

# 基于堆栈自编码器和DeepAR的航空发动机 剩余寿命预测\*

李浩, 王卓健, 李哲, 陈焯, 李园

(空军工程大学 航空工程学院, 陕西 西安 710038)

**摘要:** 针对现有航空发动机剩余寿命预测大多基于单点预测模式, 不能准确给出预测结果置信区间的问题, 提出了一种基于堆栈自编码器结合DeepAR模型的概率分布预测模型。首先, 堆栈自编码器通过无监督式深度学习对发动机监测数据进行特征提取, 构建反映性能退化的健康指标 (HI), 基于双向长短期记忆 (BiLSTM) 网络构建DeepAR预测模型, 将提取后的HI序列输入到DeepAR模型中, 预测模型对HI序列与使用时间的隐含关系进行全局学习, 并输出发动机剩余寿命的概率分布参数。利用C-MPASS涡扇发动机退化数据集进行实验, 验证所提方法的有效性。结果表明, 本文所提预测方法同其他方法相比, 对监测数据融合的效果更好, 预测模型性能提高6.4%, 实际剩余寿命基本在95%置信区间内。

**关键词:** 航空发动机; 寿命预测; 预测模型; 深度学习; 数据融合

中图分类号: V263.6 文献标识码: A 文章编号: 1001-4055 (2022) 11-210645-09

DOI: 10.13675/j.cnki.tjjs.210645

## Prediction of Remaining Useful Life of Aero-Engine Based on Stacked Autoencoder and DeepAR

LI Hao, WANG Zhuo-jian, LI Zhe, CHEN Xuan, LI Yuan

(Aeronautics Engineering College, Air Force Engineering University, Xi'an 710038, China)

**Abstract:** Aiming at the problem that most of the existing aero-engine remaining useful life (RUL) predictions are based on single-point prediction models, and the confidence interval of the prediction results cannot be accurately given, a probability distribution prediction model based on stacked autoencoder (SAE) and DeepAR model is proposed. First, the SAE extracts the features of engine monitoring data through unsupervised deep learning, and constructs health index (HI) reflecting performance degradation, the DeepAR prediction model is constructed based on bi-directional long-short term memory (BiLSTM) network, and the extracted HI sequence is input into the DeepAR model, the prediction model learns the hidden relationship between HI sequence and service time globally, and outputs the probability distribution parameters of engine RUL. The effectiveness of the proposed method is verified by experiments on C-MPASS turbofan engine degradation dataset. The results show that compared with other methods, the prediction method proposed in this paper has better monitoring data fusion effect, the performance of the model is improved by 6.4%, and the actual RUL is basically within the 95% confi-

\* 收稿日期: 2021-09-12; 修订日期: 2021-11-01。

基金项目: 国家自然科学基金 (61873351); 空军工程大学研究生创新实践基金 (CXJ2021002)。

作者简介: 李浩, 硕士生, 研究领域为航空装备状态监测与维修决策。

通讯作者: 李哲, 博士, 讲师, 研究领域为航空装备系统工程。

引用格式: 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):210645. (LI Hao, WANG Zhuo-jian, LI Zhe, et al. Prediction of Remaining Useful Life of Aero-Engine Based on Stacked Autoencoder and DeepAR[J]. *Journal of Propulsion Technology*, 2022, 43(11):210645.)

dence interval.

**Key words:** Aero-engine; Life prediction; Autoencoder; Prediction model; Deep learning; Data fusion

## 1 引言

航空发动机是航空装备的核心部件,很大程度上决定着飞机的飞行性能与飞行安全。为了提高发动机的可靠性与安全性,一些先进发动机上采用了发动机健康管理技术(Engine health management, EHM),如EJ2000发动机ECMS系统、F119发动机的DHM系统等<sup>[1]</sup>。剩余寿命(Remaining useful life, RUL)预测是实现EHM的关键技术之一。

目前RUL预测研究大多基于数据驱动<sup>[2]</sup>,即通过数据分析手段,提取发动机传感器监测的运行数据与使用寿命之间的隐含关系,从而建立RUL预测模型。发动机监测数据具有维度高、数据量大的特点,深度学习在处理此类数据具有更好的特征提取能力,因此在RUL预测领域得到广泛应用。Hu等<sup>[3]</sup>使用LSTM网络对航空发动机的RUL进行了预测,从而避免了传统RNN网络梯度消失和爆炸的问题,同时利用贝叶斯优化理论对网络结构参数进行优化,进一步提高了预测性能。Huang等<sup>[4]</sup>结合BiLSTM网络和粒子滤波算法优点,通过BiLSTM进行特征提取、选择与融合,利用粒子滤波估计系统状态和识别RUL预测模型的未知参数,提高了预测效果。李京峰等<sup>[5]</sup>考虑到发动机监测数据特征,利用LSTM网络提取时序数据整体逻辑特征,通过DBN模型建立数据从高维到低维映射关系,显著提高了预测精度。

健康管理系统通常要求预测模型产生两个结果:预测的失效时间和相关的预测置信区间<sup>[6]</sup>,但基于深度学习的RUL预测方法通常以点预测结果给出,无法确定预测结果的置信区间。针对此类问题,也有部分学者进行了一些改进,牟含笑等<sup>[7]</sup>通过连续置信网络结合BiLSTM建立RUL预测模型,并通过MC仿真和随机权重系数得到RUL预测结果不确定性。Wang等<sup>[8]</sup>引入动态全连接层替代传统全连接层,采用动态高斯丢失策略,输出RUL预测值和偏差区间。但这些改进是在网络中人工引入随机因子,其预测区间可通过调整权重的随机性而改变,RUL预测结果的不确定性由网络结构决定,预测区间的可信性无法确定。

