

# 基于数据融合与GRU的航空发动机剩余寿命预测

李路云<sup>1</sup>, 王海瑞<sup>1</sup>, 朱贵富<sup>2\*</sup>

(1. 昆明理工大学信息工程与自动化学院, 昆明, 650500;

2. 昆明理工大学信息化建设管理中心, 昆明, 650500)

**摘要** 针对深度学习构造复合健康指标可解释性差, 预测结果难以量化发动机剩余寿命预测中的不确定性问题, 提出一种基于数据融合与门控循环单元(GRU)的航空发动机剩余寿命预测方法。首先, 将多源传感器数据加权融合构造一维复合健康指标; 然后, 利用 Bootstrap 方法对一维复合健康指标进行有放回抽样, 获取  $n$  组发动机退化特征样本; 最后, 利用一维复合健康指标和  $n$  组发动机退化特征样本构建“ $n+1$ ”个基于 GRU 的剩余寿命预测模型, 实现对航空发动机剩余寿命的区间预测。为证明所提方法的可行性和优越性, 采用涡扇发动机退化数据集(C-MAPSS)的数据进行实验, 得到的均方根误差为 15.825 4, 评分函数值为 344.210 5。结果表明, 该方法不仅能获得较好的预测效果, 还能有效解决深度学习在发动机剩余寿命预测中存在的缺陷。

**关键词** 航空发动机; 寿命预测; 维纳过程; 多源传感器数据融合; 自助法; 门控循环单元

**DOI** 10.3969/j.issn.2097-1915.2022.06.005

**中图分类号** V263.5 **文献标志码** A **文章编号** 2097-1915(2022)06-0033-09

## A Remaining Useful Life Prediction of Aero-Engine Based on Data Fusion and GRU

LI Luyun<sup>1</sup>, WANG Hairui<sup>1</sup>, ZHU Guifu<sup>2\*</sup>

(1. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. Information Construction Management Center, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract** Aimed at the problems that interpretable ability of composite health indicators constructed by deep learning is poor, and the prediction results are difficult to quantify the uncertainty of engine remaining life, an aero-engine remaining life prediction method based on data fusion and gate recurrent unit (GRU) is proposed. Firstly, the one-dimensional composite health index is constructed by weighted fusion of multi-source sensor data. And then, the Bootstrap method is utilized for putting the samples back on the one-dimensional composite health index, obtaining the engine degradation characteristic samples of  $n$ -groups. Finally, “ $n+1$ ” remaining life prediction models based on GRU are constructed by using one-dimensional composite health indicators and the  $n$ -groups of engine degradation characteristic samples, the

**收稿日期**: 2022-07-09

**基金项目**: 国家自然科学基金(61863016)

**作者简介**: 李路云(1997—), 女, 云南昆明人, 硕士生, 研究方向为发动机剩余寿命预测。E-mail: 1475714011@qq.com

**通信作者**: 朱贵富(1984—), 男, 江西赣州人, 工程师, 研究方向为机器学习、智能技术。E-mail: zhuguifu@kust.edu.cn

**引用格式**: 李路云, 王海瑞, 朱贵富. 基于数据融合与 GRU 的航空发动机剩余寿命预测[J]. 空军工程大学学报, 2022, 23(6): 33-41. LI Luyun, WANG Hairui, ZHU Guifu. A Remaining Useful Life Prediction of Aero-Engine Based on Data Fusion and GRU[J]. Journal of Air Force Engineering, 2022, 23(6): 33-41.

prediction interval of engine remaining life is quantified. In order to prove the feasibility and superiority of the proposed method, the turbofan engine degradation dataset (C-MAPSS) is used for the experiment, and the root mean square error obtained is 15.825 4, the score function value is 344.210 5. The results show that this method can not only achieve the better prediction results, but also can effectively solve the defects of deep learning in engine remaining life prediction.

