

文章编号:1671-1637(2019)05-0106-10

## 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

车畅畅,王华伟,倪晓梅,付 强

(南京航空航天大学 民航学院,江苏 南京 210016)

**摘 要:**针对航空发动机性能退化失效的变点和多状态参数的时间序列预测,构建了基于多尺度排列熵算法和长短时记忆神经网络的剩余寿命预测模型;使用多尺度排列熵算法对时间序列进行变点分析,求解出性能退化过程中的突变点,得到了有故障征兆的性能退化起始点;构建了包含多变量的长短时记忆神经网络模型,将多个状态参数代入到模型中得到对应的剩余寿命;将变点后的航空发动机多状态参数和剩余寿命作为样本,代入到长短时记忆神经网络模型中进行多步和多变量的时间序列预测;通过综合航空发动机状态参数变点分析方法和时间序列预测模型,得到最终的剩余寿命预测结果。研究表明:多尺度排列熵算法能够及时监控各个状态参数的变化,当发现状态参数异常时,排列熵的值会发生跳变,从而有助于及时发现故障征兆;长短时记忆神经网络模型通过门控单元对长时间序列数据进行信息筛选,充分保留了有效信息用于时间序列预测;多变量长短时记忆神经网络能够对多状态参数进行同步分析,并且将状态参数直接与剩余寿命相对应,提高了模型效率;通过多尺度排列熵算法和长短时记忆神经网络模型的结合,能够考虑到航空发动机的多退化模式,得到更符合实际退化过程的剩余寿命预测结果;经过算例分析,提出方法的剩余寿命预测的均方根误差为5.3,与长短时记忆神经网络、反向传播神经网络和支持向量机相比,误差分别降低了63%、72%和78%。

**关键词:**航空发动机;剩余寿命预测;性能退化;变点;长短时记忆神经网络;多尺度排列熵

**中图分类号:**V267

**文献标志码:**A

### Residual life prediction of aeroengine based on multi-scale permutation entropy and LSTM neural network

CHE Chang-chang, WANG Hua-wei, NI Xiao-mei, FU Qiang

(School of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, Jiangsu, China)

**Abstract:** Aiming at the change point of aeroengine performance degradation failure and the time series prediction of multi-state parameters, the residual life prediction model based on the multi-scale permutation entropy (MPE) algorithm and long-short term memory (LSTM) neural network was constructed. The change points in time series were analyzed by the MPE algorithm, and the mutation points in the process of performance degradation were solved. The starting point of performance degradation with fault symptoms was obtained. The LSTM neural network model with multi-variables was constructed, and the corresponding residual life was obtained by

收稿日期:2019-05-11

基金项目:国家自然科学基金项目(U1233115, U1833110)

作者简介:车畅畅(1994-),男,河南驻马店人,南京航空航天大学工学博士研究生,从事航空器健康监测研究。

导师简介:王华伟(1974-),女,黑龙江齐齐哈尔人,南京航空航天大学教授,工学博士。

introducing the multi-state parameter data into the model. The aeroengine multi-state parameters and residual life after the change point were taken as samples and substituted into the LSTM neural network model, the multi-step and multi-variable time series prediction was carried out. The final residual life prediction results were obtained by integrating the state parameter change point analysis method and time series prediction model of aeroengine. Research result shows that the MPE algorithm can monitor the changes of state parameters in time. When abnormal state parameters are found, the value of permutation entropy will jump, which is helpful to discover the fault symptoms in time. The LSTM neural network model selects the information of long time series data through the gated units, and the effective information can be fully reserved for the time series prediction. The multi-variable LSTM neural network can synchronously analyze the multi-state parameters, and directly correspond to the residual life, which improves the efficiency of the model. The combination of MPE algorithm and LSTM neural network model can take the multiple degradation modes of aeroengine into account, and the residual life prediction results of aeroengine are more in line with the actual degradation process. After an example analysis, the root mean square error of the proposed residual life prediction method is 5.3, which is 63%, 72% and 78% lower than that of LSTM neural network, back-propagation neural network and support vector machine, respectively. 2 tabs, 12 figs, 32 refs.

**Key words:** aeroengine; residual life prediction; performance degradation; change point; LSTM neural network; multi-scale permutation entropy

**Author resumes:** CHE Chang-chang (1994-), male, doctoral student, 821116775 @ qq. com; WANG Hua-wei(1974-), female, professor, PhD, wang\_hw66@163. com.

## 0 引 言

在目前工业 4.0 大数据背景下,传感器技术、数据处理算法和互联网技术不断发展,为航空发动机的精准化健康管理(Prognostic and Health Management, PHM)提供了工具。PHM 通过监测航空发动机的健康状态预测设备故障,并通过对航空发动机的及时修复或替换来保障设备安全可靠运行。随着状态监测技术的不断发展,能够得到航空发动机随时间变化的表征性能退化的监测参数。在航空发动机性能退化分析中,失效时间可被视为退化过程中指定阈值的首次通过时间,剩余寿命可定义为从当前退化到预先指定的阈值的时间长度。作为 PHM 的重要指标之一,剩余寿命被用于综合衡量航空发动机的健康状况,为进一步的设备维修和更换提供指导<sup>[1]</sup>。

