

# 基于深度学习方法的航空发动机寿命预测模型\*

郭晓静<sup>1</sup>, 贡玉晶<sup>2</sup>, 徐晓慧<sup>2</sup>

(1. 中国民航大学航空工程学院 天津, 300300)

(2. 中国民航大学电子信息与自动化学院 天津, 300300)

**摘要** 为提高航空发动机剩余寿命(remaining useful life, 简称 RUL)预测能力, 构建了一种注意力机制与长短期记忆网络(long short-term memory, 简称 LSTM)融合的深度学习方法。首先, 分析多元高维的运行参数与 RUL 之间的协方差相关性, 实现数据降维, 优化模型权重; 其次, 利用运行参数的时序退化特性提高模型的回归预测效果。在 NASA 发动机数据集上实验的均方根误差(root mean square error, 简称 RMSE)范围为[4.83, 13.66], 与卷积神经网络(convolution neural networks, 简称 CNN)、LSTM 和双向长短期记忆网络(bi-directional long short-term memory, 简称 Bi-LSTM)方法相比, 极大地提高了预测的准确度, 实现了超前预测。合并样本的方法提高了模型的泛化性, 对不同类型的发动机 RUL 预测具有指导意义。

**关键词** 航空发动机; 剩余寿命预测; 协方差分析; 注意力机制; 长短期记忆网络

**中图分类号** TH17; TP183; V23

## 引言

航空发动机的运行状态对于飞行安全至关重要, 剩余寿命预测和故障诊断技术逐步成为发动机健康管理(prognostics and health management, 简称 PHM)研究中的两大热点<sup>[1]</sup>。航空发动机运行参数呈现出高维多元的特点。此外, 与故障诊断研究不同, 寿命预测研究属于典型的回归预测问题, 运行参数具有时序退化性能。根据已有运行参数进行发动机剩余寿命预测, 有利于降低人为因素带来的维修隐患, 对设备安全使用意义重大。

多源传感器融合技术为剩余寿命预测问题提供了解决方案, 所采用的研究方法从卡尔曼滤波<sup>[2]</sup>、支持向量机<sup>[3]</sup>和隐马尔科夫模型<sup>[4]</sup>, 再到神经网络<sup>[5]</sup>、受限玻尔兹曼机<sup>[6]</sup>和融合模型<sup>[7]</sup>等, 可以归为 3 类, 分别是基于数据驱动的统计学方法、传统机器学习方法以及深度学习方法。基于数据驱动的统计学方法采用全部历史数据构建拟合预测函数进行寿命预测, 简便直观, 但受目标函数、约束函数选择影响, 容易导致过拟合或欠拟合。传统机器学习方法在高维多元数据分析方面具有明显优势, 但是数据特征提取过程需要人工干预, 在模型的泛化性方面表现一般。深度学习方法通过海量数据训练模型, 描述

输入参数对输出结果的影响权重, 采用测试集验证模型的有效性。深度学习已成功应用在寿命预测<sup>[8]</sup>、故障诊断、图像识别及机器翻译等领域, 因而采用深度学习方法研究航空发动机寿命预测问题成为当前主要的研究方向。

构建基于深度学习的回归预测模型需要改善模型的平均预测精度和收敛性, 提高模型泛化性。Hinton 等<sup>[9]</sup>针对多层隐藏层网络参数学习困难的问题, 提出通过贪婪逐层预训练方法来解决梯度弥散和局部极值。Heimes<sup>[10]</sup>采用循环神经网络(recurrent neural networks, 简称 RNN)结构实现剩余寿命的预测, 通过扩展卡尔曼滤波训练和演化算法进行反向传播, 其预测结果明显优于多层感知机(multi-layer perceptron, 简称 MLP)方法, 但模型权重训练仅考虑了当前输入序列。Tian<sup>[11]</sup>开发了一种用于预测设备剩余寿命的多层人工神经网络(artificial neural network, 简称 ANN)模型, 将多维监测数据作为输入, 设备剩余寿命与全寿命占比作为输出, 但 ANN 结构仅对数据在高维空间中做拟合, 没有考虑数据的时间特征, 在预测轴承的 RUL 中, 准确性受输入数据的时间序列影响较大。Zhang 等<sup>[12]</sup>提出通过集成多目标优化下的深度置信网络(deep belief network, 简称 DBN)模型来提取传感器数据中的深