针对上述问题,本文提出一种基于SAE和DeepAR的RUL预测方法,SAE是一种可对高维数据进行融合降维的深度学习网络<sup>[9]</sup>,而DeepAR模型是一种

基于自回归神经网络架构的概率预测模型,可从监测数据中实现时序关系和分布特征的全局学习<sup>[10]</sup>。该方法首先通过SAE捕获数据之间深层特征,提取健康指标(Health index, HI),然后结合BiLSTM建立DeepAR模型,预测序列在每个时间步上取值的概率分布,输出RUL的预测均值和标准差,可有效解决预测结果不确定性依赖于网络结构的问题,提高RUL预测精度和预测区间的准确性。

## 2 RUL预测方法

### 2.1 堆栈自编码器

堆栈自编码器(Stacked autoencoder, SAE)是由自编码器(Autoencoder, AE)栈式堆叠构成的一种深层神经网络<sup>[11]</sup>。一般的自编码器网络结构如图1所示,主要由输入层、隐含层和输出层组成,训练过程可分为编码过程和解码过程。

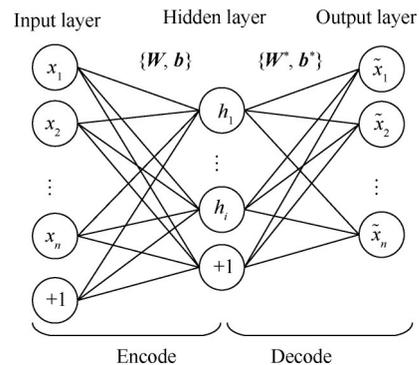


Fig. 1 Network structure of autoencoder

给定输入  $X = (x_1, x_2, \dots, x_n)$ , 编码过程是通过编码函数  $f$  将输入转化为隐含状态  $h$ 。

$$h = f(W \cdot X + b) \quad (1)$$

式中  $W, b$  分别为输入层与隐含层之间权重矩阵和偏置。

解码过程是通过解码函数  $g$  将隐含状态  $h$  重构为  $\tilde{X}$ 。

$$\tilde{X} = g(W^* \cdot h + b^*) \quad (2)$$

式中  $W^*, b^*$  为隐含层与输出层之间权重矩阵和偏置。

网络的训练是通过最小化重构误差,使得  $\tilde{X}$  尽可能与输入  $X$  相等,即

$$\Theta_{AE}(W, b, W^*, b^*) = \arg \min L(X, \tilde{X}) \quad (3)$$

式中  $\Theta_{AE}$  为  $W, b, W^*, b^*$  的取值,  $L$  为  $X$  与  $\tilde{X}$  的误差

函数。

当重构误差足够小时,可认为隐含状态  $h$  包含了原始输入  $X$  的全部信息,如果此时  $h$  的维度  $< X$ ,便达到了数据降维的效果。

SAE采用了深度学习的思想,通过引入多个隐含层从而逐层地学习原始数据的多种内在联系,更加适合特征提取,数据分类等任务。一个具有三个隐含层的SAE网络结构如图2所示,SAE网络为对称结构,上一层的输出作为下一层的输入,当原始数据输入到输入层后,先由第一隐含层进行特征提取,并输出隐含状态至第二隐含层,由第二隐含层进行更深层次特征提取,之后第三隐含层和输出层进行数据重构,其中数据抽象的过程可视为两个编码器串联,网络训练完成后,可将两个编码器组合作为发动机监测数据的健康特征提取器。

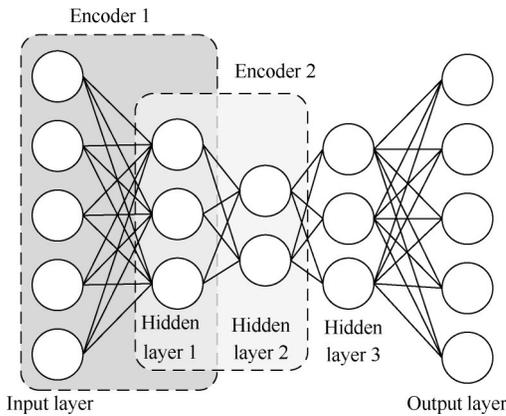


Fig. 2 Network structure of SAE

### 2.2 DeepAR 模型

DeepAR 是 Salina 等<sup>[10]</sup>于 2017 年提出的基于深度学习的时间序列预测方法,目前已经集成在 Amazon SageMaker 机器学习平台中,DeepAR 模型预测结果不是具体的数值,而是一个概率分布,通过概率分布的特征来描述该点可能出现的范围。

定义第  $i$  个时间序列在时间  $t$  的值为  $z_{i,t}$ ,模型的目标是通过已知数据  $z_{i,1:t-1}$  和协变量  $\mathbf{x}_{i,1:T}$ ,得到未知序列  $z_{i,t:T}$  的联合概率分布  $P(z_{i,t:T}|z_{i,1:t-1}, \mathbf{x}_{i,1:T})$ ,假设未知序列分布为  $Q_{\theta}(z_{i,t:T}|z_{i,1:t-1}, \mathbf{x}_{i,1:T})$ ,其概率乘积形式为

$$Q_{\theta}(z_{i,t:T}|z_{i,1:t-1}, \mathbf{x}_{i,1:T}) = \prod_{t=t_0}^T Q_{\theta}(z_{i,t}|z_{i,1:t-1}, \mathbf{x}_{i,1:T}) \quad (4)$$

