

DOI: 10.13382/j.jemi.B2205410

基于退化阶段识别与 LSTM-fine-tune 的 氧气浓缩器多阶段退化预测*

黄崧琳 景 博 潘晋新 焦晓璇 王生龙

(空军工程大学航空工程学院 西安 710038)

摘 要:退化预测是装备健康管理的重要技术途径,近年来,大量时间序列预测方法在退化预测中得到应用。然而,众多大型装备由于结构复杂,功能多样,在退化过程中存在明显的阶段性,采用单一的模型对不同阶段的退化进行预测将会出现明显的精度降低,针对不同阶段对模型重新训练也会带来时间和算力的损失。针对多阶段退化的问题,引入了迁移学习的思想,提出了一种退化阶段识别与 LSTM-fine-tune 结合的多阶段退化预测方法,采用退化数据对 LSTM 模型训练,之后对部分网络参数进行冻结,在识别到装备出现新的退化阶段后,利用新阶段的退化数据对模型进行微调,以快速匹配不同阶段的数据。为验证模型的有效性,本文以氧气浓缩器为例进行模型应用。结果表明,本文方法能够有效识别氧气浓缩器 3 个阶段的退化,每个阶段的预测均方差分别为 0.507、8.976 和 0.375,远低于不分段直接预测的均方误差 76.87,在训练时间上,对比于每个阶段重新训练时间大幅缩短,在训练精度上,明显优于维纳过程、Lstar 等传统方法。

关键词:长短周期记忆网络;模式识别;迁移学习;氧气浓缩器

中图分类号: TP277;TN98 **文献标识码:** A **国家标准学科分类代码:** 510.40

Multistage degradation prediction of oxygen concentrator based on degradation pattern recognition and LSTM-fine-tune

Huang Songlin Jing Bo Pan Jinxin Jiao Xiaoxuan Wang Shenglong

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

Abstract: Degradation prediction is an important technical approach for equipment health management. In recent years, a large number of time series prediction methods have been applied in degradation prediction. However, due to the complex structure and diverse functions of many large equipment, there are obvious stages in the degradation process, and the application of a single model to predict the degradation at different stages will significantly reduce the accuracy, and the retraining of the model for different stages will also bring the loss of time and computing power. To solve the problem of multi-stage degradation, this paper introduced the idea of transfer learning and proposed a multi-stage degradation prediction method combining degradation pattern recognition and LSTM-fine-tune. The LSTM model was trained with degradation data, and then part of network parameters was frozen. After identifying the new degradation stage of equipment, the model is fine-tuned with the degraded data of the new stage to quickly match the data of different stages. In order to verify the validity of the model, this paper takes oxygen concentrator as an example to apply the model. The results show that the proposed method can effectively identify the degradation of oxygen concentrator at three stages, and the mean square error of prediction for each stage is 0.507, 8.976 and 0.375 respectively, which is far lower than the mean square error of direct prediction without segmentation of 76.87. In terms of training time, compared with the retraining time of each stage, the training accuracy is obviously superior to the traditional methods such as Wiener process and Lstar.

Keywords: LSTM; pattern recognition; transfer learning; oxygen concentrator

0 引言

建立装备的退化模型是装备故障预测与健康管理 (PHM) 技术的关键^[1-3]。近年来,大量时间序列预测方法在退化预测模型中得到应用,RNN 及其变种 LSTM 凭借对历史数据的记忆能力,已经成为处理时序数据的最流行的人工智能方法,在航空发动机单元和机床等复杂机械装备中,LSTM 模型得到了初步应用^[4]。Elsaid^[5]利用 LSTM 对时间序列数据进行预测分析,并使用蚁群优化方法优化 LSTM 中的门,用于涡轮发动机振动预测;Zhao 等^[6]提出了一种将手动特征提取和自动特征学习相结合的方法,使用增强的 RNN 门控递归单元 (GRU) 进行机器健康监测。He 等^[7]融合了多分辨率奇异值分解与 LSTM 网络,实现对轴承性能退化的预测。