\* 中央高校基本科研业务费专项资金资助项目(3122020026)

收稿日期: 2022-06-22; 修回日期: 2022-09-03

层特征,从而实现设备 RUL 预测,但 DBN 本身并没有学习数据中时序特征的能力。Li 等<sup>[13]</sup>提出了一种基于深度 CNN 的多变量设备剩余寿命估计方法,在 C-MAPSS 数据集中的 RMSE 结果为 12.61,但是部分有效信息被池化操作所滤除。Yu 等<sup>[14]</sup>提出无中心化相似性匹配,该方法在 C-MAPSS 数据集中 Score 指标明显降低,但是通过去中心化来达到时间序列的高度匹配,影响数据真实性而使得 RMSE 的误差变大。

上述研究通常针对设备参数的高维或时序性特点中的一个方面进行寿命预测,但随着对检测准确度要求的提高,以及时序数据序列长度扩大,所建立的模型需要从长时间序列数据中实现数据特征提取。为了解决 RUL 预测中的高维数据特征提取与时序数据预测两方面问题,笔者基于数据的协方差相关性分析,提出了一种融合注意力机制与 LSTM 的深度学习网络模型,实现了对高维时序数据的特征权重分配及优化,提高了预测的准确性。

### 1 寿命预测问题描述

假设航空发动机运行参数的全序列数据为  $n$  维,长度为  $T$ ,则全序列数据集  $X$  和第  $t$  时刻多源数据  $x_t$  可分别表示为

$$X = (x_1, x_2, \dots, x_t, \dots, x_T) \quad (1)$$

$$x_t = (x_t^1, x_t^2, \dots, x_t^k, \dots, x_t^n)^T \quad (2)$$

其中:  $X \in R^{n \times T}$ ;  $x_t \in R^{n \times 1}$ ;  $x_t^k \in R$ , 为第  $k$  个传感器  $t$  时刻的检测数据。

全序列数据对应的剩余寿命真实值  $Y$  为

$$Y = (y_1, y_2, \dots, y_t, \dots, y_T) \quad (3)$$

其中:  $Y \in R^{n \times T}$ ;  $y_t \in R^{n \times 1}$  为剩余寿命对应的剩余周期数。

发动机寿命预测具有明显的健康退化特征,  $t$  时

刻的剩余寿命预测值  $\hat{y}_t$  能够依赖于前  $t-1$  个序列、寿命以及  $t$  时刻的多源数据  $x_t$  获得,即

$$\hat{y}_t = F(x_1, x_2, \dots, x_{t-1}, x_t, y_1, y_2, \dots, y_{t-1}) \quad (4)$$

回归预测模型的输入到输出是具有长周期序列依赖的非线性关系,航空发动机剩余寿命预测问题如图 1 所示。

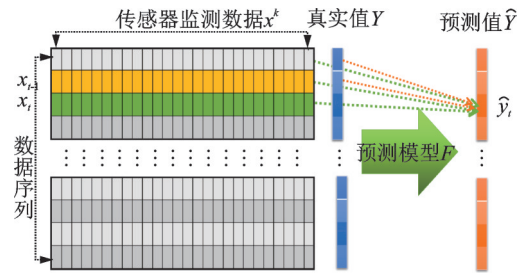


图 1 航空发动机剩余寿命预测问题示意图

Fig.1 Schematic diagram of aero-engine remaining useful life prediction problem

构建航空发动机寿命预测模型,关键在于源域的选择和权重矩阵的优化。与剩余寿命关联度较高的运行参数在预测模型  $F$  中对应权值较大,与剩余寿命关联度较小的运行参数在预测模型  $F$  中对应权值较小。这一过程主要解决 3 方面问题:①量化分析多元时序数据之间的相关性,优化权重;②采用时序处理结构,提高回归预测精度;③分析不同工况、故障模式的样本规模对剩余寿命的影响作用,丰富样本量,防止欠拟合。