**Key words** aero-engines; life prediction; wiener process; multi-source sensor data fusion; bootstrap; gate recurrent unit

航空发动机是飞机的核心部件,它的健康状况关系到飞机的安全性与经济性,对它进行准确合理的预测性维护就相当重要。利用传感器采集技术和先进智能技术对发动机的剩余寿命进行预测,就成了预测性维护工作中的关键一环。

随着“大数据”时代的到来,数据驱动的方法逐渐成为剩余寿命预测的主流方法<sup>[1]</sup>。任子强等将多源传感器数据融合成一维复合健康指标,再利用线性 Wiener 过程对一维复合健康指标进行退化建模<sup>[2]</sup>。虽然随机退化模型有较强的可解释性,但预测精度还有待提高。Li 等采用 SFS 算法优化了 SVR 中的超参数,实现了滚动轴承的剩余寿命预测<sup>[3]</sup>。浅层机器学习难以充分提取设备的退化特征,在预测准确性和鲁棒性方面,深度学习更具优势<sup>[4]</sup>。为获得更高的预测精度,马忠等利用改进的 CNN 对航空发动机的剩余寿命进行预测<sup>[5]</sup>。Kong 等提出了一种 DCNN 与 LSTM 相结合的方法,同时使用贝叶斯优化算法对两个网络的超参数进行优化,有效提高了锂离子电池的剩余寿命预测精度<sup>[6]</sup>。以上方法虽然获得了较好的预测效果,但并未对预测中的不确定性进行量化。航空发动机工作环境复杂,采集到的退化数据不可避免地会受到噪声的污染,为使预测结果更接近现实,应对预测中的不确定性进行量化<sup>[7]</sup>。Sun 等将 MC Dropout 技术应用于多尺度卷积神经网络中,实现了滚动轴承剩余寿命的区间预测<sup>[8]</sup>。该方法有效量化了滚动轴承剩余寿命预测中的不确定性,但这种不确定性依赖于网络结构,无法保证预测结果的可靠性。李浩等利用 SAE 构造健康指标,将提取后的健康指标放入基于 BiLSTM 构建的 DeepAR 模型中进行剩余寿命预测<sup>[9]</sup>。该方法实现了发动机剩余寿命的区间预测,但是通过 SAE 构造的健康指标依然存在可解释性差的弊端。

利用深度学习进行寿命预测可获得较高的预测精度,但通过模型构造的健康指标和模型的可解释性成了一个巨大的挑战<sup>[10]</sup>。数理统计的方法可解释性强,但处理大数据的能力还有待提高。于是,专家们开始提出一种将深度学习与数理统计相结合的剩余寿命预测方法。Liu 等利用 PCA 提取隐藏在原始传感器数据中的关键特征,再构建一个由 Wie-

ner 过程、LSTM、XGBoost 等构成的动态多阶段组合预测模型实现对航空发动机的剩余寿命预测<sup>[11]</sup>。彭开香等采用 DBN 构造健康指标,再利用 HMM 模型实现对航空发动机的剩余寿命预测<sup>[12]</sup>。以上两种方法结合了深度学习和数理统计两者的优点,互相弥补彼此的不足,但这样的结合仍然存在两大缺陷:一是利用深度学习模型构造的健康指标可解释性差;二是提取的健康指标和随机模型是否匹配也是一个需要解决的问题<sup>[13]</sup>。

基于以上分析,本文提出一种融合数理统计与深度学习的新型航空发动机剩余寿命预测方法。一方面,利用 Wiener 过程建立退化模型,将模型预测寿命和真实寿命之间的偏差作为优化目标函数,形成复合健康指标提取与随机退化建模的反馈闭环,经过多次优化调整得到融合系数的最优解,再利用融合系数的最优解将多源传感器数据进行加权融合,构造一个解释性强的一维复合健康指标<sup>[13]</sup>。另一方面,利用一维复合健康指标和 Bootstrap 方法构建  $n$  个基于 GRU 的集成回归模型和 1 个基于 GRU 的预测误差模型,最终得到航空发动机剩余寿命的区间预测,有效解决了深度学习模型中预测结果不确定性难以量化的问题,为实际工程问题提供了一种新的解决思路。

## 1 理论基础

### 1.1 健康指标的构造

航空发动机是一种复杂的大型机械设备,仅依靠单一传感器监测数据并不能全面有效地表征发动机的健康状态,需要将多源传感器监测数据进行融合,充分提取所有监测数据中的退化特征,从而准确预测发动机的剩余寿命<sup>[14]</sup>。本实验选用的训练集包含 100 个发动机从开始运行至失效的完整状态数据,测试集包含 100 个发动机失效前某一段时间内的非完整监测数据。每个发动机的退化数据都是由 21 维传感器监测得到的,这些退化数据具有大规模、高维度、非完整的特点。为充分提取所有监测数据中的退化特征,本文参考和借鉴文献<sup>[13]</sup>的方法,将能够体现发动机退化趋势的 14 维传感器数据进