目前有关剩余寿命预测的研究方法主要包括退化分布预测、机器学习、深度学习等。退化分布预测能够根据研究对象的特点,选择合适的分布函数或随机过程对设备性能退化过程进行分布拟合,从而预测剩余寿命。作为最流行的随机建模方法之一,过去几十年来 Wiener 过程在剩余寿命预测方面有

着显著的发展和广泛的应用。Huang 等提出了自适应偏斜 Wiener 模型,使用状态估计的两阶段算法来分析历史信息 and 先验知识,从而预测设备的剩余寿命<sup>[2]</sup>;Hu 等使用 Wiener 过程来构建性能退化过程模型,对剩余寿命进行实时预测<sup>[3]</sup>;Wang 等用 Wiener 过程描述性能退化模型来预测液压泵的剩余使用寿命<sup>[4]</sup>。高斯分布、隐马尔可夫等方法也在剩余寿命预测方面有一定的应用,Zhang 等在集成学习的基础上构建了加权高斯过程回归模型,用于电动机机械传动器的剩余寿命预测<sup>[5]</sup>;Aye 等基于已有的简单均值和协方差函数提出了改进的高斯过程回归模型,用于低速轴承剩余寿命预测<sup>[6]</sup>;Kumar 等基于隐马尔可夫和多项式回归的预测模型对时间序列传感器信号进行聚类以估算刀具的健康状态<sup>[7]</sup>;Chen 等提出了一种具有自相关观测的隐马尔可夫模型,用于处理制造系统的退化建模<sup>[8]</sup>。

机器学习方法通过建立预测模型来分析相关传感数据与性能退化量的关系,从而挖掘出数据特征用于性能退化预测。Rai 等将外加输入的非线性自回归神经网络与小波技术用于轴承的 RUL 估计,同时提出了基于马氏距离的累积和图法,用于克服故障特征高度非单调的问题<sup>[9]</sup>;Liu 等提出了一种

结合局部和全局相似性的贝叶斯极端学习机参数更新算法,用于消除多个不确定性源的影响,并准确预测晶体振荡器的剩余使用寿命<sup>[10]</sup>;Ali 等将单纯形模糊自适应神经网络与威布尔分布相结合,用于精确的轴承剩余寿命预测<sup>[11]</sup>;Zhao 等提出了一种改进的反向传播(Back Propagation, BP)神经网络,用于研究飞机发动机在相同渐变模式下的剩余寿命预测<sup>[12]</sup>;Wu 等提出了基于自适应网络的模糊推理系统和基于多项式曲线拟合的预测模型,用于多传感器信息融合在线剩余寿命预测<sup>[13]</sup>。

深度学习作为目前研究的热点也在剩余寿命预测有了一定的应用。深度学习通过构建多层神经网络来对样本进行前向训练和反向微调,能够更加深入地挖掘样本中的隐含特征,得到更加精确的预测结果。Ren 等基于深度自编码和深度神经网络的新框架网络用于轴承的智能剩余寿命预测<sup>[14]</sup>;Guo 等提出了一种基于递归神经网络的健康指标用于轴承的剩余使用寿命预估<sup>[15]</sup>;Zhang 等将多状态参数转化为健康指数,并通过长短期记忆(Long-Short Term Memory, LSTM)神经网络对健康指数进行时间序列预测,并设置阈值得到其剩余寿命<sup>[16]</sup>;Wu 等构建了变体的 Vanilla-LSTM 模型,用于对复杂环境下的剩余寿命预测<sup>[17]</sup>。

上述模型通过对状态参数和故障信息进行特征提取得到了较为准确的剩余寿命预测结果。其局限性表现在以下方面:忽略了复杂的性能退化过程对剩余寿命的影响,对有些复杂系统,其初始退化量往往较小,而在初始故障征兆出现后,其退化量才开始显著增加,因此,需要找到性能退化过程中的变点,从而得到更准确的预测结果;对数据的质量要求较高,不能够广泛研究同类型发动机的不同退化过程;不能直接构建状态参数与剩余寿命的映射关系,在构建模型时往往是先通过状态参数得到性能退化量,再由性能退化量预测剩余寿命,由于性能退化量的定义和测量主观因素较多,往往有较大误差。

综上所述,本文构建了基于多尺度排列熵(Multi-Scale Permutation Entropy, MPE)和 LSTM 神经网络的剩余寿命预测模型。首先,选择 MPE 算法对多状态参数的性能退化过程进行变点分析,该方法能够挖掘多状态参数中的微小变化规律,对系统整体的运行状况进行监控,及时发现状态参数的异常变化,通过设置合理的阈值得到较为准确的性能退化变点;然后,针对航空发动机状态参数与剩余寿命的映射关系以及航空发动机的状态参数特点,基

于深度学习方法构建了 LSTM 模型,对多状态参数和剩余寿命进行多步时间序列预测,该方法能够对性能退化变点之后的状态监测和剩余寿命信息进行反复的训练和迭代,提高剩余寿命预测的准确度。通过 MPE 和 LSTM 的结合克服了在目前剩余寿命预测的研究中退化模式单一、状态参数较少、模型的确定性要求较高、剩余寿命预测误差较大的问题。