### 2 建模理论依据

#### 2.1 多元时序数据相关性

C-MAPSS 数据集如表 1 所示,是 NASA 故障预测研究中心公开的涡轮发动机运行状态仿真数据集,包含训练集和测试集,每一类有 4 组样本 (FD001~FD004),每组样本量各不相同。多元高

表 1 C-MAPSS 数据集

Tab.1 Data sets of C-MAPSS

数据集	数据样本	样本量/发动机数	故障模式	运行工况	寿命周期最大值	寿命周期最小值
训练数据	train_FD001	20 631 / 100	HPC	1	362	128
	train_FD002	53 750 / 260	HPC	6	378	128
	train_FD003	24 720 / 100	HPC+Fan	1	525	145
	train_FD004	61 249 / 249	HPC+Fan	6	543	128
测试数据	test_FD001	13 096	HPC	1	—	—
	test_FD002	33 991	HPC	6	—	—
	test_FD003	16 596	HPC+Fan	1	—	—
	test_FD004	41 214	HPC+Fan	6	—	—

HPC 为高压压气机;Fan 为风扇叶片


维的数据样本来源于涡轮发动机运行状态检测数据,每组样本有26维,其中21维对应的发动机多元运行参数物理量如表2所示,剩余5维分别表示发动机台号、时间序列、故障模式和运行工况。

表2 C-MAPSS数据集21维传感器数据物理量

Tab.2 Actual value of 21 dimensions sensor data in data set of C-MAPSS


传感器编号	物理描述	传感器编号	物理描述
1	风扇进口温度	12	燃油量与高压压气机出口静压的比率
2	低压压气机出口温度	13	修正风扇转速
3	高压压气机出口温度	14	修正转速
4	低压涡轮出口温度	15	涵道比
5	风扇进口压强	16	燃烧器油气比
6	外涵道压强	17	抽汽焓
7	高压压气机出口压强	18	风扇转速
8	实际风扇转速	19	风扇修正转速
9	实际核心机转速	20	高压涡轮冷气流量
10	发动机压强比	21	低压涡轮冷气流量
11	高压压气机出口静压		

21维发动机运行参数大致可分为4类:温度、压强、转速和流量。从样本量最大的train\_FD004中取1台发动机检测数据,分析其传感器监测数据与RUL的曲线,如图2所示。每类曲线均呈现非单调变化,且有一定周期性,但4类曲线变化规律无明显相似,这说明传感器监测数据与RUL值之间的相关性在同类别中和类别之间均有不同。该结论对FD001~FD003数据集仍然成立。




(a) 温度传感器与RUL的曲线图

(a) Curve diagram of temperature sensors and RUL



(b) 压强传感器与RUL的曲线图


(b) Curve diagram of pressure sensors and RUL



发动机检测序列

(c) 转速传感器与RUL的曲线图

(c) Curve diagram of speed sensors and RUL



发动机检测序列

(d) 流量传感器与RUL的曲线图

(d) Curve diagram of flow sensors and RUL

图2 train\_FD004中传感器监测数据与RUL的曲线

Fig.2 Curve of sensor monitoring data of train\_FD004 and RUL

## 2.2 多元数据与剩余寿命的相关性

多元数据与剩余寿命的相关性可采用协方差进行量化计算,即

$$\text{cov}(x^k, Y) = E((x^k - E(x^k))(Y - E(Y))) \quad (5)$$

$$\rho(x^k, Y) = \frac{\text{cov}(x^k, Y)}{\sqrt{D(x^k)D(Y)}} \quad (6)$$

其中: $k$ 为数据维数; $Y$ 为发动机剩余寿命; $E(x^k)$ ,  $D(x^k)$ 分别为第 $k$ 维数据的均值和方差; $E(Y)$ ,  $D(Y)$ 分别为剩余寿命的均值和方差。