行加权融合,构造一个可解释性强的健康指标。

### 1.1.1 多源传感器数据加权融合

利用式(1)构造一维复合健康指标:

$$F_m(t) = \sum_{b=1}^S x_{m,b}(t) \omega_b \quad (1)$$

式中: $S$ 为传感器的个数; $\omega_b$ 为第 $b$ 个传感器数据的融合系数; $x_{m,b}(t)$ 表示第 $m$ 个发动机的第 $b$ 个传感器在 $t$ 时刻采集到的退化数据。

第 $m$ 个发动机对应的监测时间记作 $t_m$ ,则复合健康指标对应的观测数据记作 $f_m$ ,如式(2)、式(3)所示。

$$t_m = \{t_{m,0}, t_{m,1}, t_{m,2}, \dots, t_{m,K_m}\} \quad (2)$$

$$f_m = \{f_{m,0}, f_{m,1}, f_{m,2}, \dots, f_{m,K_m}\} \quad (3)$$

式中: $f_{m,k} = F_m(t_{m,k}), k=0, 1, 2, \dots, K_m$ ;  $K_m$ 为第 $m$ 个发动机的监测数据个数,  $\Delta t = t_{m,k} - t_{m,k-1}$ 。

### 1.1.2 利用 Wiener 过程退化建模

利用线性 Wiener 过程对复合健康指标进行建模。模型描述如下:

$$F_m(t) = f_{m,0} + \lambda_m t + \sigma_m B(t) \quad (4)$$

式中: $f_{m,0}$ 为第 $m$ 个发动机在 $t_{m,0}=0$ 时刻的初始退化量; $\lambda_m$ 为漂移系数,反应了第 $m$ 个发动机的退化率; $\sigma_m$ 为第 $m$ 个发动机的扩散系数,刻画退化过程的随机不确定性; $B(t)$ 为反映退化过程时变随机性的标准 Brownian 运动。

### 1.1.3 求解融合系数

构建如下式所示表征预测效果的优化目标函数:

$$J(W, \nu) = \frac{1}{N} \sum_{m=1}^N (\hat{y}_m - y_m)^2 = \frac{1}{N} \sum_{m=1}^N \left( \frac{K_m \Delta t (\nu - \sum_{b=1}^S x_{m,b}(t_{m,0}) \omega_b)}{\sum_{b=1}^S x_{m,b}(t_{m,K_m}) \omega_b - \sum_{b=1}^S x_{m,b}(t_{m,0}) \omega_b} - y_m \right)^2 \quad (5)$$

式中: $N$ 为发动机的个数; $W = \{\omega_1, \omega_2, \dots, \omega_S\}$ 为 $S$ 个传感器监测数据对应的融合系数向量; $\nu$ 是复合健康指标对应的失效阈值; $\hat{y}_m$ 和 $y_m$ 分别为剩余寿命预测值和对应的实际值,具体推导过程见文献[13]。

$$\{W^*, \nu^*\} = \min J(W, \nu) \quad (6)$$

通过最小化 $J(W, \nu)$ 可得到最优解 $\{W^*, \nu^*\}$ ,本文利用拟牛顿法对式(6)进行多维搜索求解,具体求解过程如图1所示。




图1 多源传感器数据融合过程

### 1.1.4 健康指标的评估

为证明加权融合方法构造的健康指标优于其他方法构造的健康指标,本文采用 Spearman 相关系数评估发动机剩余寿命与健康指标之间的关联程度。Spearman 相关系数的绝对值越大,两变量之间的关联程度越强<sup>[15]</sup>,Spearman 相关系数的计算公式如下:

$$\rho_m = 1 - \frac{6 \sum_{k=0}^{K_m} (\tilde{f}_{m,k} - \tilde{y}_{m,k})^2}{K_m^3 - K_m} \quad (7)$$

式中: $\rho_m$ 为第 $m$ 个发动机的 Spearman 相关系数; $f_{m,k}$ 为第 $m$ 个发动机在 $t_{m,k}$ 时刻的健康指标; $y_{m,k}$ 为 $f_{m,k}$ 对应的剩余寿命; $K_m$ 为 $f_{m,k}$ 的样本大小; $\tilde{f}_{m,k}$ 是 $f_{m,k}$ 排序后的位置; $\tilde{y}_{m,k}$ 是 $y_{m,k}$ 排序后的位置。