然而,由于装备退化机理复杂、失效类型多样、服役环境恶劣,装备的退化过程呈现出明显的多阶段性,采用单一的模型对不同阶段的退化进行预测将会出现明显的精度降低。针对这一问题,大多数文献采用的方案是将退化阶段识别与寿命预测结合,在不同退化阶段中采用不同模型,达到动态调整模型的目的。王国锋等^[8]根据谐波减速器退化趋势的变化,进行多阶段退化过程的划分,并采用振动特征来建立高斯过程回归模型,对性能指标值进行精准预测以实现退化模型后验分布参数的实时更新。李潇瀛等^[9]通过 FCM 估计设备退化状态的拐点,将退化状态划分成不同的阶段,之后由 ARIMA 对设备监测数据进行基于拐点分段的寿命预测。李娟等^[10]在 AIC 准则最小及拟合优度最大的原则下,选择转换变量,对转换后的压力传感器信号建立自回归模型,实现对机载燃油泵多阶段性能退化的建模。刘君强等^[11]采用超统计理论进行突变点检测,将航空发动机的健康数据划分为多个退化阶段,并通过非线性拟合对发动机 RUL 进行预测。

在传统方法中,对不同阶段的模型进行重新选择与训练能够有效提升寿命预测的精度,但在实际数据处理过程中,存在如下两方面问题:1) 针对不同阶段对模型重新训练会带来时间和算力的损失,如果装备的退化阶段较多,需要对模型进行多次的再训练,带来了较大的运算成本;2) 重新训练模型需要充足的数量,当识别到不同的退化阶段后,需要积累一定量的数据才能对模型进行重新训练,造成了装备监测的空档期。

针对以上问题,本文引入了迁移学习中模型微调的思想,提出了一种退化阶段识别与 LSTM-fine-tune 结合的多阶段退化预测方法,采用退化数据对 LSTM 模型训练,之后对部分网络参数进行冻结,在识别到装备出现新的退化阶段后,利用新阶段的退化数据对模型进行微调,

以快速匹配不同阶段的数据。为验证模型的有效性,本文以氧气浓缩器为例进行模型应用。结果表明,本文方法能够有效识别氧气浓缩器 3 个阶段的退化,每个阶段的预测均方差分别为 0.507、8.976 和 0.375,远低于不分阶段直接预测的均方误差 76.87,在训练时间上,对比于每个阶段重新训练时间大幅缩短,在训练精度上,明显优于维纳过程、Lstar 等传统方法。

1 模型架构

本文提出的方法整体方案如图 1 所示。对于具有多阶段退化过程的装备,监测并采集其退化数据;在装备运行过程中,首先基于装备退化数据对多层 LSTM 网络进行训练,并对 LSTM 网络部分层级网络参数进行冻结;之后将训练好的模型用于退化数据预测,并利用模式识别方法定时对退化的阶段进行识别;当判定装备退化阶段发生改变,前期训练模型将难以适应新阶段的退化数据,因此利用该阶段少量退化数据对模型参数进行微调,从而使模型快速适应不同的退化阶段。




图 1 模型流程

Fig. 1 Model flow chart

2 LSTM 模型分析

2.1 网络结构

LSTM 神经网络结构的输入输出如图 2 所示, $x_1, x_2, \dots, x_n$ 表示时间长度为 n 的序列输入, $y_1, y_2, \dots, y_n$ 为对应的输出, $cell 1, cell 2, \dots, cell n$ 代表 LSTM 网络随时间变化的 n 个状态在时间维度上展开,实质上是一个网络随着时间的推进不断变化。

LSTM 的内部结构如图 3 所示, LSTM 每一个 $cell$ 含有 3 个门,分别为遗忘门、输入门、输出门。每个时间点的 $cell$ 会接收上一个时间点处理并传入的两路信号: $C_{(t-1)}$ 与 $h_{(t-1)}$ 。当某个时间点对应的变量输入至 LSTM 的 $cell$ 网络中,将与 $h_{(t-1)}$ 变量合并作为 4 个带激活函数的全连接网络的输入,并形成 4 个输出变量 $f_{(t)}, i_{(t)}, a_{(t)}, o_{(t)}$,其中 $C_{(t-1)}$ 与 $f_{(t)}$ 通过遗忘门相乘, $a_{(t)}, i_{(t)}$ 通过输入门相乘,遗忘门与输入门的相加的结果有两个走向,一是




图 2 LSTM 网络结构示意图

Fig. 2 Schematic diagram of LSTM network structure

作为 $C_{(t)}$ 直接成为下一个时间点 cell 的输入;二是通过激活函数后与 $o_{(t)}$ 在输出层相乘,得到的结果作为这一时间点的输出,并作为下一个时间点的 $h_{(t)}$ 。