4组训练集相关系数如图3所示。其中,散点代表21维数据,散点编号与表2运行参数编号一致,红色虚线标识相关系数为0的参考线。train\_FD001中存在4个与RUL相关系数为0的传感器,train\_FD003中有2个与RUL相关系数为0的传感器,train\_FD002和train\_FD004中没有与RUL相关系数为0的传感器,各组相关系数为0的传感器分布不同。不同训练样本在相关系数分布上呈现明显的不对称性,散点位置距离0参考线越远,相关性权重越大;多数传感器与RUL呈现负相关。

此外,各组传感器数据与RUL的相关性有区段度,相关系数为0的传感器参数意味着在相应样本训练时可作剪枝或丢弃。根据单一数据集建模会导致模型预测结果欠拟合或过拟合,影响模型泛化性,降低寿命预测准确性。

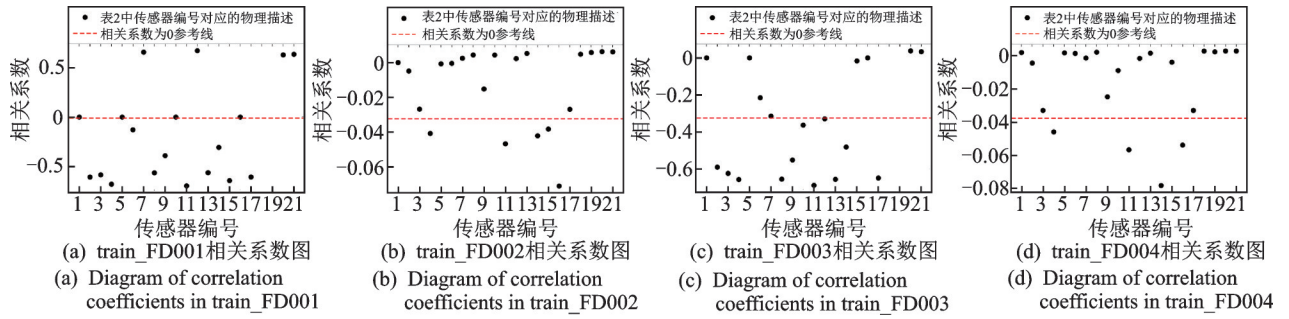


图3 4组训练集相关系数

Fig.3 Diagram of correlation coefficients in four training data sets

### 2.3 样本扩增分析相关性

为使模型实现对未来不确定输入数据的准确预测,将4组训练样本合并为1组,合并样本包含4组不同运行工况和故障模式的数据特征。与表1所示原始分组数据训练样本相比,合并训练样本数据扩增为160 350个样本量(709台发动机)在多种故障模式和运行工况下的传感器监测数据。

对合并数据进行相关性分析,合并训练集相关系数如图4所示。21个传感器中有11个传感器的数据与RUL呈正相关,剩余10个传感器不同程度地与RUL呈负相关。合并数据将原来各组数据中与RUL不相关(相关系数为0)的传感器变为弱相关(相关系数不为0)。




图4 合并训练集相关系数

Fig.4 Diagram of correlation coefficients in integrated training data sets

## 3 注意力机制与LSTM的融合模型

### 3.1 融合注意力机制与LSTM的结构

LSTM单元通过“门控”机制来调整信息传递过程中的记忆状态,实现对时序信息的选择性遗忘或保留,但是LSTM单元更新记忆信息的过程对所有数据序列无差别更新,因此LSTM单元不具备特征提取能力。融合注意力机制与LSTM的结构如图5所示,可实现对序列特征的提取和权重分配。