并通过参数化似然函数表示该分布,有

$$\prod_{t=t_0}^T Q_{\theta}(z_{i,t}|z_{i,1:t-1}, \mathbf{x}_{i,1:T}) = \prod_{t=t_0}^T \ell(z_{i,t}|\theta(\mathbf{h}_{i,t}, \Theta)) \quad (5)$$

$$\mathbf{h}_{i,t} = h(\mathbf{h}_{i,t-1}, z_{i,t-1}, \mathbf{x}_{i,t}, \Theta) \quad (6)$$

式中  $h$  为 RNN 神经网络的隐含状态函数,  $\theta$  为输出状态函数,  $\Theta$  为网络结构参数。

由于航空发动机监测数据为实值数据服从高斯分布,则似然函数形式为

$$\ell(z_{i,t}|\mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z_{i,t} - \mu)^2}{2\sigma^2}\right) \quad (7)$$

$$\mu(\mathbf{h}_{i,t}) = \mathbf{W}_{\mu}\mathbf{h}_{i,t} + \mathbf{b}_{\mu} \quad (8)$$

$$\sigma(\mathbf{h}_{i,t}) = \ln(1 + \exp(\mathbf{W}_{\sigma}\mathbf{h}_{i,t} + \mathbf{b}_{\sigma})) \quad (9)$$

式中  $\mathbf{W}_{\mu}, \mathbf{b}_{\mu}, \mathbf{W}_{\sigma}, \mathbf{b}_{\sigma}$  分别为全连接层输出  $\mu, \sigma$  权重与偏置。

DeepAR 模型结构如图 3 所示。

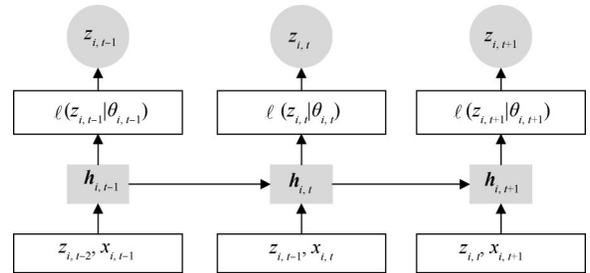


Fig. 3 Diagram of DeepAR network

在训练过程,每一个时间步  $t$  中,网络通过特征  $x_{i,t}$ 、上一时间步的目标值  $z_{i,t-1}$  和隐含状态  $h_{i,t-1}$  来计算当前时间步  $h_{i,t}$ ,并通过输出状态函数  $\theta$  计算似然  $\ell(z_{i,t}|\theta(\mathbf{h}_{i,t}, \Theta))$  的参数。

网络的学习则是将对数似然函数作为损失函数,并通过优化器使得对数似然最大,损失函数  $L$  表达式为

$$L = -\sum_i \sum_t \ln \ell(z_{i,t}|\theta(\mathbf{h}_{i,t}, \Theta)) \quad (10)$$

### 2.3 双向长短期记忆网络

在 DeepAR 模型中需要引入 RNN 神经网络计算隐含状态。目前较为广泛的用于序列预测的方法是长短期记忆(LSTM)网络,LSTM 是一种特殊的 RNN,相对于 RNN,LSTM 能够较好地解决序列中长期依赖的问题<sup>[12]</sup>。

图 4 为一个 LSTM 单元内部结构,每个 LSTM 单元的作用主要通过内部的遗忘门、输入门和输出门更新单元状态  $C$  以及输出隐含状态  $h$ 。遗忘门根据输入  $\mathbf{x}_t$  和上一单元输出  $h_{t-1}$  决定遗忘的信息  $f_t$ ,输入门通过输入控制  $i_t$  选择候选记忆信息  $\tilde{C}_t$ ,决定上一状态  $C_{t-1}$  更新的内容,输出门通过输出控制  $o_t$  决定当前单元状态传递到下一单元的隐含状态  $h_t$ 。

$$f_t = \sigma(\mathbf{W}_f[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f) \quad (11)$$

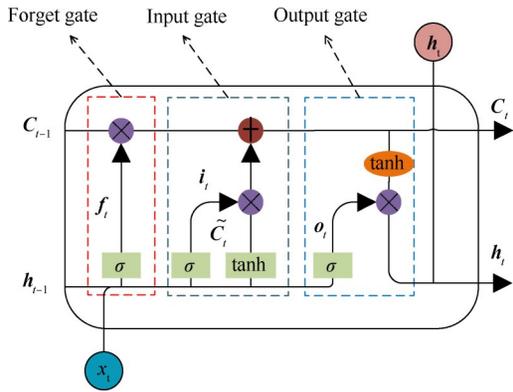


Fig. 4 Network structure of LSTM

$$i_i = \sigma(W_i \cdot [h_{i-1}, x_i] + b_i) \quad (12)$$

$$\tilde{C}_i = \tanh(W_c \cdot [h_{i-1}, x_i] + b_c) \quad (13)$$

$$C_i = f_i \odot C_{i-1} + i_i \odot \tilde{C}_i \quad (14)$$

$$o_i = \sigma(W_o \cdot [h_{i-1}, x_i] + b_o) \quad (15)$$

$$h_i = o_i \odot \tanh(C_i) \quad (16)$$

式中  $\sigma$  为 sigmoid 激活函数,  $\tanh$  为激活函数,  $W_f, W_i, W_c, W_o$  分别为  $f_i, i_i, \tilde{C}_i, o_i$  的权重矩阵,  $b_f, b_i, b_c, b_o$  分别为  $f_i, i_i, \tilde{C}_i, o_i$  的偏置。