图 3 Cell 内部结构示意图

Fig. 3 Cell internal structure diagram

2.2 前向传播

以 t 时刻值 LSTM 网络为例,推导数据在网络中如何计算及传播。对于中间过程变量 $f_{(t)}$ 、 $i_{(t)}$ 、 $a_{(t)}$ 、 $o_{(t)}$ 而言,是由 $h_{(t-1)}$ 与 $x_{(t)}$ 组合后经过一个全连接神经网络得到的。假设 $f_{(t)}$ 与输入 $h_{(t-1)}$ 、 $x_{(t)}$ 对应的权重与偏置为 W_f 、 U_f 与 b_f , $i_{(t)}$ 与输入 $h_{(t-1)}$ 、 $x_{(t)}$ 对应的权重与偏置为 W_i 、 U_i 与 b_i , $a_{(t)}$ 与输入 $h_{(t-1)}$ 、 $x_{(t)}$ 对应的权重与偏置为 W_a 、 U_a 与 b_a , $o_{(t)}$ 与输入 $h_{(t-1)}$ 、 $x_{(t)}$ 对应的权重与偏置为 W_o 、 U_o 与 b_o ,其输入输出关系式如下:

遗忘门输入 $f_{(t)}$ 更新方式如下:

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

输入门的两个输入 $i_{(t)}$ 、 $a_{(t)}$,更新方式分别如下:

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

$$a_t = \tanh(W_a \cdot h_{t-1} + U_a \cdot x_t + b_a) \quad (3)$$

cell 状态更新方式如下:

$$C_t = f_t \cdot C_{t-1} + g_t \cdot i_t \quad (4)$$

输出门的输入 $o_{(t)}$ 更新方式如下:

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

输出门的输出 $h_{(t)}$ 更新方式如下:

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

当前时间点的输出可表示如下:

$$y_t = \sigma(V \cdot h_t + c) \quad (7)$$

通过式(7),推导了时间序列在 t 时刻作为 LSTM 网络的输入变量映射到输出的过程及公式。在下一个时间点 $t+1$,cell 内部的参数的初始状态即为时间点 t 的状态,通过对 t 时刻传入的参数 $h_{(t)}$ 、 $C_{(t)}$ 进行计算,计算方法与 t 时刻相同,从而计算网络的输出^[12-13]。

2.3 反向传播

通过前向传播,计算了在现有网络参数状态下,时间序列的每一个时间点输入向输出的映射关系。想要得到能够准确反映时间序列输入输出对应关系的 LSTM 网络,还需要通过误差分析对网络参数进行迭代修正。对于 LSTM 模型任一时间点的 cell, $h_{(t)}$ 、 $C_{(t)}$ 在传播历史数据信息的同时,误差也随数据传播。因此 LSTM 的损失函数 $L(t)$ 可以分成两个部分,一是当前时间点的网络输出与真实输出的误差,用 $l(t)$ 表示,另一部分是时刻 t 之后的误差通过 $h_{(t)}$ 、 $C_{(t)}$ 方向传播引入的损失,用 $L(t+1)$ 表示,即任一时刻的误差可表示如式(8)所示,其中 τ 表示时间序列最后一个时间点。因篇幅原因,对于反向传播的公式不进行详细介绍。

$$L(t) = \begin{cases} l(t) + L(t+1), & t < \tau \\ l(t), & t = \tau \end{cases} \quad (8)$$

3 LSTM-fine-tune 的不同退化阶段模型微调

LSTM 模型根据现有条件采集的全寿命周期数据建立的相应的退化映射函数关系,以对装备退化的数据进行预测。然而,由于装备退化过程存在阶段性,当装备退化阶段发生变化,前期训练的模型将会失效,造成预测精度的急剧降低。因此,本文借鉴时间序列迁移学习中模型微调的思想,在进入不同退化阶段后对预测模型进行微调,使其快速匹配新退化阶段的退化数据,提高其预测精度。

LSTM-fine-tune 整体结构如图 4 所示,对于源域与目标域的时间序列退化数据,采用多层的 LSTM 网络分别进行抽象,再通过全连接层网络对数据进行预测。首先基于退化数据对多层的 LSTM 模型进行训练,并对网络的部分层参数进行冻结,不再发生变化。