通过 $t$ 时刻初始序列 $x_t$ 与前一时刻的传感器监测数据对应的初始隐藏序列 $h_{t-1}$ ,计算得到每个传感器的权重得分为

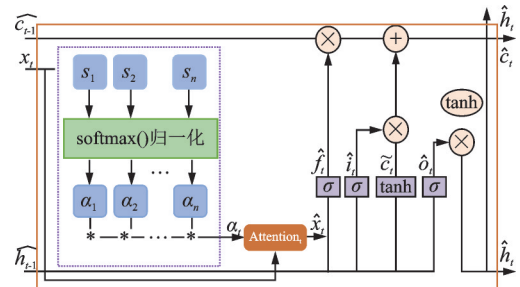


图5 融合注意力机制与LSTM的结构示意图

Fig.5 Structural diagram of fusing attention mechanism and LSTM

$$s_i^k = V_s^T \tanh(W_s [h_{t-1}, x_t]) \quad (7)$$

其中: $s_i^k$ 为 $t$ 时刻第 $k$ 维个传感器的相似性得分; $V_s$ 、 $W_s$ 为训练参数; $h_{t-1}$ 为 $t-1$ 时刻的初始隐藏序列; $x_t$ 为 $t$ 时刻序列数据的输入。

引入softmax将得分转换为权重之和为1的概率分布,概率最大的即为该传感器对应的权重,从而得到序列数据的注意力编码向量 $A_t$ 为

$$\alpha_i^k = \exp(s_i^k) / \sum_{i=1}^n \exp(s_i^k) \quad (8)$$

$$A_t = (\alpha_1^t, \alpha_2^t, \dots, \alpha_n^t, \dots, \alpha_n^t) \quad (9)$$

其中: $\alpha_i^k$ 为 $t$ 时刻第 $k$ 维数据的权重分布; $i$ 为传感器序号。

取注意力编码向量 $A_t$ 与原始输入序列 $x_t$ ,经过向量运算得到包含权重信息的输入序列,即

$$\hat{x}_t = A_t \circ x_t \quad (10)$$

其中: $k$ 为序列的维数; $t$ 为序列时刻; $\circ$ 为向量乘法运算。

将包含权重的序列数据 $\hat{x}_t$ 作为输入,经过如式(11)~(15)所示的LSTM处理,得到包含权重信息的序列输出。

$$\hat{f}_t = \sigma(W_f [\widehat{h}_{t-1}, \widehat{x}_t] + b_f) \quad (11)$$

$$\hat{i}_t = \sigma(W_i [\widehat{h}_{t-1}, \widehat{x}_t] + b_i) \quad (12)$$

$$\hat{c}_t = f_t \circ \widehat{c}_{t-1} + \hat{i}_t \circ \tanh(W_c [\widehat{h}_{t-1}, \widehat{x}_t] + b_c) \quad (13)$$

$$\hat{o}_t = \sigma(\mathbf{W}_o[\widehat{\mathbf{h}}_{t-1}, \widehat{\mathbf{x}}_t] + \mathbf{b}_o) \quad (14)$$

$$\hat{\mathbf{h}}_t = \hat{o}_t \circ \tanh(\widehat{\mathbf{c}}_t) \quad (15)$$

其中： $\widehat{\mathbf{f}}_t$ 为对 $t-1$ 时刻选择性遗忘后的信息； $\sigma$ 为sigmoid非线性激活函数； $\mathbf{W}$ 、 $\mathbf{b}$ 为训练参数； $\widehat{\mathbf{h}}_{t-1}$ 为 $t-1$ 时刻输出的隐藏状态； $\widehat{\mathbf{i}}_t$ 为 $t$ 时刻保留的输入信息； $\widehat{\mathbf{c}}_t$ 为 $t$ 时刻的记忆状态； $\tanh$ 为双曲正切激活函数； $\circ$ 为向量乘法运算； $\widehat{\mathbf{o}}_t$ 为 $t$ 时刻的输出信息； $\hat{\mathbf{h}}_t$ 为 $t$ 时刻基于记忆信息处理后对传感器数据的输出隐藏状态。

