 的性能退化预测模型

在得到性能退化分析结果后, 通过滑动窗口法和重复分割来增加性能退化时间序列样本量, 然后将时间序列样本分为训练集和测试集带入到 Bi-LSTM 模型, 可以得到在模型训练过程中的训练误差和测试误差变化如图 12 所示。可以看出训练误差和测试误差随着训练周期的增加逐渐下降, 其中训练误差和测试误差的变化趋势相似, 测试误差略高于训练误差。




图 12 基于 Bi-LSTM 的性能退化预测示意图

为了测试 Bi-LSTM 的预测效果,将预测过程分为前期、中期和后期。在前中期的时间序列预测容易产生梯度消失和局部最优的现象,从而导致长期预测不准确的问题。因此在前中期通过时间序列预测获得一定的预测结果后,使用分布拟合的方法将人工经验和模型结果相结合得到性能退化趋势。选取一组时间序列样本的性能退化预测结果如图 13 所示。可以看出,随着已知时间序列的增加,性能退化预测结果与实际值更加接近,在设定阈值后,剩余寿命预测结果也更为准确。




图 13 Bi-LSTM 训练误差与测试误差

为了验证本文所提方法的有效性,构建了不同的深度学习模型用于剩余寿命预测。针对多状态参数的回归分析,选取了常用的 CNN、DBN、ANN 和支持向量回归作为对比模型,并根据数据特点,选取了合适的模型参数。其中,SVR 模型的惩罚系数  $C=1$ ,核函数选用径向基函数(Radial basis function network, RBF); DBN 和 ANN 的模型结构都是[14, 10, 6, 3, 1]; CNN 模型的输入为二维,其余基本参数设置与 1D-CNN 相同。选择训练最后一个训练周期的测试集的 MAE 和  $R$  系数作为对比指标,试验结果如表 2 所示。可以看出本文提出的 1D-CNN 与其他模型相比能够提升 1%~5%的  $R$  系数值,降低 36%~69%的 MAE 误差,从而证明了 1D-CNN 具有良好的时间序列样本回归分析能力。

表 2 回归分析模型试验结果对比

| 模型     | 测试 $R$ 系数 | 测试 MAE  |
|--------|-----------|---------|
| 1D-CNN | 0.992 2   | 0.016 1 |
| CNN    | 0.982 2   | 0.025 3 |
| SVR    | 0.940 1   | 0.052 6 |
| DBN    | 0.976 4   | 0.028 3 |
| ANN    | 0.969 8   | 0.030 8 |

对于性能退化预测,将 RNN、GRU、LSTM 作为对比模型。考虑到时间序列预测模型具有相似的模型结构,为了保证模型的对比效果,对比模型与 Bi-LSTM 采用相同的模型参数和剩余寿命求解策略。LSTM、GRU 和 RNN 的误差变化如图 14~16 所示。可以看出 Bi-LSTM 与 LSTM、GRU 和 RNN 相比有更小的误差波动,并且最终误差分别降低了 28%、35%和 69%。




图 14 RNN 训练误差与测试误差




图 15 GRU 训练误差与测试误差




图 16 LSTM 训练误差与测试误差

根据经验设定 0.95 作为的性能退化阈值, 可以得到在前期(50 循环)、中期(100 循环)和后期(100 循环)的不同时间序列预测模型的剩余寿命预测结果, 如图 17 所示。可以看出, 本文提出的 Bi-LSTM 模型与其他模型相比能够得到更为集中的且误差较小的剩余寿命预测结果。并且在前期、中期和后期都能得到较为准确的剩余寿命预测结果。




图 17 剩余寿命预测结果对比

## 5 结论

(1) 本文针对性能退化程度未知的多状态参数时间序列数据, 在多状态参数主成分分析的基础上采用随机分布拟合, 得到了多状态参数对应的整体性能退化程度, 用作回归分析样本标签。

(2) 本文使用 1D-CNN 模型挖掘多状态参数和性能退化量之间的深层次映射关系, 从而得到实时的多状态参数对应的性能退化量。

(3) 为了预测性能退化量的变化趋势, 在采用滑动窗口和重复分割方法扩充样本的基础上, 本文使用 Bi-LSTM 模型对性能退化量进行时间序列预测。通过设定退化阈值, 并通过模型反推可以得到现有退化量和退化阈值之间的时间间隔作为剩余寿命预测结果。

(4) 通过实例验证证明了本文提出的方法与其他模型相比, 在性能退化回归分析、性能退化预测和剩余寿命预测方面都有着较低的测试误差和更准确的输出结果。本文的研究方法能够通过多维长时间序列数据的深度学习模型分析得到较为准确的剩余寿命预测结果, 对于复杂系统剩余寿命预测有重要参考价值。

## 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(20): 50-57.

[2] 马彦, 陈阳, 张帆, 等. 基于扩展  $H_{\infty}$  粒子滤波算法的动力电池寿命预测方法[J]. 机械工程学报, 2019, 55(20): 50-57.