## 1.2 基于 GRU 和 Bootstrap 方法的剩余寿命预测

GRU 网络运行速度快、处理时序特征有较好的优势,但无法量化寿命预测的不确定性,于是将它与 Bootstrap 方法进行结合,通过 Bootstrap 方法对最优复合健康指标进行重复抽样来量化寿命预测的不确定性。与其他预测模型相比,这种组合方法不仅能获得较高的预测精度,还能实现对航空发动机剩余寿命的单点预测和区间预测。

### 1.2.1 Bootstrap 方法

Bootstrap 是一种通过对传感器监测数据进行重复抽样来量化预测不确定性的方法,其基本思想是通过原始样本进行 $n$ 次有放回抽样,得到 $n$ 个与原始样本大小相等的 Bootstrap 样本<sup>[16]</sup>。Bootstrap 方法从理论上减少了预测值与真实值之间的偏差,适用于难于获取区间估计的样本预测<sup>[17]</sup>。

### 1.2.2 GRU

GRU<sup>[18]</sup>和 LSTM<sup>[19]</sup>一样,是为了解决 RNN 梯度消失问题而提出来的。GRU 与 LSTM 的区别主要在于 GRU 的结构和参数比 LSTM 更简单,运算效率更高效,GRU 的结构如图2所示,主要由重置门和更新门构成。

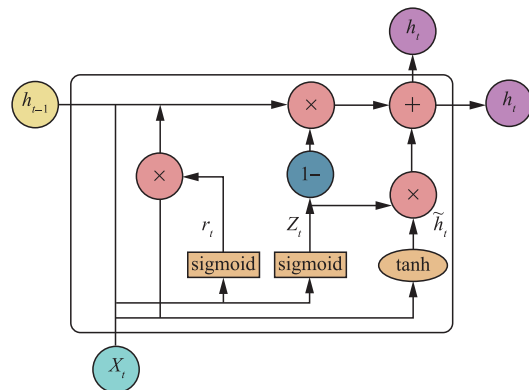


图2 GRU 的结构图

计算公式如下:

$$\begin{cases} r_t = \text{sigmoid}(\mathbf{W}_r x_t + \mathbf{U}_r h_{t-1} + b_r) \\ z_t = \text{sigmoid}(\mathbf{W}_z x_t + \mathbf{U}_z h_{t-1} + b_z) \\ \tilde{h}_t = \tanh(\mathbf{W}_h x_t + r_t \mathbf{U}_h h_{t-1} + b_h) \\ h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t \end{cases} \quad (8)$$

式中:  $x_t$  表示当前时刻的输入;  $h_t$  表示当前时刻的输出;  $h_{t-1}$  表示上一时刻的输出;  $r_t$  为重置门激活结果;  $z_t$  为更新门激活结果;  $\tilde{h}_t$  表示当前时刻候选隐藏状态;  $\mathbf{W}$ 、 $\mathbf{U}$  表示权重矩阵;  $b$  表示偏置参数。

### 1.2.3 构建 GRU 和 Bootstrap 方法的寿命预测模型

文献[20]利用 Bootstrap 方法和二维 DCNN 实现了对滚动轴承的剩余寿命区间预测, 本文参考此文献方法, 利用 GRU 和 Bootstrap 方法实现对航空发动机的剩余寿命区间预测(图 3)。

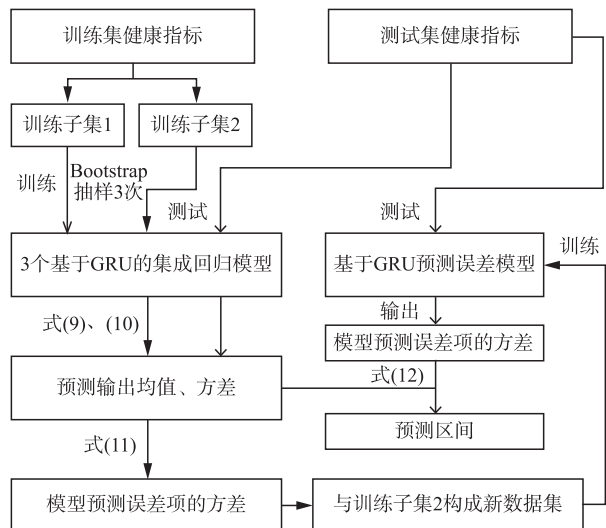


图 3 Bootstrap-GRU 预测模型

**步骤 1** 将训练集中 100 个发动机构造的一维复合健康指标和标签记作  $G_{\text{train}} = \{F_m^{\text{train}}, y_m^{\text{train}}\}_{m=1}^{100}$ 。

**步骤 2** 将  $G_{\text{train}}$  以 7:3 的比例划分为训练子集  $G_1 = \{F_i^{\text{train}}, y_i^{\text{train}}\}_{i=1}^{70}$  和训练子集  $G_2 = \{F_j^{\text{train}}, y_j^{\text{train}}\}_{j=1}^{30}$ 。