## 1 航空发动机剩余寿命预测

航空发动机具有海量的状态参数、复杂的系统结构和多种故障模式。通常航空发动机性能退化曲线见图 1,可见:在变点之前,航空发动机的初始性能退化量往往较小;在变点之后,系统的初始故障征兆形成,性能退化程度显著增加,因此,从系统刚开始性能退化就进行剩余寿命预测是不合理的,需要找到系统性能退化的变点,才能准确及时地进行性能退化预测<sup>[18-20]</sup>。本文采用多尺度排列熵算法对系统的多个状态参数进行初始变点分析,实时监控状态参数的变化,及时发现排列熵异常变化的故障征兆点,并通过设置阈值,确定变点出现的时间点。




图 1 航空发动机性能退化曲线

Fig. 1 Performance degradation curve of aeroengine

与此同时,传统的性能退化分析大多是通过性能退化量进行分布拟合,然后确定相应的性能退化阈值,得到一组失效时间,从而再反向推导出对应的剩余寿命,并根据对应失效时间得出失效分布密度函数,得到系统性能退化失效的统计学规律。然而对于一些结构复杂的设备,难以准确统计其性能退化量并进行分布拟合,因此,本文直接对多性能状态参数和剩余寿命的对应关系进行分析,通过 LSTM 的门控制和神经元组合来进行时间序列的多步和多参数预测,从而得到长时间高准确度的性能退化失效的剩余寿命预测结果。

## 2 基于 MPE 的性能退化变点分析

排列熵算法是针对时间序列本身所具有的空间特性而提出的信号突变检测方法,具有计算简单、抗噪声能力较强、时间敏感性强、突变信息识别性高、输出结果直观等优点。作为一种非线性分析方法,其应用领域广泛,效果明显,对于实现复杂机电系统异常状态的实时在线监测有重要作用<sup>[21]</sup>。

### 2.1 排列熵定义

设包含  $n$  个状态参数的一维时间序列  $\mathbf{X}$  为

$$\mathbf{X} = (x_1, x_2, \dots, x_n) \quad (1)$$

式中:  $x_i$  为第  $i$  个元素,  $i=1, 2, \dots, n$ 。

采用相空间重构延迟坐标法对  $\mathbf{X}$  中任一元素  $x_i$  进行相空间重构,对每个采样点取其连续的  $m$  个样本点,得到点  $x_i$  的重构向量  $\mathbf{X}_i$  为

$$\mathbf{X}_i = (x_i, x_{i+l}, \dots, x_{i+(m-1)l}) \quad (2)$$

式中:  $m, l$  分别为重构维数和延迟时间。

使用  $j_1, j_2, \dots, j_m$  表示  $\mathbf{X}_i$  中的各个状态参数所在的索引,将  $\mathbf{X}_i$  按升序排列可以得到:  $x_{i+(j_1-1)l} \leq x_{i+(j_2-1)l} \leq \dots \leq x_{i+(j_m-1)l}$ <sup>[22]</sup>。其中如果  $\mathbf{X}_i$  中的 2 个状态参数相等则按照先后顺序排列,这样对于任意的  $\mathbf{X}_i$  都能得到排列  $\mathbf{S}$  为

$$\mathbf{S} = (S_1, S_2, \dots, S_k) \quad (3)$$

式中:  $S_g$  为第  $g$  种排列顺序,  $g=1, 2, \dots, k$ 。

对每种排列情况出现次数进行统计得到每种序列出现的概率,关系如下

$$\sum_{g=1}^k p_g = 1 \quad (4)$$

式中:  $p_g$  为第  $g$  种排列顺序出现的概率。

得到序列归一化后的排列熵为<sup>[23]</sup>

$$H = \frac{-\sum_{g=1}^k p_g \ln(p_g)}{\ln(m!)} \quad (5)$$

式中:  $H$  为列归一化后的排列熵,代表了时间序列  $\mathbf{X}_i$  的随机性,其值越小说明该时间序列越规则,反之则该时间序列越具有随机性。

### 2.2 多尺度排列熵定义

为了避免排列熵过于敏感,提高模型的稳定性,引入多尺度排列熵的概念。对时间序列进行粗粒化处理。得到粗粒化序列的表达式<sup>[24]</sup>为

$$y_\tau = \frac{1}{\tau} \sum_{i=(r-1)\tau+1}^{\tau} x_i \quad (6)$$

式中:  $y_\tau$  为第  $r$  个粗粒化序列在尺度因子  $\tau$  下的粗粒化序列,其中  $r=1, 2, \dots, n/\tau$ ,其最大值一般为 10,

当  $\tau=1$  时,粗粒化序列即为原始序列,当  $\tau>1$  时,原始序列被粗粒化为长度为  $n/\tau$  的粗粒序列。

计算每个粗粒化序列的排列熵,得到与多个尺度因子对应的排列熵的过程即称为多尺度排列熵分析<sup>[25]</sup>。

### 2.3 性能退化变点分析

设备状态参数在故障征兆出现前后其排列熵往往都会有较为明显的上升,因此,可以选取全寿命周期的设备运行状态参数作为样本,从头开始逐步统计其多尺度排列熵的变化。定义  $\beta$  为多尺度排列熵的短时变化率,则有

$$\beta_\gamma = \frac{H_\gamma - H_{\gamma-\theta}}{\theta} \quad \gamma > \theta \quad (7)$$