双向长短期记忆 (BiLSTM)<sup>[13]</sup> 是由前向 LSTM 和后向 LSTM 组合来利用过去时刻和未来时刻的信息更好地挖掘时序数据之间的内部关系, 图 5 为 BiLSTM 网络结构。

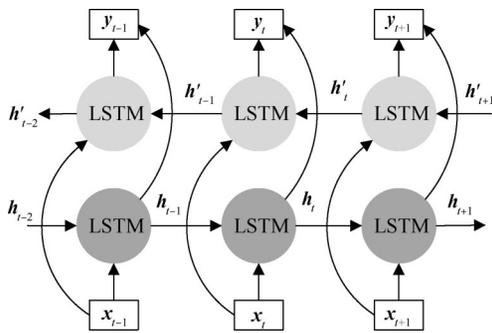


Fig. 5 Diagram of BiLSTM network

前向 LSTM 从正向的序列计算隐含状态  $h_i$ , 后向 LSTM 从反向的序列计算隐含状态  $h'_i$ , 然后连接  $h_i, h'_i$  作为 BiLSTM 的输出  $y_i$ , 将 LSTM 单元视为一个函数  $M$ , 其计算公式为

$$h_i = M(x_i, h_{i-1}) \quad (17)$$

$$h'_i = M(x_i, h'_{i+1}) \quad (18)$$

$$y_i = W_y h_i + W'_y h'_i + b_y \quad (19)$$

式中  $W_y, W'_y$  分别为  $h_i, h'_i$  输出连接的权重矩阵,  $b_y$  为  $h_i, h'_i$  输出连接的偏置。

## 2.4 RUL 预测模型

本文所提的航空发动机 RUL 预测方法的基本思想是通过堆叠编码器对航空发动机历史监测数据特征提取, 利用多层编码结构将高维时序数据转化为一维数据, 从而构建反应发动机性能退化状况的健康指标  $H$ , 使得  $H$  最大程度上反映发动机健康状况, 然后构建 DeepAR 时间序列预测模型, 将  $H$  序列输入 DeepAR 模型进行训练, 通过 BiLSTM 神经网络捕获  $H$  时序数据中的关联关系, 并利用 DeepAR 结构输出 RUL 概率分布函数参数, 实现 RUL 区间概率预测, 训练完成后, 便可将发动机在线监测的实时运行数据输入到训练好的编码器和预测模型中实现 RUL 的预测。

基于 SAE-DeepAR 深度学习的 RUL 预测模型框架如图 6 所示。

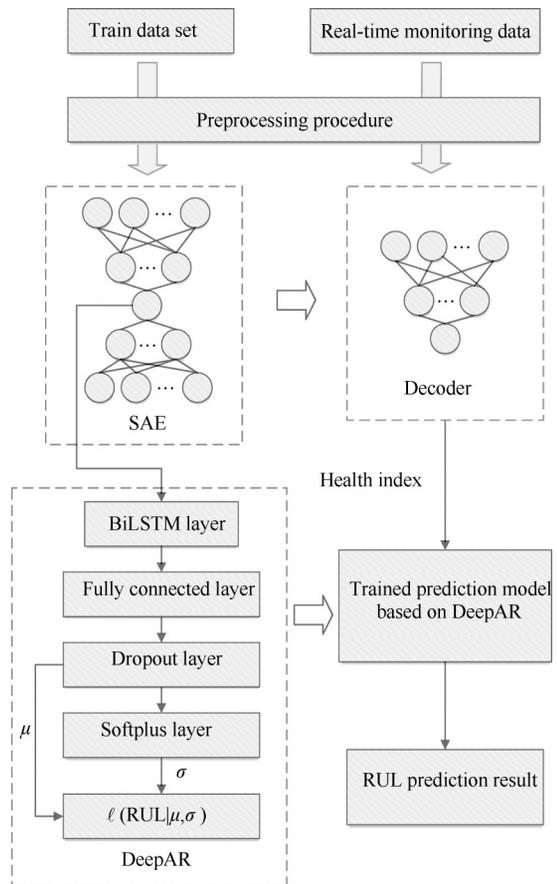


Fig. 6 Flowchart of the proposed RUL prediction method

### 步骤一: 数据预处理

航空发动机的监测数据通常具有多个数据变量, 如压力、温度、流量等, 不同类型数据的数据量级存在较大差异, 需要对数据进行 Z-Score 标准化, 计算式为

$$x'_i(t) = \frac{x_i(t) - \mu(x_i)}{\sigma(x_i)} \quad (20)$$

式中  $x_i(t)$ ,  $x'_i(t)$  分别为第  $i$  个序列在时刻  $t$  的观测值和标准化后的值,  $\mu(x_i)$ ,  $\sigma(x_i)$  为序列  $x_i$  的均值与标准差。