**步骤 3** 针对训练子集  $G_1$  采用有放回抽样的方式生成 3 ( $n=3$ ) 个 Bootstrap 样本, 记作  $G_n = \{F_n, y_n\}_{n=1}^3$ , 且每个 Bootstrap 样本的数量均与训练子集  $G_1$  的样本数量相同。

**步骤 4** 利用  $G_n$  中的 3 个 Bootstrap 样本分别训练 3 个基于 GRU 的集成回归模型。

**步骤 5** 将测试集中 100 个发动机构造的一维复合健康指标和标签记作  $G_{\text{test}} = \{F_m^{\text{test}}, y_m^{\text{test}}\}_{m=1}^{100}$ 。

**步骤 6** 利用训练完成的 GRU 集成回归模型处理  $G_{\text{test}}$ , 得到第  $m$  个发动机的预测值为  $\hat{y}_m$ , 再通过式(9)、式(10)计算得到输出均值  $\bar{y}_m$ 、预测方差  $\sigma_{y_m}^2$ 。

$$\bar{y}_m = \frac{1}{3} \sum_{n=1}^3 \hat{y}_m^{(n)} \quad (9)$$

$$\sigma_{y_m}^2 = \frac{1}{3-1} \sum_{n=1}^3 (\hat{y}_m^{(n)} - \bar{y}_m)^2 \quad (10)$$

**步骤 7** 将训练子集  $G_2$  放入基于 GRU 的集成回归模型中进行预测, 根据式(9)和式(10)求出  $G_2$  的输出均值  $\bar{y}_j$  和预测方差  $\sigma_{y_j}^2$ 。

**步骤 8** 采用式(11)近似求出模型预测误差项的方差。

$$r_j^2 = \max\{(y_j^{\text{train}} - \bar{y}_j)^2 - \sigma_{y_j}^2, 0\} \quad (11)$$

**步骤 9** 基于  $G_2$  和利用  $G_2$  所获得的对应模型预测误差项的方差  $r_j^2$  构造一新的数据集, 记作  $G_{r,2} = \{F_j^{\text{train}}, r_j^2\}_{j=1}^{30}$ 。

**步骤 10** 构建一个新的基于 GRU 的预测误差模型完成对新数据集  $G_{r,2}$  的训练。

**步骤 11** 将  $G_{\text{test}}$  输入到基于 GRU 的预测误差模型后估计得到模型预测误差项的方差  $\sigma_{\epsilon_m}^2$ 。

**步骤 12** 利用式(12)计算航空发动机剩余寿命预测区间,  $t_{d_f}^{1-\frac{\alpha}{2}}$  的值可直接通过查表获得。

$$(\bar{y}_m \pm t_{d_f}^{1-\frac{\alpha}{2}} \sqrt{\sigma_{y_m}^2 + \sigma_{\epsilon_m}^2}) \quad (12)$$

## 2 方法步骤

为解决深度学习方法在航空发动机剩余寿命预测中存在的弊端, 提出一种多源传感器数据加权融合与 GRU 相结合的剩余寿命预测方法。其核心步骤是: ①通过直接观察法挑选出能够表征发动机退化趋势的 14 维传感器监测数据作为特征参数, 对特征参数进行标准化和贴标签处理; ②利用 Wiener 过程构建一个反馈闭环回路, 通过对优化目标函数进行搜索寻优, 得到多源传感器数据的融合系数, 根据融合系数构造一维复合健康指标; ③利用一维复合健康指标和 Bootstrap 方法构建 3 个基于 GRU 网络的集成回归模型和一个基于 GRU 网络的预测误差模型, 根据模型预测结果计算得到发动机剩余寿命的预测区间; ④采用均方根误差和评分函数对预测结果进行评价。具体实施流程如图 4 所示。