式中:  $\beta_\gamma$  为在  $\gamma$  时刻的多尺度排列熵的短时变化率;  $H_\gamma$  为某一个状态参数在  $\gamma$  时刻的多尺度排列熵;  $\theta$  为松弛因子。

当没有故障征兆时,多尺度排列熵的值较为稳定;当有故障征兆时,多尺度排列熵的值会突然降低,因此,本文定义  $\theta=5$ ,当  $\beta_\gamma < -0.02$  时,  $\gamma$  所对应的时刻为变点。

## 3 基于 LSTM 的时间序列预测

LSTM 是在循环神经网络 (Recurrent Neural Network, RNN) 基础上的改进,典型的 RNN 结构见图 2,可见:  $\mathbf{a}=(a_1, a_2, \dots, a_n)$  为输入;  $\mathbf{b}=(b_1, b_2, \dots, b_n)$  为输出;  $\mathbf{h}=(h_1, h_2, \dots, h_n)$  为隐藏层。通过多个序列的组合和前后连接, RNN 能够根据当前信息和历史信息来进行预测。然而,随着神经网络的复杂度逐渐提高, RNN 往往出现信息过载和局部过优化的问题。作为 RNN 的变体, LSTM 能够利用门控制单元使网络的信息提取更有选择性,从而有效地提高信息的利用率和时间序列预测的准确率<sup>[26]</sup>。

LSTM 通过引入长时记忆单元、输入门、遗忘门、输出门、短时记忆单元等概念,让整个网络模型




图2 RNN 结构

Fig. 2 Structure of RNN



的运行时间更短、误差更小。一个典型的 LSTM 模型结构<sup>[27]</sup>见图 3, 可见:  $C_t$ 、 $s_t$  分别为  $t$  时刻长时记忆单元和短时记忆单元;  $\tilde{C}_t$  为  $t$  时刻候选长时记忆单元;  $\otimes$ 、 $\oplus$  分别为元素的乘法与加法;  $f_t$  为  $t$  时刻的遗忘门单元;  $u_t$  为  $t$  时刻的输入门单元;  $o_t$  为  $t$  时刻的输出门单元;  $a_t$  为  $t$  时刻的输入;  $b_t$  为  $t$  时刻的输出; Sigmoid( $\cdot$ )、Tanh( $\cdot$ ) 均为常用的激活函数, 以  $\epsilon$  为自变量, 分别表示为

$$\text{Sigmoid}(\epsilon) = \frac{1}{1 + e^{-\epsilon}} \quad (8)$$

$$\text{Tanh}(\epsilon) = \frac{e^{\epsilon} - e^{-\epsilon}}{e^{\epsilon} + e^{-\epsilon}} \quad (9)$$

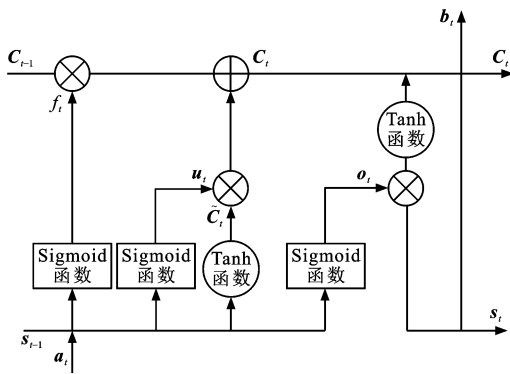


图 3 LSTM 结构

Fig. 3 Structure of LSTM

LSTM 中的遗忘门被用来删除  $t$  时刻不需要的信息, 形式为

$$f_t = \text{Sigmoid}\{W_1[C_{t-1}, s_{t-1}, a_t] + v_1\} \quad (10)$$

式中:  $W_1$  为遗忘门权重;  $v_1$  为遗忘门偏差。

遗忘门会输出一个 0~1 的数值给  $t-1$  时刻的长时记忆单元  $C_{t-1}$ , 1 表示完全保留, 0 表示完全舍弃。遗忘门使用 Sigmoid( $\cdot$ ) 作为激活函数<sup>[28]</sup>。