装备虽然各个退化阶段存在差异,但由于退化机理基本一致,因此前一阶段的退化模型参数可以迁移应用至新的退化阶段。当检测到装备退化阶段发生变化,模型将利用新一阶段的退化数据对模型参数中未冻结的部分进行微调,使模型更加贴合新的退化阶段,同时,少量的参数微调也能节省重新训练模型的时间。




图 4 LSTM- fine-tune 整体架构

Fig. 4 LSTM-fine-tune overall architecture

4 基于 Switching 卡尔曼滤波的退化阶段识别

卡尔曼滤波算法通过式(9)和(10)所示的状态方程和观测方程完成系统的状态预测与更新^[14]。

$$X_k = AX_{k-1} + BU_k + W_k \quad (9)$$

$$Z_k = H_k X_k + V_k \quad (10)$$

其中, X_k 为 k 时刻系统待估计的状态; A 为系统的一步状态转移矩阵; B 为系统模型参数; U_k 为系统控制量; W_k 为系统噪声序列; Z_k 为系统观测值; H_k 为测量系统的参数; V_k 为测量噪声序列。

依据广义伪贝叶斯估计 (generalized pseudo-Bayesian, GPB) 原理, 计算由 n 个标准卡尔曼滤波器描述的退化过程的模型变换概率 S_k^{ij} , 其表达式为:

$$S_k^{ij} = \frac{T_{ij} S_{k-1}^i}{\sum_{i=1}^n T_{ij} S_{k-1}^i} \quad (11)$$

其中, 变换概率 S_k^{ij} 表示系统模型由 $k-1$ 时刻的模型 i 变换为 k 时刻的模型 j 的概率, 模型概率 S_{k-1}^i 表示 $k-1$ 时刻系统模型为 i 的概率, 模型转换矩阵 T_{ij} 表示模型之间的变换关系^[15]。

则 $k-1$ 时刻模型 j 的状态和协方差估计可由模型 i 的状态值和协方差按式(12)和(13)求得。

$$\tilde{X}_{j,k-1} = \sum_{i=1}^n S_{k-1}^{ij} X_{i,k-1} \quad (12)$$

$$\tilde{P}_{j,k-1} = \sum_{i=1}^n S_{k-1}^{ij} [P_{i,k-1} + (X_{i,k-1} - \tilde{X}_{j,k-1})(X_{i,k-1} - \tilde{X}_{j,k-1})^T] \quad (13)$$

其中, $X_{i,k-1}$ 表示模型 i 在 $k-1$ 时刻的后验状态估计值, $P_{i,k-1}$ 表示模型 i 在 $k-1$ 时刻的后验协方差估计值。将式(12)和(13)获得的加权状态和协方差估计值按照式(14)进行更新求解即可获得每个模型 k 时刻的后验状

态估计值 X_k^j 和后验协方差估计值 P_k^j 。按照式(15)计算每个滤波器的测量残差 V_k^i 和残差协方差 C_k^i :

$$V_k^i = Z_k - H_k^i \hat{X}_{k|k-1}^i \quad (14)$$

$$C_k^i = H_k^i \hat{P}_{k|k-1}^i H_k^{iT} + R_k^i \quad (15)$$

每个滤波器的似然估计可表示为:

$$L_k^i = N(V_k^i; 0, C_k^i) \quad (16)$$

则 k 时刻每个模型的概率可表示为:

$$S_k^i = \frac{L_k^i \sum_{i=1}^n T_{ij} S_{k-1}^i}{\sum_{i=1}^n (L_k^i \sum_{i=1}^n T_{ij} S_{k-1}^i)} \quad (17)$$

每次迭代更新的输入状态:

$$X_k = \sum_{i=1}^n S_k^i X_k^i \quad (18)$$

每次迭代更新的输入协方差:

$$P_k = \sum_{i=1}^n S_k^i [P_k^i (X_k^i - X_k)(X_k^i - X_k)^T] \quad (19)$$

通过比较各模型的概率大小可获得各退化阶段的置信度水平, 从而能够判断退化数据所处的退化阶段。采用 SKF 进行退化阶段识别的流程如图 5 所示^[16-17]。

5 基于 Switching 卡尔曼滤波与 LSTM-fine-tune 的氧气浓缩器多阶段退化预测

5.1 基于 Switching 卡尔曼滤波的氧气浓缩器退化阶段识别

对氧气浓缩器提取出的退化健康因子进行数据预处理及可视化, 结果如图 6 所示。通过数据可视化可以发现, 氧气浓缩器退化并不是一个持续的过程, 而是存在明显的分段^[18]。对于这种明显具有阶段性退化的数据, 可能出现突然的拐点, 这种拐点的出现是由监测对象本身退化特性决定的, 拐点出现的时机也具有一定的随机性。对于基于数据驱动的寿命预测方法而言, 模型进行寿命