### 3.2 网络模型

采用融合注意力机制与LSTM结构的预测模型如图6所示,主要包括数据分析、数据预处理、模型训练和预测4个模块。

数据分析模块基于C-MAPSS航空发动机仿真模型,分析传感器监测数据与剩余寿命之间的相关性,分别对4组训练样本进行降维。

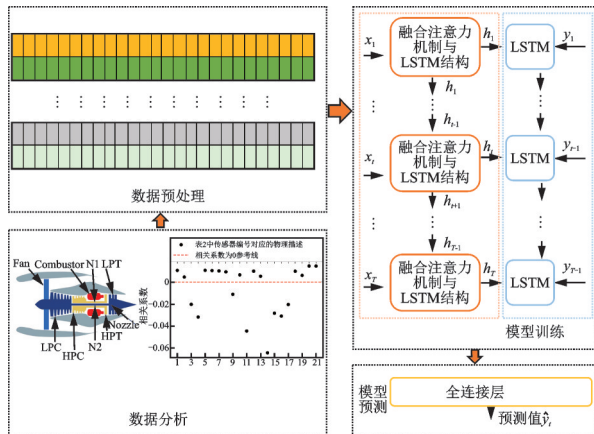


图6 融合注意力机制与LSTM结构的预测模型

Fig.6 Network model diagram combining attention mechanism and LSTM

数据预处理模块对降维后的序列归一化,以滑动窗口方式向模型输入高维序列数据。

模型训练模块包含编码和解码两部分。编码部分由提出的融合注意力机制与LSTM结构对输入序列进行处理,得到包含权重信息的隐藏编码序列;解码部分由LSTM结构进行解码。训练过程中依据RUL标签对模型进行参数优化。

预测模块基于训练模型结构和参数,经过全连接层得到预测的RUL。

## 4 实验及结果分析

### 4.1 实验设计

将21维传感器检测数据作为输入,以训练集中

寿命的逆序值作为RUL标签。基于数据分析在提出的网络模型上开展2类实验:①合并4组训练样本为1组,包含的样本量为160 350,训练后进行预测;②分别对4组样本进行训练和预测。

#### 4.1.1 数据归一化

航空发动机状态参数呈现多元性,量纲不统一,数据区间差异较大,训练耗时且不易收敛。对输入数据作归一化处理,经过处理后的数据范围为 $[0, 1]$ 。归一化方法为

$$x_t^{k'} = \frac{x_t^k - \min(x^k)}{\max(x^k) - \min(x^k)} \quad (16)$$

其中： $x_t^{k'}$ 为经过归一化处理后的第 $t$ 个序列中第 $k$ 维数据的值； $x_t^k$ 为原始数据中第 $t$ 个序列中第 $k$ 个维数据的值； $\min(x^k)$ 、 $\max(x^k)$ 分别为第 $k$ 维数据的最小值和最大值。

#### 4.1.2 滑动窗口处理

基于航空发动机传感器监测数据的长周期性,采用滑动窗口方法按一定步长和窗口大小动态读取数据,直至遍历完数据序列。实验设置的步长为1,窗口大小为10。图7为合并训练集中的传感器检测数据经过归一化处理后的滑动窗口示意图。某一时刻中窗口划过的传感器数据形成高维向量,用作模型的输入。




图7 滑动窗口示意图

Fig.7 Schematic of the sliding window

#### 4.1.3 衡量指标

均方根误差用来衡量样本预测值与真实值之间的平均偏离程度,评价模型预测的准确性,即

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (17)$$

其中： $n$ 为样本量； $\hat{y}_i$ 为预测值； $y_i$ 为真实值。

采用不对称得分函数(Score)评价模型超前预测效果,即

$$\text{Score} = \begin{cases} \sum_{i=1}^n e^{\left(\frac{d}{a_1}\right)} - 1 & (d \geq 0) \\ \sum_{i=1}^n e^{-\left(\frac{d}{a_2}\right)} - 1 & (d < 0) \end{cases} \quad (18)$$

其中： $n$ 为预测样本量； $d = \hat{y}_i - y_i$ ； $a_1 = 10$ ； $a_2 = 13$ 。

当  $d < 0$  时,预测值小于真实值,表示超前预测;当  $d \geq 0$  时,测试值大于真实值,表示滞后预测。该函数对超前预测和滞后预测分别用不同的参数来区分。对寿命后期的预测重要性大于寿命前期,即超前预测有利于及时发现设备隐患,提前进行维护。