候选长时记忆单元保存着未经处理的输入数据, 形式为

$$\tilde{C}_t = \text{Tanh}\{W_2[s_{t-1}, a_t] + v_2\} \quad (11)$$

式中:  $W_2$  和  $v_2$  分别为候选值权重和候选值误差。

输入门被用来确定被存放在长时记忆单元中的新信息, 为了便于计算, 定义  $t$  时刻的输入门  $u_t$  为

$$u_t = 1 - f_t \quad (12)$$

综上, 引入遗忘门  $f_t$  和输入门  $u_t$  可以得到  $t$  时刻长时记忆单元  $C_t$  的形式为

$$C_t = f_t C_{t-1} + u_t \tilde{C}_t \quad (13)$$

输出门决定着短时记忆单元, 形式为

$$o_t = \text{Sigmoid}\{W_3[C_t, s_{t-1}, a_t] + v_3\} \quad (14)$$

$$s_t = b_t = o_t \text{Tanh}(C_t) \quad (15)$$

式中:  $W_3$  为输出门权重;  $v_3$  为输出门偏差。

### 3.1 多变量的 LSTM 网络结构

为了对多变量进行时间序列预测, 在经典 LSTM 模型的基础上构建了多变量的 LSTM 结构, 用于多状态参数的时间序列预测<sup>[29]</sup>。选取其中 2 个序列进行分析见图 4, 可见:  $a(n)_1$ 、 $a(n)_2$  分别为时间序列 1 中第  $n$  个状态参数的输入和输出;  $a(n)_2$ 、 $a(n)_3$  分别为时间序列 2 中第  $n$  个状态参数的输入和输出。每个序列对应的子序列的输出为预测的下一时间序列的值,  $b_1$  为序列 1 的前一个序列的输出值,  $b_2$ 、 $b_3$  为序列 1、2 的输出值。通过多个变量的信息传递能够更加全面地反映系统的状态, 得到较为准确的预测值。

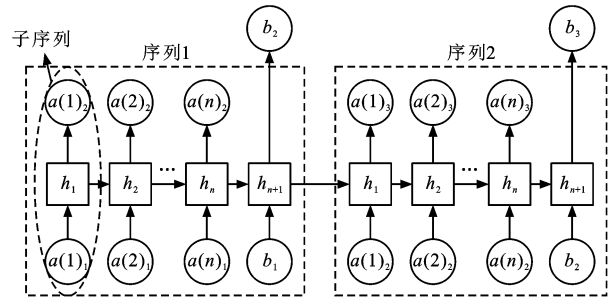


图 4 多变量 LSTM 模型

Fig. 4 Multi-variable LSTM model

在多步预测时如果只对剩余寿命进行时间序列预测, 往往会造成误差越来越大, 不能够充分考虑多状态参数的变化情况, 因此, 提出了将每个变量所在子序列的输出作为下一个 LSTM 单元对应变量的输入。这样就能够通过反复迭代来对多状态参数和剩余寿命进行更加准确的长期时间预测。

### 3.2 LSTM 的训练流程

多变量 LSTM 模型的训练流程包括 LSTM 数据准备、定义和拟合模型、模型误差计算 3 个部分。

#### 3.2.1 LSTM 数据准备

本文中将历史状态参数与剩余寿命作为输入, 将剩余寿命的时间序列预测作为输出。同时采用滑动窗口法来处理时间序列数据, 使用先前的时间步长来预测下一个时间步长, 时间步长是指每个特征的信息能够传递给下一个特征的长度<sup>[30]</sup>。首先, 将准备好的数据集分成训练集和测试集; 然后, 将训练集和测试集分成输入和输出变量; 最后, 将输入重构为 LSTM 预期的 3D 格式, 即[样本, 时间步长, 变量个数]。

#### 3.2.2 定义和拟合模型

构建 LSTM 时需要定义 LSTM 的层数、神经元个数、损失函数、总样本训练次数 (Epoch)、训练

样本批量数、模型参数的初始值等。将均方根误差(Root Mean Squares Error, RMSE)函数作为损失函数,在训练过程中通过求解误差函数偏导数,并且采用随机梯度下降的方法来更新模型参数,从而实现误差的逐层反向传播,微调整个模型参数。

### 3.2.3 模型评估

在模型拟合后,可以输入测试集,并通过计算剩余寿命预测值和真实值之间的误差  $E$  来检验模型的预测效果,定义为

$$E = \sqrt{\sum_{\lambda=1}^{\varphi} (d_{\lambda} - \tilde{d}_{\lambda})^2 / \varphi} \quad (16)$$

式中: $d_{\lambda}$  和  $\tilde{d}_{\lambda}$  分别为第  $\lambda$  个样本的真实剩余寿命和预测剩余寿命; $\varphi$  为样本个数。

## 4 基于 MPE 和 LSTM 的剩余寿命预测模型

基于 MPE 和 LSTM 的剩余寿命预测模型见图 5,可见:模型主要分为样本采集、基于 MPE 的变点分析和基于 LSTM 的时间序列预测 3 个部分。通过合适的流程设计,能够获得较为准确的实时剩余寿命预测结果。模型的详细流程如下。

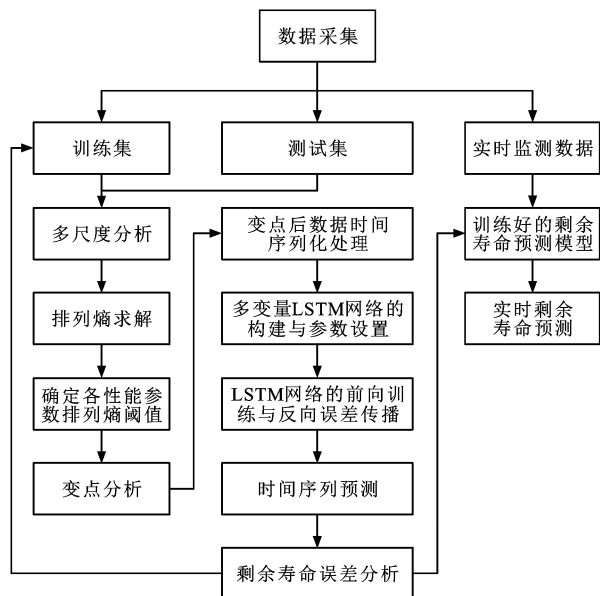


图5 基于 LSTM 和 MPE 的航空发动机剩余寿命预测

Fig. 5 Residual life prediction of aeroengine based on LSTM and MPE

(1) 样本采集。将采集到的样本分为训练集、测试集和实时状态参数。首先,通过训练集来训练 MPE 和 LSTM 模型;然后,将测试集代入模型中进行误差分析,当误差未达到要求时则继续训练模型;最后,将实时状态参数代入到训练好的剩余寿命模