### 步骤二:提取健康特征

将预处理后的监测数据作为训练集数据输入到 SAE 中得到一个编码器和解码器,编码器将训练集数据编码为一维数据来构建健康指标( $H$ ),同时解码器将  $H$  解码重构,根据重构数据与原数据的重构误差进行 SAE 网络的学习优化。重构误差用均方误差来表示,计算式为

$$F(H, \tilde{H}) = \frac{1}{N} \sum_t (H(t) - \tilde{H}(t))^2 \quad (21)$$

式中  $H(t)$ ,  $\tilde{H}(t)$  分别为  $H$  在时刻  $t$  的原始值和重构值,  $N$  为序列长度,  $F(H, \tilde{H})$  为健康指标  $H$  的重构误差。

### 步骤三:DeepAR 模型训练

按照 DeepAR 模型的原理对 BiLSTM 网络进行结构设计,搭建如图 6 中 DeepAR 部分的深度神经网络模型,模型中引入了随机丢弃层,可以防止模型训练中过拟合的问题,提高模型的泛化性能,同时,通过 Softplus 层输出  $\sigma$ ,一方面避免因输出负数产生错误,另一方面也可以更好地挖掘  $H$  序列中的非线性关系,模型构建完成后,将  $H$  输入到 DeepAR 模型进行训练,选用合适的优化器进行网络学习,由于时序预测模型中样本批次大小和迭代次数对模型训练效果具有较大的影响,通过网格搜索对这两个超参数进行优化,最终得到 RUL 预测模型。

### 步骤四:RUL 预测

首先将训练完成后的 SAE 网络中编码器部分作为  $H$  特征提取器,与训练好的 DeepAR 模型组合成预测模型,将待预测的发动机监测数据按照训练过程中同样的方法进行预处理,代入到预测模型,模型以数组形式输出 RUL 高斯分布的均值与标准差,从而得到 RUL 的区间范围与概率密度。

## 3 实验分析

### 3.1 数据集描述

为验证本文所提的 RUL 预测方法的有效性以及评估其准确性,选用航空发动机 RUL 预测研究领域广泛使用的 C-MAPSS 涡扇发动机数据集,该数据集是 NASA 埃姆斯研究中心通过 C-MPASS 仿真平台模拟发动机运行到失效的全寿命过程,并记录 3 个工况

条件和 21 个工作状态的监测数据。

该数据集共分 4 组 FD001~004,以使用循环次数作为寿命度量,每组数据集分为训练集和测试集,训练集包含发动机整个寿命周期内数据和寿命标签,测试集仅包含发动机运行到某一时刻前的监测数据,数据集还提供了测试集的真实 RUL 以便验证。本文选取 FD001 组数据进行模型的实验,该组数据包含了 100 台发动机在海平面使用条件和高压压气机退化模式的训练集和测试集。

### 3.2 预测效果评估

为了比较本文所提出的预测方法的准确性,选取 RMSE 和 Score 两个指标来度量模型预测性能。

RMSE 是指均方根误差,常作为深度学习模型中误差衡量标准,能够反映预测值与真实值之间的总体偏差,其数学定义式  $E$  为

$$E = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_p^i - R_t^i)^2} \quad (22)$$

式中  $R_p^i$  为第  $i$  台发动机 RUL 预测值,  $R_t^i$  为第  $i$  台发动机 RUL 真实值,  $n$  为预测数量。

Score 指标是数据集提供方设计的评价函数,通常得分越低,预测效果越好,其数学表达式  $S$  为

$$S = \begin{cases} \sum_{i=1}^n \exp\left(-\left(\frac{R_p^i - R_t^i}{13}\right)\right) - 1 & (R_p^i - R_t^i \leq 0) \\ \sum_{i=1}^n \exp\left(\frac{R_p^i - R_t^i}{10}\right) - 1 & (R_p^i - R_t^i > 0) \end{cases} \quad (23)$$

该评价函数的得分曲线如图 7 所示。

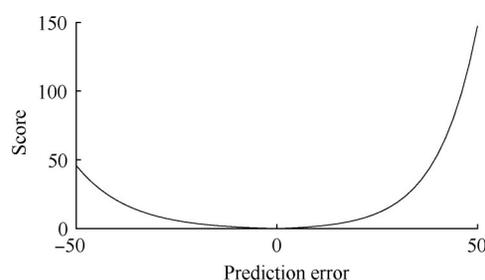


Fig. 7 Score function curve

从图 7 可以看到, RUL 的过早预测,即预测 RUL 小于实际 RUL 的惩罚分数比过晚预测较低,这是由于发动机对飞行安全具有较高的重要性,过晚的预测可能会使维护人员对发动机的使用造成决策失误而产生重大事故隐患,因此在预测误差范围相同时,人们往往更倾向于选择较为保守的估计。

### 3.3 实验过程及结果

#### 3.3.1 数据预处理

监测数据相对于发动机的 RUL 具有单调性的趋

势才能作为特征提取的对象,因此首先从监测数据中剔除没有明显退化趋势的传感器数据,最终筛选出14个传感器数据作为输入。由于数据中含有一定噪声,影响预测精度,通过移动平均法对数据进行平滑处理,窗口长度设置为25,之后进行标准化处理,消除因监测数据不同量纲带来的训练误差。

图8为该组数据集中1号发动机监测数据预处理后的结果,由图中可以看出监测数据随着发动机使用次数的增加都具有一定的趋势,下一步则是从趋势中提取表征发动机健康状态的特征。