### 4.2 实验结果

#### 4.2.1 数据集合并实验与分组实验

2类实验在4组测试样本中的均方根误差如表3所示,实验1(合并训练)对4组测试样本的预测结果均优于分组训练,合并训练包含的训练样本更加丰富,相关特征更加充分。模型能够解决对未来输入数据不确定的问题,提高预测的准确性和模型的泛化性。

表 3 2类实验在4组测试样本中的均方根误差

测试数据集	实验1(合并训练)	实验2(分组训练)
test_FD001	5.43	6.68
test_FD002	4.83	5.53
test_FD003	13.66	16.12
test_FD004	8.41	10.33

实验1对 test\_FD001 的预测情况见图8,整体预测良好。4组测试样本中最大的测试样本量为41 214,说明模型能够解决长序列预测的回归问题。

从实验1预测的4组测试样本中各任取1台发动机,其预测情况如图9所示。其中:图9(a)发动机寿命周期最短为216,预测误差范围为 $[-5, -3.37]$ ;图9(c)发动机寿命周期最长为483,预测误




图 8 实验1对 test\_FD001 的预测情况

Fig.8 The prediction of test\_FD001 in experiment one

差范围为 $[-104.61, -2.67]$ 。寿命周期长度不同,预测效果存在差异。寿命衰退过程中预测误差  $d$  始终小于0( $d = \text{预测值} - \text{真实值}$ ),随着时间推移, $d$  的绝对值变小,说明整体为超前预测,而且在寿命后期准确性更高。

#### 4.2.2 对比实验

针对 C-MPASS 数据集,将本研究的方法与常用的 CNN, LSTM 及 BiLSTM 预测方法进行对比,结果如表4所示。RMSE 指标在 test\_FD002 中最低,为4.83;在 test\_FD003 中最高,为13.66;test\_FD002 的 RMSE 指标相较于 CNN<sup>[15]</sup>, LSTM<sup>[16]</sup> 和 BiLSTM 分别减少了84%,83%和89%,明显优于其他方法。Score 指标与 BiLSTM 方法相比也较优,在 test\_FD001 中最低,为6 281;在 test\_FD004 中最高,为948 407。

构建的回归预测模型从 RMSE 指标来看,均优于其他方法,其中合并训练的预测准确度高于分组训练,提高了预测的准确性。从 Score 指标来看,实现了超前预测。

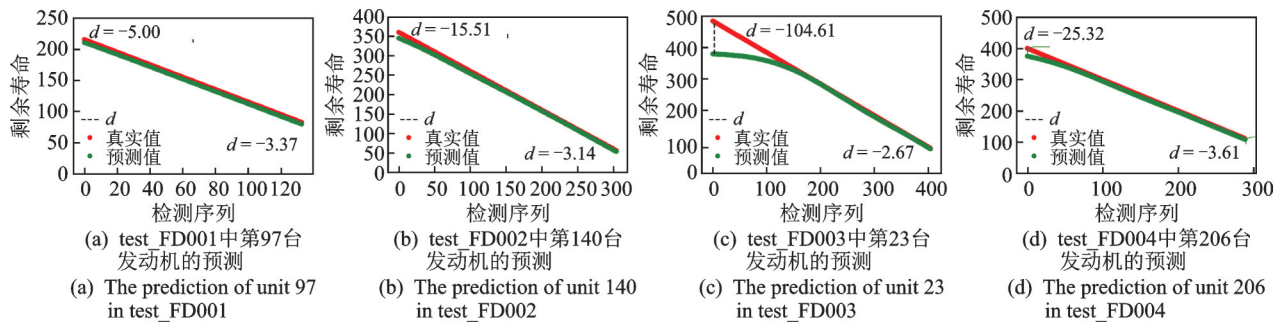


图 9 实验1对4组测试集中任意1台发动机的预测情况

Fig.9 The prediction for one unit of 4 test samples in experiment one

表 4 不同方法结果对比

测试数据集	CNN <sup>[15]</sup>		LSTM <sup>[16]</sup>		BiLSTM		本研究方法	
	RMSE	Score	RMSE	Score	RMSE	Score	RMSE	Score
test_FD001	18.45	1 286.7	16.73	388.68	28.35	4 111	5.43	6 281
test_FD002	30.29	1 357.0	29.43	10 654.00	47.14	103 980	4.83	12 674
test_FD003	19.82	1 596.2	18.07	822.19	37.15	24 750	13.66	182 740
test_FD004	29.16	7 886.4	28.40	6 730.60	58.85	566 019	8.41	948 407