型中得到实时剩余寿命预测的结果。

(2) 基于 MPE 的变点分析。通过对故障数据进行多尺度分析和排列熵求解,能够得到航空发动机各个状态参数的排列熵阈值,从而应用于状态参数变点分析。

(3) 基于 LSTM 的时间序列预测。构建了 LSTM 模型,用于剩余寿命的时间序列预测。首先,采用滑动窗口法将变点后的数据进行时间序列化,得到适合模型处理的时间序列样本;然后,构建多变量和多步的 LSTM 模型进行时间序列预测,并进行相关参数设置;最后,通过前向传播和反向误差传播对 LSTM 模型进行训练,从而得到剩余寿命的时间序列预测结果。

## 5 实例分析

本文使用 C-MAPSS 进行发动机退化仿真。其中发动机模型和组件中共有 9 个主要部件:风扇、燃烧室、发动机低压转子、低压涡轮、低压压缩机、高压压缩机、高压转子、高压涡轮、尾喷管<sup>[31-32]</sup>。原始数据包括 21 个状态参数,如表 1 所示。通过试验仿真可以将发动机每运行一段时间作为一个循环,并统

表 1 航空发动机状态参数 C-MAPSS 仿真

Tab. 1 C-MAPSS simulation of aeroengine state parameters

状态参数	含义
$P_1$	风扇入口总温度
$P_2$	低压压缩机进气道总温度
$P_3$	高压压缩机进气道总温度
$P_4$	低压涡轮进气道总温度
$P_5$	风机入口压力
$P_6$	旁通管总压力
$P_7$	高压压缩机出口处总压力
$P_8$	物理风机转速
$P_9$	物理核心速度
$P_{10}$	发动机压力比
$P_{11}$	高压压缩机出口静压
$P_{12}$	燃料流量比率
$P_{13}$	修正风机转速
$P_{14}$	修正核心转速
$P_{15}$	涵道比
$P_{16}$	燃烧器的燃料-空气比
$P_{17}$	放气热含量
$P_{18}$	风扇转速要求
$P_{19}$	修正风扇转速要求
$P_{20}$	高压涡轮冷却剂释放速度
$P_{21}$	低压涡轮冷却剂释放速度

计在该循环下的状态参数,从而得到发动机从开始运行到失效的全寿命周期内的状态参数。

### 5.1 基于 MPE 的航空发动机变点分析

本文研究的航空发动机状态参数有 21 个,选取其中 5 个状态参数的时间序列进行多尺度排列熵分析,结果见图 6,可见:  $P_1$ 、 $P_2$ 、 $P_3$  和  $P_5$  的排列熵值在尺度因子从 1 增加到 10 的过程中分别下降了 14%、19%、15% 和 12%,而  $P_4$  的排列熵值变化不大。这说明随着尺度的增大,大部分状态参数的粗粒化序列的复杂度和随机性都会降低。另外,不同状态参数的多尺度排列熵随着尺度因子的增加有不同的下降速率,因此,为了更好进行突发失效预测,采用多尺度排列熵均值作为评价指标。




图 6 尺度因子与多尺度排列熵关系

Fig. 6 Relationship between scale factor and MPE

选取状态参数  $P_3$  的一组全寿命周期内的样本,该状态参数归一化后随航空发动机循环次数的变化见图 7,可见:随着循环次数从 0 增加到 190,归一化后的状态参数从 0 增加到 1 附近,同时有较大的振荡幅度。该时间序列经过多尺度排列熵求解的结果见图 8,可见:在前 75 个循环,多尺度排列熵均值处于随机无序状态,数值在 0.96 附近小幅波动;从 85 循环到 120 循环,由于出现故障征兆,多尺度排列熵均值先从 0.95 跳变到极小值 0.41,再回归到 0.91;从 160 循环到 190 循环,多尺度排列熵均值先从 0.9 跳变到最低值 0.35,再回归到 0.93。

综上所述,状态参数在变化过程中表现出不同的空间复杂性,在有故障征兆时,状态参数时间序列的多尺度排列熵均值也会发生明显的跳变。通过 MPE 模型能够对各状态参数的变化及时监控,当发现状态参数异常时及时预警,有助于及时发现故障征兆,为后续的时间序列预测打下基础,提高剩余寿命预测的准确性,进而提高整个系统的安全性和可靠性。




图 7 状态参数  $P_3$  变化曲线

Fig. 7 Change curve of state parameter  $P_3$




图 8 多尺度排列熵变化曲线

Fig. 8 Change curve of MPE

### 5.2 基于 LSTM 的航空发动机时间序列预测

在 MPE 变点分析的基础上,选取变点之后的时间序列代入到 LSTM 模型进行时间序列预测。其中样本中包括 21 个状态参数的时间序列和对应的剩余寿命。训练样本数为 1 000,测试样本数为 500。设置网络为 2 层,每层节点为 50 个,设置训练样本批量数为 10(每 10 个连续时间序列样本为一组进行训练),各网络的初始参数为随机极小值。