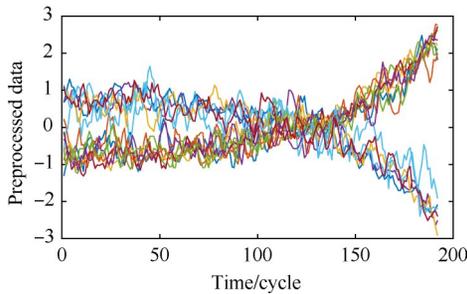


Fig. 8 Preprocessed engine monitoring data

### 3.3.2 健康指标提取

本文通过SAE进行健康指标 $H$ 提取,首先构建由三个编码器串联的SAE网络,按照逐层提取的过程,将编码器部分网络参数设置如表1所示,为防止SAE网络过度拟合,在误差函数增加一个L2正则化项,同时为了更好的提取监测数据与RUL之间的非线性关系,SAE网络中各神经元激活函数采sigmoid函数,其计算式为

$$f_s(x) = \frac{1}{1 + e^{-x}} \quad (24)$$

式中 $x$ 为神经元输入, $f_s(x)$ 为神经元输出。

Table 1 SAE network parameters

Item	Hidden size	Max echos
Hidden layer 1	8	90
Hidden layer 2	4	90
Hidden layer 3	1	50

将处理好的数据输入到SAE网络中,三层结构的编码器会将14维的输入数据按照8维、4维、1维的顺序依次降维,提取出发动机健康指标。

以编号为1,25,50,75,100的发动机为例,健康指标 $H$ 提取结果如图9所示,在RUL较大时即发动机的使用初期阶段 $H$ 变化相对缓慢,而在使用后期 $H$ 随RUL减小具有明显变化趋势,并且在发动机失效时, $H$ 到达某个数值附近,根据 $H$ 数据前期与后期退化趋

势不同的特点,将发动机运行状态分为健康期和退化期,并对RUL标签进行分段处理,由文献[14]可知,退化临界值设置在130时,模型预测效果较好。

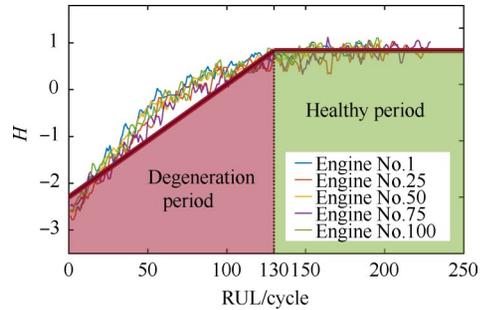


Fig. 9 RUL label setting

为比较不同特征提取方法的优劣,本文通过计算 $H$ 趋势部分 $D$ 与RUL之间的相关系数 $C$ 对 $H$ 的趋势性进行度量<sup>[15]</sup>,计算式为

$$C = \frac{\left| n \sum_{i=1}^n d_i t_i - \sum_{i=1}^n d_i \sum_{i=1}^n t_i \right|}{\sqrt{\left\{ n \sum_{i=1}^n (d_i)^2 - \left( \sum_{i=1}^n d_i \right)^2 \right\} \left\{ n \sum_{i=1}^n (t_i)^2 - \left( \sum_{i=1}^n t_i \right)^2 \right\}}} \quad (25)$$

式中 $d_i$ 是 $H$ 序列通过移动均值方法得到的 $H$ 趋势部分 $D$ 的第 $i$ 个值, $t_i$ 是 $D$ 中第 $i$ 个值 $d_i$ 所对应的RUL, $n$ 为序列长度。

经过计算,得到健康指标序列的趋势性指标,并与主成分分析(PCA)、连续深度置信网络(CDBN)<sup>[7]</sup>两种方法结果进行对比,结果如表2所示。

Table 2 Performance comparison with other feature extraction methods

Method	PCA	CDBN	SAE
$C$	0.8670	0.9527	0.9685

由结果可知,SAE网络提取的健康指标与RUL具有更强的相关性,主要是因为SAE采用的是逐层深度式学习,能够更好地提取深层次特征和非线性关系,因此通过输入该健康指标序列进行模型训练会有更好的预测结果。

### 3.3.3 RUL预测模型训练与优化

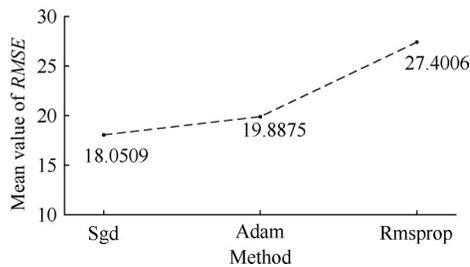
首先,搭建DeepAR网络并设置网络超参数如表3所示,对于时序数据,深度学习网络的最大训练迭代次数和最小批尺寸对训练效果影响较大,而且不同的优化算法对训练效果也有影响,因此本文分别使用随机梯度下降(Sgd)、均方根传递(Rmsprop)和

适应性矩估计(Adam)三种优化算法对最大训练迭代次数和最小批尺寸(参数限制分别为50~70,20~40)进行网格搜索调优,以RMSE为预测结果的误差指标,选择平均REMS最小的优化算法为最优求解器,并选择在该优化算法下RMSE最小时的训练迭代次数和最小批尺寸作为超参数的优化结果。

**Table 3 DeepAR network parameters**

Hyperparameter	Value
Number of hidden units in BiLSTM layer	90
Number of hidden units in fully connected layer	60
Probability property of dropout layer	0.5
Initial learn rate	0.08
Gradient threshold	1