## 5 结论

1) 航空发动机的传感器检测数据具有高维、异构和时序特点,采用相关性分析的数据处理方法实现了对高维数据不同影响程度的区分。

2) 基于注意力机制的权重分配和LSTM处理时序数据的能力,构建的融合模型提高了预测的准确度。可用于解决同类型的回归问题。

3) 为了实现对不同运行工况下的航空发动机剩余寿命进行预测,合并扩增训练数据集的结果与分组训练的效果相比有明显提升。

4) 鉴于超前预测依然存在一定的误差,后续将结合数据相关性,进一步优化注意力权重分配,以提高超前预测的能力。

## 参 考 文 献

- [1] ZIO E. Prognostics and health management (PHM): where are we and where do we (need to) go in theory and practice [J]. *Reliability Engineering & System Safety*, 2022, 218: 108119.
- [2] CUI L L, WANG X, XU Y G, et al. A novel switching unscented kalman filter method for remaining useful life prediction of rolling bearing [J]. *Measurement*, 2019, 135: 678-684.
- [3] KHELIF R, CHEBEL-MORELLO B, MALINOWSKI S, et al. Direct remaining useful life estimation based on support vector regression [J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(3): 2276-2285.
- [4] KUMAR A, CHINNAM R B, TSENG F. An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools [J]. *Computers & Industrial Engineering*, 2019, 128: 1008-1014.
- [5] YAN H H, WAN J F, ZHANG C H, et al. Industrial big data analytics for prediction of remaining useful life based on deep learning [J]. *IEEE Access*, 2018, 6: 17190-17197.
- [6] HOU M R, PI D C, LI B R. Similarity-based deep learning approach for remaining useful life prediction [J]. *Measurement*, 2020, 159: 107788.
- [7] 赵志宏, 李晴, 李春秀. 基于卷积GRU注意力的设备剩余寿命预测 [J]. *振动、测试与诊断*, 2022, 42(3): 572-579.  
ZHAO Zhihong, LI Qing, LI Chunxiu. Remaining useful life prediction based on ConvGRU-attention method [J]. *Journal of Vibration, Measurement & Diagnosis*, 2022, 42(3): 572-579.(in Chinese)
- [8] 王玉静, 李少鹏, 康守强, 等. 结合CNN和LSTM的滚动轴承剩余使用寿命预测方法 [J]. *振动、测试与诊断*, 2021, 41(3): 439-446.  
WANG Yujing, LI Shaopeng, KANG Shouqiang, et al. Method of predicting remaining useful life of rolling bearing combining CNN and LSTM [J]. *Journal of Vibration, Measurement & Diagnosis*, 2021, 41(3): 439-446.(in Chinese)
- [9] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [10] HEIMES F O. Recurrent neural networks for remaining useful life estimation [C] // 2008 International Conference on Prognostics and Health Management. Denver: IEEE, 2008: 1-6.
- [11] TIAN Z G. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring [J]. *Journal of Intelligent Manufacturing*, 2012, 23(2): 227-237.
- [12] 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*, 2017, 28(10): 2306-2318.
- [13] 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: 1-11.
- [14] YU W N, KIM I 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.
- [15] BABU G S, ZHAO P L, LI X L. Deep convolutional neural network based regression approach for estimation of remaining useful life [C] // Database Systems for Advanced Applications. Dallas: Springer, 2016: 214-228.
- [16] 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). Dallas: IEEE, 2017: 88-95.



第一作者简介:郭晓静,女,1980年11月生,硕士、副教授。主要研究方向为智能检测及图像处理。

E-mail: 13820869553@139.com