通过将构建好的训练样本代入到 LSTM 模型中进行训练,其中样本训练和预测的误差定义见图 9,可见:训练误差为在训练过程中将训练集中的状态参数和剩余寿命标签输入到模型中,经过参数




图 9 样本训练、测试和预测误差

Fig. 9 Training, testing and prediction errors of samples

优化得到的预测值与剩余寿命标签的平均绝对误差 (Mean Absolute Error, MAE);测试误差为将测试集的状态参数输入到训练后的模型中得到的预测值与测试集剩余寿命标签的 MAE;样本预测误差为在输入一组实时状态参数后,后续时间序列的剩余寿命预测值与真实值的 RMSE。

训练 100 个 Epoch,并在每个 Epoch 后统计一次 MAE,得到的样本总体训练误差和测试误差的变化见图 10,可见:随着训练次数从 0 增加到 100,训练误差从 0.080 降低到 0.001,测试误差从 0.492 降低到 0.037。




图 10 剩余寿命预测训练误差与测试误差

Fig. 10 Training error and testing error of residual life prediction

选取一组在变点后的时间序列样本到训练好的 LSTM 模型中,定义当前循环次数为 0,得到统计的后续剩余寿命预测值见图 11,可见:LSTM 的剩余寿命预测值与真实值较为接近, RMSE 从 0.37 逐渐增加到 3.69 左右,基本符合剩余寿命预测的精度要求。




图 11 LSTM 剩余寿命预测结果

Fig. 11 Prediction results of residual life with LSTM

### 5.3 MPE-LSTM 的航空发动机剩余寿命预测

选取 500 个全寿命周期样本,对 LSTM 模型和本文提出的 MPE-LSTM 融合模型分别进行剩余寿




图 12 剩余寿命预测对比

Fig. 12 Comparison of residual life prediction results

命预测,选取其中一组的预测结果见图 12,可见:变点在第 125 循环;MPE-LSTM 模型能够及时发现变点,预测结果与实际情况大致相符;LSTM 不能考虑变点的影响,预测偏差较大。选取传统 BP 神经网络和支持向量机 (Support Vector Machine, SVM) 网络进行剩余寿命预测,得到预测结果如表 2 所示,其中 MPE-LSTM 的剩余寿命预测的 RMSE 为 5.3,与 LSTM、BP 和 SVM 相比,误差分别下降了 63%、72% 和 78%。可以看出 BP 神经网络和 SVM 因不能考虑到性能退化变点和时间序列的前后关联性,整体剩余寿命预测的结果误差很高,不符合实际精度要求。通过 LSTM 和 MPE 的结合不仅能够准确得到性能退化变点,而且能够充分考虑时间序列前后联系,得到较为准确的剩余寿命预测结果。

表 2 剩余寿命预测结果对比

Tab. 2 Comparison of residual life prediction results

方法	RMSE 值
BP	23.6
LSTM	14.4
SVM	19.3
MPE-LSTM	5.3

## 6 结 语

(1)针对航空发动机初始退化较小,出现故障征兆时的退化量较为明显的特点,本文使用 MPE 算法对航空发动机状态参数进行变点分析,从而敏锐地捕捉到状态参数异常变化点,较为准确地判断故障征兆起始时刻。

(2)针对航空发动机性能退化过程较为复杂,难以通过性能退化量的分布拟合来预测剩余寿命的问题,本文基于深度学习方法构建了多变量和多步的 LSTM 模型,对性能退化变点后时间序列



中的状态参数和对应剩余寿命进行直接深入的时间序列预测。

(3) 基于 MPE 算法和 LSTM 模型构建了剩余寿命预测模型, 该模型能够通过对海量状态参数的变点分析和时间序列预测得到较为准确的实时剩余寿命预测结果, 实现工业 4.0 背景下航空发动机健康管理的智能化、高效化和精准化。

(4) 本文对多状态参数的权重分配问题未作详细的研究, 未来应该根据实际工程需要, 调整状态参数权重, 从而将工程经验与智能算法相结合, 得到更准确的航空发动机剩余寿命预测结果。