图 5 SKF 退化阶段识别流程

Fig. 5 Identification flow chart of SKF degradation stage

预测是基于对历史数据的理解和建模,知识来源完全是历史数据,采用数据驱动模型预测带有随机性的拐点,其精度将大大降低,因此,本文采用退化阶段识别与数据驱动的寿命预测结合的方法,实现对多阶段退化数据的预测。




图 6 退化数据拟合

Fig. 6 Degradation data fitting

基于 Switching 卡尔曼滤波器,对氧气浓缩器退化数据提取出的健康因子进行了模式分类与辨识,各模式所具有的置信度如图 7 所示。结合图 6 的数据可视化可以判断,氧气浓缩器在前 76 h 内氧气浓缩器处于平稳阶段,局部波动但整体趋势平稳;从第 76 h 进入退化阶段,氧分压开始趋势性下降;196 h 后,氧分压进入平稳阶段,此时氧分压数值已经处于较低的水平,可以判定氧气浓缩器失效。

5.2 基于 LSTM-fine-tune 模型的氧气浓缩器分阶段预测

通过氧气浓缩器退化阶段识别,氧气浓缩器退化可以分为 3 个阶段,分别为平稳-退化-平稳阶段。对于氧气浓缩器而言,退化模式单一,在全寿命周期内退化机理一




图 7 退化阶段识别

Fig. 7 Degradation pattern recognition

致,但由于性能变化对应到健康指标上并不是线性关系,因此不同退化阶段对应的模型参数发生了改变。因此,本节针对氧气浓缩器 3 阶段退化,基于 LSTM-fine-tune 模型展开预测研究。

首先需要确定 LSTM-fine-tune 网络架构,在本文中,采用 20 层 LSTM 网络的结构,并将前 18 层 LSTM 网络设置为冻结层,将后两层 LSTM 网络设置为微调层。在退化的第 1 阶段,LSTM 模型尚未训练,需要较大的数据量对网络参数进行训练。因此,在氧气浓缩器退化的第 1 阶段,本文采用了第 1 阶段退化数据总量的 40% 对网络参数进行训练,并利用剩余的退化数据对网络预测能力进行测试,结果如图 8 所示。第 1 阶段训练结束后,对前 5 层 LSTM 网络参数进行冻结,不再发生变化。当氧气浓缩器退化进入第 2 阶段,基于第 1 阶段训练的网络参数将无法匹配退化数据,需要对网络参数进行微调,因此在第 2 阶段,采用了该阶段前 10% 的退化数据对后 2 层 LSTM 的网络参数进行微调,以快速适应该阶段的退化数据。在第 3 阶段,模型调整策略与第 2 阶段相同,预测结果如图 8 所示。

作为对照组,本文采用 LSTM 直接预测的方法对氧气浓缩器退化数据进行预测,结果如图 9 所示。

预测结果如表 1 所示,结合图表可以发现,采用分段预测第 1 阶段误差均方根为 0.507,第 2 段误差均方根为 8.976,第 3 阶段误差均方根为 0.375,远低于不分段直接预测的误差均方根 76.87。从结果分析,分段预测的精度要远高于不分段直接预测。分析原因,主要是由于长短周期记忆网络的时间序列预测是基于对历史数据的抽象,从历史数据中获取装备退化的经验知识,因此知识的来源完全是历史退化数据。然而对于多阶段退化部件而言,可能出现突然的拐点,这种拐点的出现是由监测对象本身退化特性决定的,拐点出现的时机也具有一定的随机性。长短周期记忆网络只能从历史数据中获取经验,难以预测拐点的发生,因此直接对多阶段退化数据进行预测精度不高。采用退化阶段识别与寿命预测相结合