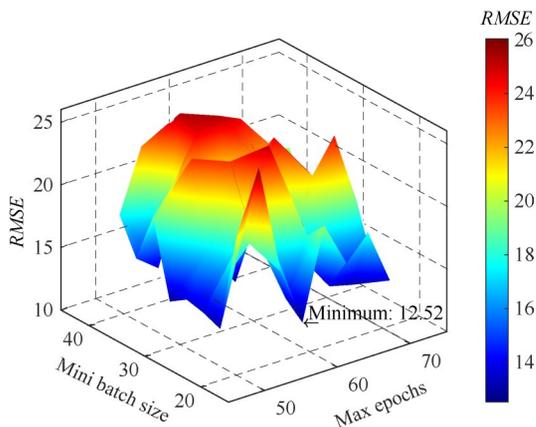
其次,使用不同参数的预测模型对训练集数据进行训练,再将测试集的数据采用同样的预处理后输入到训练好的预测模型中得到不同的预测结果。图10为不同优化器的训练结果,从图中可以看出选择Sgd方法总体上效果更优,因此选择Sgd作为DeepAR预测模型训练的优化算法。



**Fig. 10 Prediction results of different training methods**

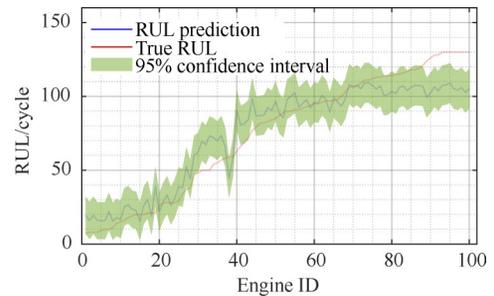
图11为使用Sgd方法进行网格搜索调优的结果,从图11可以看出,当最大训练迭代次数为59,最小批尺寸为20时,模型训练效果最好。

图12为测试集的RUL预测结果,红色为实际的RUL,蓝色为预测的RUL,绿色部分为RUL预测分布



**Fig. 11 Grid search optimization result**

的95%置信区间,为了便于观察,图中按照测试集中真实RUL值进行从小到大排列,从图12中可以看到,测试集中大部分发动机的RUL在预测分布的95%置信区间内,同时,RUL预测误差范围基本控制在-27~27,可见本文所提出的预测方法能够较好地用于预测航空发动机的RUL。



**Fig. 12 RUL prediction results**

为了对比不同方法的优缺点,本文选取DLSTM<sup>[16]</sup>,XGBoost<sup>[17]</sup>,Autoencoder-BLSTM<sup>[18]</sup>和CDBN-BiLSTM<sup>[7]</sup>4种基于神经网络的RUL预测方法与进行比较,对比结果如表4所示。

**Table 4 Performance comparison with other neural network methods**

Method	RMSE	Score	Prediction type
DLSTM	18.33	655	V
XGBoost	13.74	286	V
Autoencoder-BiLSTM	13.63	261	V
CDBN-BiLSTM	12.51	219	P
SAE-DeepAR	12.52	205	P

表中V表示预测结果以单个数值形式给出,P代表预测结果以概率密度形式给出,通过对比可以发现,基于SAE-DeepAR的RUL预测方法与一般的神经网络预测方法相比精度更高,而且兼顾了预测结果不确定性的优点,与CDBN-BiLSTM相比,在RMSE基本一致情况下,Score指标提升6.4%,综合预测性能更好,而且SAE-DeepAR是从数据中学习得到RUL分布函数的参数,与CDBN-BiLSTM在网络中加入随机因子相比,在实际中更有指导意义。

3.3.4 预测过程评估

航空发动机作为一种长期使用的航空装备,其使用寿命长达数千小时,对发动机的RUL预测,不止关注某一时刻预测的准确性,更应重视航空发动机使用全过程中的预测效果,为了观察RUL预测过程是否准确,本文随机选取2台全过程循环的发动机进行预测,预测过程和循环数>100后概率密度曲线如图13所示。从图13中可以观察到,随着发动机运行