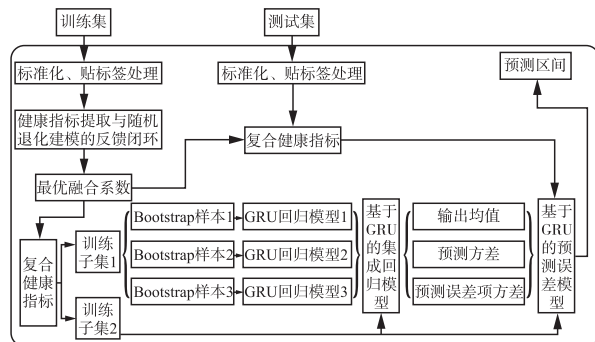


图 4 方法流程图

### 3 实验研究与分析

#### 3.1 实验数据

为验证本文所提方法的效果,选取 C-MAPSS 涡扇发动机退化数据集中的 FD0001 数据集进行实验,该数据集包含训练集、测试集,具体数据信息如表 1 所示<sup>[21]</sup>。

表 1 FD0001 数据集

数据集	发动机数量/个	传感器维度/维	数据集特点
训练集	100	21	全寿命
测试集	100	21	片段式

#### 3.2 性能度量指标

本文选用均方根误差和评分函数作为模型的性能度量指标<sup>[22]</sup>。

均方根误差(RMSE,式中简记  $R_{RMSE}$ )的数学表达为:

$$R_{RMSE} = \sqrt{\frac{1}{N} \sum_{m=1}^N (\hat{y}_m - y_m)^2} \quad (13)$$

评分函数(Score,式中简记  $S_{score}$ )表达式如式(14)、式(15)所示:

$$S_{score} = \sum_{m=1}^N S_m \quad (14)$$

$$S_m = \begin{cases} e^{-\frac{\hat{y}_m - y_m}{13}} - 1, & \hat{y}_m - y_m < 0 \\ e^{\frac{\hat{y}_m - y_m}{10}} - 1, & \hat{y}_m - y_m \geq 0 \end{cases} \quad (15)$$

式中: $N$  为发动机总数量; $\hat{y}_m$  为剩余寿命的预测值; $y_m$  为真实值。均方根误差和评分函数的图像如图 5 所示,均方根误差具有相同的惩罚,评分函数对滞后预测的惩罚大于对超前预测的惩罚,两者的值都是越小越好。

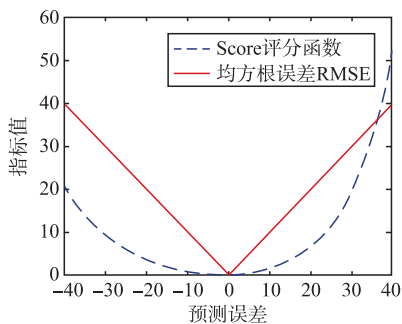




















图 5 评价函数图像

#### 3.3 数据预处理

训练集中 1 号发动机的 21 维传感器监测到的数据如图 6 所示,从图 6 中可以看出,2、3、4、7、8、9、11、12、13、14、15、17、20、21 号传感器监测到的数据

能够反映涡扇发动机的退化趋势,因此选择以上 14 维传感器监测到的数据作为模型的特征参数。








图 6 1 号发动机传感器监测数据变化趋势

利用 Z-Score 方法对特征参数进行标准化处理,计算式为:

$$x_m'(t) = \frac{x_m(t) - \mu(x_m)}{\sigma(x_m)} \quad (16)$$

式中: $x_m(t)$ 和 $x_m'(t)$ 分别为第 $m$ 个发动机的在 $t$ 时刻监测到的退化数据和标准化后的值; $\mu(x_m)$ 和 $\sigma(x_m)$ 为 $x_m(t)$ 的均值和标准差。

再利用分段线性函数给标准化后的特征参数贴上标签,分段点设置为 130<sup>[23]</sup>。当发动机的剩余寿命大于等于 130 时,标签值为 130,当剩余寿命小于 130 时,标签值依次递减 1。

### 3.4 构造健康指标

根据 1.1 节中所提方法,求解得到训练集的融合系数为  $\{W^*\} = \{0.300\ 4, 0.205\ 5, 0.792\ 3, -0.401\ 2, 0.200\ 5, -0.148\ 5, 0.794\ 3, -0.608\ 6, -0.024\ 5, 0.223\ 1, 0.519\ 1, 0.485\ 0, -0.239\ 2, -0.414\ 5\}$ ,利用求解得到的融合系数,将处理好的训练集和测试集数据进行加权融合构造一维复合健康指标。训练集中 1 号发动机构造的一维复合健康指标如图 7 所示。