图 8 氧气浓缩器退化数据分段预测效果

Fig. 8 Segmentation prediction effect of oxygen concentrator degradation data

后,长短周期记忆对每一阶段的退化开展抽象学习,重新获取退化的经验知识,从而能够大幅提高寿命预测精度。

表 1 预测结果对比

Table 1 Comparison of prediction results		
方法	均方根误差	重新训练时间/s
本文方法	3. 277	12. 976
不分段直接预测	76. 87	0
每段重新训练	3. 145	43. 827
维纳过程	12. 23	2. 853
Lstar	8. 334	5. 332




图 9 氧气浓缩器退化数据直接预测效果

Fig. 9 Oxygen concentrator degradation data directly predicts effects

对比于每个退化阶段对 LSTM 模型重新训练,本文方法在预测精度上与之相当,但在重新训练时间上明显小于重新训练。原因是本文采用了迁移学习中模型微调的思想,将前一个退化阶段的经验知识应用至后一个阶段的预测,因此需要调整的参数大幅减小,从而重新训练的时间也大幅减小。

对比于传统的维纳过程、Lstar 等方法,本文方法由于采用了深度学习网络,在重新训练时间上不具有优势,但训练精度明显高于维纳过程、Lstar 等方法。

6 结 论

针对多阶段退化的问题,本文引入了迁移学习的思想,提出了一种退化阶段识别与 LSTM-fine-tune 结合的多阶段退化预测方法,采用退化数据对 LSTM 模型训练,之后对部分网络参数进行冻结,在识别到装备出现新的退化阶段后,利用新阶段的退化数据对模型进行微调,以快速匹配不同阶段的数据。为验证模型的有效性,本文以氧气浓缩器为例进行模型应用。结果表明,本文方法能够有效识别氧气浓缩器 3 个阶段的退化,每个阶段的预测均方差分别为 0. 507、8. 976 和 0. 375,远低于不分段直接预测的均方误差 76. 87,在训练时间上,对比于每个阶段重新训练时间大幅缩短,在训练精度上,明显优于维纳过程、Lstar 等传统方法。

在模型应用方面,本文提出方法在氧气浓缩器的 3 阶段退化数据中进行了验证。但是在氧气浓缩器的 3 个阶段中,第 1 阶段处在平稳状态,第 3 阶段处在健康指标较低水平,对于寿命预测的需求明显低于第 2 阶段,因此在后期的工作中,可以针对装备监测的实际需求调整预测策略,使算法更加符合实际装备监测要求。