MA Yan, CHEN Yang, ZHANG Fan, et al. Remaining useful life prediction of power battery based on extend  $H_{\infty}$  particle filter algorithm[J]. Journal of Mechanical Engineering, 2019, 55(20): 50-57.

[3] 王玺, 胡昌华, 任子强, 等. 基于非线性 Wiener 过程的航空发动机性能衰减建模与剩余寿命预测[J]. 航空学报, 2019, 41(2): 190-200.

WANG Xi, HU Changhua, REN Ziqiang, et al. Performance degradation modeling and remaining useful life prediction for aero-engine based on nonlinear wiener process[J]. Acta Aeronautica et Astronautica Sinica, 2019, 41(2): 190-200.

[4] WANG G, LIU X, ZHAO Y, et al. Neural network-based adaptive motion control for a mobile robot with unknown longitudinal slipping[J]. Chinese Journal of Mechanical Engineering, 2019, 32(4): 36-44.

[5] LIU Z, CHENG Y, WANG P, et al. A method for remaining useful life prediction of crystal oscillators using the Bayesian approach and extreme learning machine under uncertainty[J]. Neurocomputing, 2018, 305: 27-38.

[6] CHEN Z, LI Y, XIA T, et al. Hidden Markov model with auto-correlated observations for remaining useful life prediction and optimal maintenance policy[J]. Reliability Engineering & System Safety, 2019, 184: 123-136.

[7] LI X, WU S, LI X, et al. Particle swarm optimization-support vector machine model for machinery fault diagnoses in high-voltage circuit breakers[J]. Chinese Journal of Mechanical Engineering, 2020, 33(1): 104-113.

[8] WANG B, LEI Y, YAN T, et al. Recurrent convolutional neural network: A new framework for remaining useful life prediction of machinery[J]. Neurocomputing, 2020, 378: 117-129.

[9] LIU J, LI Q, CHEN W, et al. Remaining useful life prediction of PEMFC based on long short-term memory recurrent neural networks[J]. International Journal of Hydrogen Energy, 2019, 44(11): 5470-5480.

[10] AN Q, TAO Z, XU X, et al. A data-driven model for milling tool remaining useful life prediction with convolutional and stacked LSTM network[J]. Measurement, 2020, 154: 107461.



- [11] REN L, CHENG X, WANG X, et al. Multi-scale dense gate recurrent unit networks for bearing remaining useful life prediction[J]. *Future Generation Computer Systems*, 2019, 94: 601-609.
- [12] YU W, KIM Y, MECHEFSKE C. An improved similarity-based prognostic algorithm for RUL estimation using an RNN autoencoder scheme[J]. *Reliability Engineering & System Safety*, 2020, 199: 106926.
- [13] ZHAO J, MAO X, CHEN L. Speech emotion recognition using deep 1D & 2D CNN LSTM networks[J]. *Biomedical Signal Processing and Control*, 2019, 47: 312-323.
- [14] ABDOLI S, CARDINAL P, KOERICH A L. End-to-end environmental sound classification using a 1D convolutional neural network[J]. *Expert Systems with Applications*, 2019, 136: 252-263.
- [15] CHE C, WANG H, FU Q, et al. Combining multiple deep learning algorithms for prognostic and health management of aircraft[J]. *Aerospace Science and Technology*, 2019, 94: 105423.
- [16] XIA T, SONG Y, ZHENG Y, et al. An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation[J]. *Computers in Industry*, 2020, 115: 103182.
- [17] KIM B, CHUNG K, LEE J, et al. A Bi-LSTM memory network for end-to-end goal-oriented dialog learning[J]. *Computer Speech & Language*, 2019, 53: 217-230.
- [18] 车畅畅, 王华伟, 倪晓梅, 等. 基于多尺度排列熵和长短时记忆神经网络的航空发动机剩余寿命预测[J]. *交通运输工程学报*, 2019, 19(5): 106-115.  
CHE Changchang, WANG Huawei, NI Xiaomei, et al. Residual life prediction of aeroengine based on multi-scale permutation entropy and LSTM neural network[J]. *Journal of Traffic and Transportation Engineering*, 2019, 19(5): 106-115.
- [19] BOUDIAF A, MOISSAOUI A, DAHANE A, et al. A comparative study of various methods of bearing faults diagnosis using the case western reserve university data[J]. *Journal of Failure Analysis & Prevention*, 2016, 16(2): 271-284.

---

作者简介: 车畅畅, 男, 1994 年出生, 博士研究生。主要研究方向为航空发动机故障诊断和可靠性。

E-mail: 821116775@qq.com

王华伟(通信作者), 女, 1974 年出生, 博士, 教授。主要研究方向为可靠性工程、民机安全性分析。

E-mail: wang\_hw66@163.com