本文选用 Spearman 相关系数来评估一维复合健康指标的优劣,对比了 LSTM、t-SNE、1D-CNN

和加权融合的方法(见表 2),结果证明利用加强融合方法构造的健康指标能更好地提取发动机的深层退化特征。




图 7 1 号发动机一维复合健康指标

表 2 健康指标对比

Method	LSTM	t-SNE	1D-CNN	加权融合
$\rho$	0.854 7	-0.800 1	0.867 9	-0.944 1

### 3.5 GRU 预测模型的主要参数

参数见表 3。

表 3 GRU 网络主要参数

参数	数据值
Number of hidden units in GRU layer	200
Number of hidden units in fully connected layer	50
Probability property of dropout layer	0.5
Initial learn rate	0.01
Gradient threshold	1
miniBatchSize	20
maxEpochs	60

### 3.6 实验结果及分析

图 8 给出的是模型预测误差(预测寿命-真实寿命)的分布情况,从图 8 中可以看出,预测误差在  $(-10, 0]$  的发动机数量是最多的,超前预测的发动机数量和滞后预测的发动机数量近似相等。




图 8 误差分布直方图

图 9 中,随机展示了 8 号、49 号、12 号和 100 号测试集发动机剩余寿命的点估计和区间估计。从图 9 中可以看出,在发动机的整个退化过程中,不论是真实的退化过程还是模型预测的退化过程都在 90% 的置信区间。




图 9 测试集中的单个发动机剩余寿命预测结果

图 10 为 100 个测试集发动机的剩余寿命预测结果,为便于观察,按照图 10 中发动机真实剩余寿命的大小进行升序排序,可得如图 11 所示的预测结果。




图 10 测试集发动机剩余寿命预测结果

从图 11 中,可以更加直观地看到,本文所提方

法获得的预测结果与发动机的真实剩余使用寿命比较贴近,且测试集中 100 个发动机的真实剩余寿命和预测剩余寿命都在 90% 的置信区间。

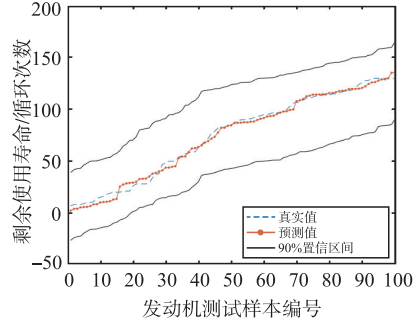


图 11 测试集发动机剩余寿命预测结果排序

为了证明本文所提方法的性能,进行如下对比,结果见表 4。

表 4 对比结果

方法	均方根误差	评分函数	耗时/s
SVR <sup>[24]</sup>	20.960 0	1 382	
CNN <sup>[5]</sup>	15.690 0	389.97	
CNN+GRU <sup>[25]</sup>	18.670 0	761	
DBN+HMM <sup>[12]</sup>	33.818 1		
GRU+Bootstrap	18.809 8	535.147 5	235
加权融合+LSTM+Bootstrap	15.674 3	357.259 9	351
加权融合+GRU+Bootstrap	15.825 4	344.210 5	227

从表 4 中可以看出,与传统机器学习方法、单一深度学习网络、混合深度学习网络和其他深度学习与数理统计的组合方法对比,本文所提方法预测效果较好;与 LSTM 网络对比,两者预测效果近似,但 GRU 网络的运行时长缩短了 124 s,有较高的运行效率。此外,若不使用加权融合的方法构造一维复合健康指标,而是选择直接将预处理好的 14 维传感器特征参数放入 GRU 模型中进行剩余寿命预测,这样做预测效果非但没有本文所提方法好,而且会因为数据维度多导致训练时长增加。

## 4 结论

针对深度学习模型在剩余寿命预测领域中存在的一些问题,本文提出了一种基于数据融合与 GRU 的航空发动机剩余寿命预测方法,选择 C-MAPSS 涡扇发动机退化数据集进行实验验证,得出如下结论。

1)通过加权融合方法构造的一维复合健康指标不仅能够很好地映射发动机的退化过程,还能实现数据的降维,减少时间复杂度和空间复杂度。与其他方式相比,该方法构造的一维复合健康指标不仅具有可解释性强的优点,还能更加充分地提取发动机的退化特征。



2)利用GRU网络建立剩余寿命预测模型,不仅能获得较好的预测效果,还能大大提高网络的训练效率;将GRU与Bootstrap方法结合起来成功量化了剩余寿命预测中存在的确定性。