参考文献

[1] 陈雪峰. 智能运维与健康管理 [M]. 北京:机械工业

- 出版社, 2018.
- CHEN X F. Intelligent Operation and Maintenance and Health Management [M]. Beijing: China Machine Press, 2018.
- [2] 年夫顺. 关于故障预测与健康管理技术的几点认识[J]. 仪器仪表学报, 2018, 8(39): 1-14.
- NIAN F SH. Some understanding of fault prediction and health management technology [J]. Chinese Journal of Scientific Instrument, 2018, 8(39): 1-14.
- [3] 彭宇, 刘大同. 数据驱动故障预测和健康管理综述[J]. 仪器仪表学报, 2014, 35(3): 481-495.
- PENG Y, LIU D T. Data-driven prognostics and health management: A review of recent advances [J]. Chinese Journal of Scientific Instrument, 2014, 35(3): 481-495.
- [4] YUAN M, WU Y, LIN L. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network [C]. 2016 IEEE International Conference on Aircraft Utility Systems (AUS). IEEE, 2016: 135-140.
- [5] ELSAID A E R, EL JAMIY F, HIGGINS J, et al. Optimizing long short-term memory recurrent neural networks using ant colony optimization to predict turbine engine vibration [J]. Applied Soft Computing, 2018, 73: 969-991.
- [6] ZHAO R, YAN R, WANG J, et al. Learning to monitor machine health with convolutional Bi-directional LSTM networks [J]. Multidisciplinary Digital Publishing Institute, 2017, 17(2): 273.
- [7] HE M, ZHOU Y, LI Y, et al. Long short-term memory network with multi-resolution singular value decomposition for prediction of bearing performance degradation [J]. Measurement, 2020, 156: 107582.
- [8] 王国锋, 曹增欢, 冯海生. 基于多阶段退化建模的谐波减速器实时可靠性评估与寿命预测[J]. 天津大学学报(自然科学与工程技术版), 2022, 55(2): 122-132.
- WANG G F, CAO Z H, FENG H SH. Real-time reliability evaluation and life prediction of harmonic reducer based on multi-stage degradation modeling [J]. Journal of Tianjin University (Natural Science & Engineering Technology), 2022, 55(2): 122-132.
- [9] 李潇瀛, 方鸽, 李昌均. 基于 FCM-ARIMA 的多阶段退化设备寿命预测研究[J]. 计算机仿真, 2021, 38(8): 33-36, 74.
- LI X Y, FANG G, LI CH J. Research on life prediction of multi-stage degradation equipment based on FCM-ARIMA [J]. Computer Simulation, 2021, 38(8): 33-36, 74.
- [10] 李娟, 景博, 焦晓璇. 基于 LSTAR 的机载燃油泵多阶段退化建模[J]. 北京航空航天大学学报, 2017, 43(5): 880-886.
- LI J, JING B, JIAO X X. Multi-stage degradation modeling of airborne fuel pump based on LSTAR [J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(5): 880-886.
- [11] 刘君强, 胡东斌, 潘春露. 基于超统计的多阶段航空发动机剩余寿命预测[J]. 北京航空航天大学学报, 2021, 47(1): 56-64.
- LIU J Q, HU D B, PAN CH L. Remaining useful life prediction of multi-stage aero-engine based on super statistics [J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(1): 56-64.
- [12] ZHENG Z, CHEN W, WU X, et al. LSTM network: A deep learning approach for short-term traffic forecast [J]. Iet Intelligent Transport Systems, 2017, 11(2): 68-75.
- [13] XU L, LI Q, YU J, et al. Spatiotemporal predictions of SST time series in China's offshore waters using a regional convolution long short-term memory (RC-LSTM) network [J]. International Journal of Remote Sensing, 2020, 41(9): 3368-3389.
- [14] LIM C K R, MBA D. Switching Kalman filter for failure prognostic [J]. Mechanical Systems and Signal Processing, 2015, 52: 426-435.
- [15] 崔展博, 景博, 焦晓璇. 基于联邦卡尔曼滤波器的容错组合导航系统设计[J]. 电子测量与仪器学报, 2021, 35(11): 143-153.
- CUI ZH B, JING B, JIAO X X. Design of fault-tolerant integrated navigation system based on Federal Kalman filter [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(11): 143-153.
- [16] 崔玲丽, 王鑫, 王华庆. 基于改进开关卡尔曼滤波的轴承故障特征提取方法[J]. 机械工程学报, 2019, 55(7): 44-51.
- CUI L L, WANG X, WANG H Q. Bearing fault feature extraction method based on improved switched Kalman filter [J]. Chinese Journal of Mechanical Engineering, 2019, 55(7): 44-51.
- [17] 景博, 崔展博, 孙宏达. 失效物理与数据驱动融合的燃油泵在线寿命预测[J]. 仪器仪表学报, 2022, 43(3): 68-76.
- JING B, CUI ZH B, SUN H D. Online life prediction of the fuel pump based on failure physics and data-driven fusion [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 68-76.
- [18] 潘晋新, 景博, 焦晓璇. 多应力耦合条件下氧气浓缩器退化建模[J/OL]. 北京航空航天大学学报: 1-14

[2022-03-07].

PAN J X, JING B, JIAO X X. Degradation modeling of oxygen concentrator under multi-stress coupling [J/OL]. Journal of Beijing University of Aeronautics and Astronautics ;1-14[2022-03-07].

作者简介



黄崧琳, 2016 年于空军工程大学获得学士学位, 现为空军工程大学航空工程学院硕士研究生, 主要研究方向为智能检测与健康管理、嵌入式系统设计。

E-mail: 992433266@qq.com

Huang Songlin received his B. Sc. degree from Air Force Engineering University in 2016. Now he is a M. Sc. candidate in Air Force Engineering University. His

main research interests include intelligent detection and health management, embedded system design.



景博, 1996 年于空军工程大学获得硕士学位, 2002 年于西北工业大学获得博士学位, 现为空军工程大学教授, 主要研究方向为故障预测与健康管理、测试性设计、传感器网络与信息融合。

E-mail: jingbo_sensor@163.com

Jing Bo received M. Sc. from Air Force Engineering University in 1996 and Ph. D. from Northwestern Polytechnical University in 2002, respectively. Now she is a professor in Air Force Engineering University. Her main research interests include prognostics and health management, design for testability, sensor network and information fusion.