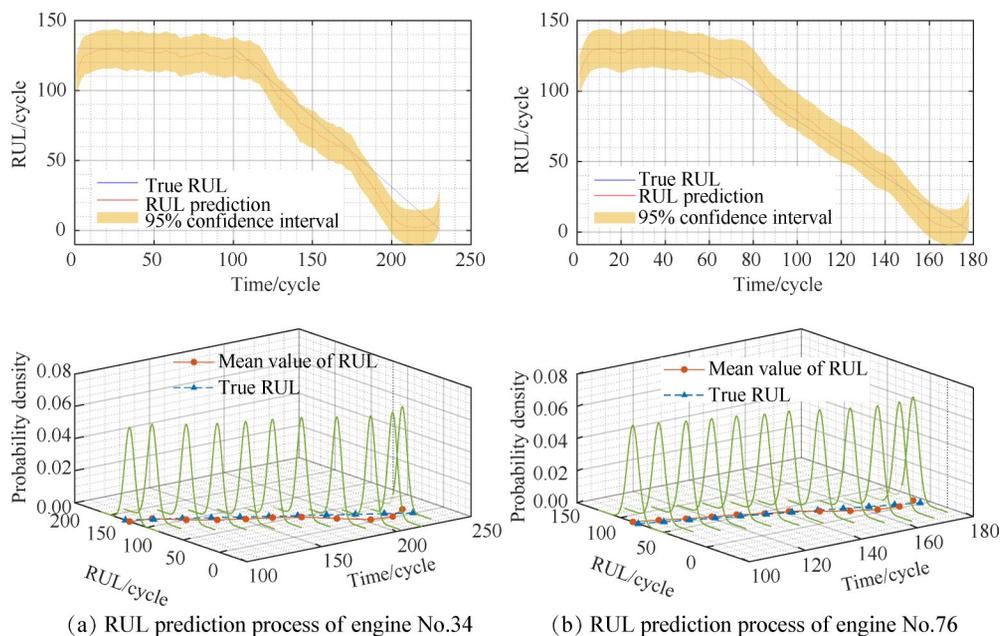


Fig. 13 Engine RUL prediction process

次数的增加,RUL预测结果不断接近于真实值,且在整个预测过程中,真实值基本在95%置信区间,因此本预测文所提方法可以应用于航空发动机使用过程中的RUL预测,为维护和人员对发动机的使用管理提供决策依据。

## 4 结论

本文结合SAE和DeepAR模型提出了一种航空发动机RUL预测方法,通过C-MPASS发动机退化数据集进行了实验验证并得到以下结论:

(1)通过SAE从航空发动机监测数据提取健康指标,能够捕捉数据间的非线性关系,并且同一般的降维方法相比,SAE效果更好,所提取的健康指标趋势更明显。

(2)DeepAR预测模型以概率分布形式输出RUL预测结果,给出了RUL的区间估计,并且预测精度也比一般的预测方法更高,实验中绝大部分RUL真实值包含在预测分布的95%置信区间内,与目前预测精度较高的方法相比,性能提高6.4%,同时该方法是从监测数据的全局进行分布特征的学习,较引入随机因子而进行区间估计的方法更具有应用价值。

(3)基于SAE和DeepAR的RUL预测方法在发动机全过程预测中具有较好的预测效果,同时由于没有强调发动机故障机理分析,可快速将预测模型部署到不同型号发动机上,具备一定的通用性。

致谢:感谢国家自然科学基金、空军工程大学研究生

创新实践基金的资助。

## 参考文献

- [1] 王伟生,肖金彪.航空发动机健康管理系统及其标准分析[J].航空动力,2019(1):68-70.
- [2] 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.
- [3] Hu S, Zhang S, Xu X. RUL Prediction by LSTM Model with Bayesian Parameter Optimization for Turbine Engines[C]. Guiyang: 6th Annual International Conference on Network and Information Systems for Computers, 2020.
- [4] Huang C-G, Yin X, Huang H, et al. An Enhanced Deep Learning-Based Fusion Prognostic Method for RUL Prediction[J]. IEEE Transactions on Reliability, 2020, 69(3): 1097-1109.
- [5] 李京峰,陈云翔,项华春,等.基于LSTM-DBN的航空发动机剩余寿命预测[J].系统工程与电子技术,2020,42(7):1637-1644.
- [6] 张宝珍.国外新一代战斗机综合保障工程实践[M].北京:航空工业出版社,2014.
- [7] 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,DOI:10.7527/S1000-6893.2021.25403,2021-05-11.
- [8] Wang B, Lei Y, Li N, et al. Multiscale Convolutional Attention Network for Predicting Remaining Useful Life of Machinery[J]. IEEE Transactions on Industrial Electronics, 2021, 68(8): 7496-7504.
- [9] 朱乔木,陈金富,李弘毅,等.基于堆叠自动编码器

- 的电力系统暂态稳定评估[J]. 中国电机工程学报, 2018, 38(10): 2937-2946.
- [10] Salinas D, Flunkert V, Gasthaus J, et al. DeepAR: Probabilistic Forecasting with Autoregressive Recurrent Networks [J]. *International Journal of Forecasting*, 2020, 36(3): 1181-1191.
- [11] Hinton G E, Salakhutdinov R. Reducing the Dimensionality of Data with Neural Networks [J]. *Science*, 2006, 313(5786): 504-507.
- [12] Wu Y, Yuan M, Dong S, et al. Remaining Useful Life Estimation of Engineered Systems Using Vanilla LSTM Neural Networks [J]. *Neurocomputing*, 2018, 275(31): 167-179.
- [13] 申彦斌, 张小丽, 夏 勇, 等. Bi-LSTM神经网络用于轴承剩余使用寿命预测研究[J]. 振动工程学报, 2021, 34(2): 411-420.
- [14] Ji S, Han X, Hou Y, et al. Remaining Useful Life Prediction of Airplane Engine Based on PCA-BLSTM [J]. *Sensors*, 2020, 20(16).
- [15] Zhang B, Zhang L, Xu J. Degradation Feature Selection for Remaining Useful Life Prediction of Rolling Element Bearings [J]. *Quality and Reliability Engineering International*, 2016, 32(2): 547-554.
- [16] 马奇友, 刘可薇, 杜 坚, 等. 基于深度长短期记忆网络的发动机叶片剩余寿命预测[J]. 推进技术, 2021, 42(8): 1888-1897. (MA Qi-you, LIU Ke-wei, DU Jian, et al. Prediction of Residual Life of Engine Blades Based on Deep Short Term Memory Network [J]. *Journal of Propulsion Technology*, 2021, 42(8): 1888-1897.)
- [17] 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[J]. 化工自动化及仪表, 2020, 47(3): 243-247.
- [18] 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.

(编辑: 史亚红)