3)深度学习与数理统计的组合方法不仅能获得较高的预测精度,还能有效解决深度学习在涡扇发动机剩余寿命预测中的弊端,为涡扇发动机制定维修策略提供有力帮助。

## 参考文献

- [1] 张永峰,陆志强. 基于集成神经网络的剩余寿命预测[J]. 工程科学学报, 2020, 42(10):1372-1380.
- [2] 任子强,司小胜,胡昌华,等. 融合多传感器数据的发动机剩余寿命预测方法[J]. 航空学报, 2019, 40(12):134-145.
- [3] LI Y X, HUANG X Z, ZHAO C Y, et al. Stochastic Fractal Search-Optimized Multi-Support Vector Regression for Remaining Useful Life Prediction of Bearings[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2021, 43(9):1-18.
- [4] LI X Q, JIANG H K, LIU Y, et al. An Integrated Deep Multiscale Feature Fusion Network for Aero-engine Remaining Useful Life Prediction with Multi-sensor Data[J]. Knowledge-Based Systems, 2022, 235:107652.
- [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.
- [6] KONG D P, WANG S H, PING P. State-of-Health Estimation and Remaining Useful Life for Lithium-Ion Battery Based on Deep Learning with Bayesian Hyperparameter Optimization[J]. International Journal of Energy Research, 2022, 46(5):6081-6098.
- [7] SHE D M, JIA M P. A BiGRU Method for Remaining Useful Life Prediction of Machinery[J]. Measurement, 2021, 167:108277.
- [8] SUN H C, WU C C, LEI Z Y. Uncertainty Measurement of the Prediction of the Remaining Useful Life of Rolling Bearings[J]. Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems, 2022, 5(3):031007.
- [9] 李浩,王卓健,李哲,等. 基于堆栈自编码器和DeepAR的航空发动机剩余寿命预测[J]. 推进技术, 2022, 43(11):72-80.
- [10] 刘惠,刘振宇,郑维强,等. 深度学习在装备剩余使用寿命预测技术中的研究现状与挑战[J]. 计算机集成制造系统, 2021, 27(1):34-52.
- [11] LIU J Q, YU Z Q, ZUO H F, et al. Multi-Stage Residual Life Prediction of Aero-Engine Based on Real-Time Clustering and Combined Prediction Model[J]. Reliability Engineering & System Safety, 2022, 225:108624.
- [12] 彭开香,皮彦婷,焦瑞华,等. 航空发动机的健康指标构建与剩余寿命预测[J]. 控制理论与应用, 2020, 37(4):713-720.
- [13] 李天梅,司小胜,刘翔,等. 大数据下数模联动的随机退化设备剩余寿命预测技术[J]. 自动化学报, 2022, 48(9):2119-2141.
- [14] 曹惠玲,崔科璐,梁佳旺. 基于多参数融合相似的民航发动机寿命预测[J]. 中国机械工程, 2020, 31(7):781-787.
- [15] 刘泓成. 基于改进神经网络的锂电池剩余使用寿命预测研究[D]. 长春:吉林大学, 2021:18-26.
- [16] 尹敏轩. 基于数据驱动的货车车钩全寿命及剩余寿命预测方法研究[D]. 成都:西南交通大学, 2021:30-32.
- [17] 余道明. 基于深度学习的滚动轴承健康评估与剩余寿命预测研究[D]. 南京:东南大学, 2020:61-68.
- [18] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation[J]. Computer Science, 2014(9):1-15.
- [19] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [20] 黄承庚. 基于监测大数据的产品剩余寿命预测方法研究[D]. 成都:电子科技大学, 2019:92-107.
- [21] SAXENA A, GOEBEL K, SIMON D, et al. Damage Propagation Modeling for Aircraft Engine Run-to-Failure Simulation[C]//2008 International Conference on Prognostics and Health Management. Denver, CO, USA; IEEE, 2008:1-9.
- [22] 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, TX, USA; IEEE, 2017:88-95.
- [23] HEIMES F O. Recurrent Neural Networks for Remaining Useful Life Estimation[C]//2008 International Conference on Prognostics and Health Management. Denver, CO, USA; IEEE, 2008:1-6.
- [24] SATEESH BABU G, 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. Cham: Springer International Publishing, 2016:214-228.
- [25] 王文庆,郭恒,范启富. 基于CNN与GRU的航空发动机剩余寿命预测[C]//第37届中国控制会议论文集(F). 武汉:中国控制学会, 2018:546-551.

(编辑:姚树峰)