#### 参 考 文 献 :

#### References :

- [1] 马小骏, 任淑红, 左洪福, 等. 基于 LS-SVM 算法和性能可靠性的航空发动机在翼寿命预测方法[J]. 交通运输工程学报, 2015, 15(3): 92-100.  
MA Xiao-jun, REN Shu-hong, ZUO Hong-fu, et al. Prediction method of aero-engine life on wing based on LS-SVM algorithm and performance reliability[J]. Journal of Traffic and Transportation Engineering, 2015, 15(3): 92-100. (in Chinese)
- [2] HUANG Ze-yi, XU Zheng-guo, KE Xiao-jie, et al. Remaining useful life prediction for an adaptive skew-Wiener process model[J]. Mechanical Systems and Signal Processing, 2017, 87: 294-306.
- [3] HU Yao-gang, LI Hui, SHI Ping-ping, et al. A prediction method for the real-time remaining useful life of wind turbine bearings based on the Wiener process [J]. Renewable Energy, 2018, 127: 452-460.
- [4] WANG Xing-jian, LIN Si-ru, WANG Shao-ping, et al. Remaining useful life prediction based on the Wiener process for an aviation axial piston pump[J]. Chinese Journal of Aeronautics, 2016, 29(3): 779-788.
- [5] ZHANG Yu-jie, PENG Xi-yuan, PENG Yu, et al. Weighted bagging Gaussian process regression to predict remaining useful life of electro-mechanical actuator[C]//IEEE. 2016 Prognostics and System Health Management Conference. New York: IEEE, 2016: 1-6.
- [6] AYE S A, HEYNS P S. An integrated Gaussian process regression for prediction of remaining useful life of slow speed bearings based on acoustic emission[J]. Mechanical Systems and Signal Processing, 2017, 84: 485-498.
- [7] 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 and Industrial Engineering, 2019, 128: 1008-1014.
- [8] CHEN Zhen, LI Ya-ping, XIA Tang-bin, et al. Hidden Markov model with auto-correlated observations for remaining useful life prediction and optimal maintenance policy[J]. Reliability Engineering and System Safety, 2019, 184: 123-136.
- [9] RAI A, UPADHYAY S H. The use of MD-CUMSUM and NARX neural network for anticipating the remaining useful life of bearings[J]. Measurement, 2017, 111: 397-410.
- [10] LIU Zhen, CHENG Yu-hua, WANG Pan, 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.
- [11] ALI J B, CHEBEL-MORELLO B, SAIDI L, et al. Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network [J]. Mechanical Systems and Signal Processing, 2015, 56/57: 150-172.
- [12] ZHAO Ze-qi, LIANG Bin, WANG Xue-qian, et al. Remaining useful life prediction of aircraft engine based on degradation pattern learning [J]. Reliability Engineering and System Safety, 2017, 164: 74-83.
- [13] WU Jun, SU Yong-heng, CHENG Yi-wei, et al. Multi-sensor information fusion for remaining useful life prediction of machining tools by adaptive network based fuzzy inference system[J]. Applied Soft Computing, 2018, 68: 13-23.
- [14] REN Lei, SUN Ya-qiang, CUI Jin, et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks [J]. Journal of Manufacturing Systems, 2018, 48: 71-77.
- [15] GUO Liang, LI Nai-peng, JIA Feng, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98-109.
- [16] ZHANG Jian-jing, WANG Peng, YAN Ru-qiang, et al. Long short-term memory for machine remaining life prediction[J]. Journal of Manufacturing Systems, 2018, 48: 78-86.
- [17] WU Yi-ting, YUAN Mei, DONG Shao-peng, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks[J]. Neurocomputing, 2018, 275: 167-179.
- [18] WEN Yu-xin, WU Jian-guo, DAS D, et al. Degradation modeling and RUL prediction using Wiener process subject to multiple change points and unit heterogeneity[J]. Reliability Engineering and System Safety, 2018, 176: 113-124.
- [19] SON J, ZHANG Yi-lu, SANKAVARAM C, et al. RUL prediction for individual units based on condition monitoring signals with a change point [J]. IEEE Transactions on Reliability, 2015, 64(1): 182-196.
- [20] WANG Ping-ping, TANG Yin-cai, BAE S J, et al. Bayesian analysis of two-phase degradation data based on change-point Wiener process [J]. Reliability Engineering and System Safety, 2018, 170: 244-256.
- [21] LIU Lian-sheng, WANG Shao-jun, LIU Da-tong, et al. Quantitative selection of sensor data based on improved permutation entropy for system remaining useful life prediction[J]. Microelectronics Reliability, 2017, 75: 264-270.
- [22] ZHANG Xiao-yuan, LIANG Yi-tao, ZHOU Jian-zhong, et al. A novel bearing fault diagnosis model integrated permutation

- entropy, ensemble empirical mode decomposition and optimized SVM[J]. *Measurement*, 2015, 69: 164-179.
- [23] LI Yong-bo, XU Min-qiang, WEI Yu, et al. A new rolling bearing fault diagnosis method based on multiscale permutation entropy and improved support vector machine based binary tree[J]. *Measurement*, 2016, 77: 80-94.
- [24] 姚德臣, 杨建伟, 程晓卿, 等. 基于多尺度本征模态排列熵 SA-SVM 的轴承故障诊断研究[J]. *机械工程学报*, 2018, 54(9): 168-176.
- YAO De-chen, YANG Jian-wei, CHENG Xiao-qing, et al. Railway rolling bearing fault diagnosis based on multi-scale IMF permutation entropy and SA-SVM classifier[J]. *Journal of Mechanical Engineering*, 2018, 54(9): 168-176. (in Chinese)
- [25] AZAMI H, ESCUDERO J. Improved multiscale permutation entropy for biomedical signal analysis: interpretation and application to electroencephalogram recordings[J]. *Biomedical Signal Processing and Control*, 2016, 23: 28-41.
- [26] ZHANG Yong-zhi, XIONG Rui, HE Hong-wen, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(7): 5695-5705.
- [27] TAN J H, HAGIWARA Y, PANG W, et al. Application of stacked convolutional and long short-term memory network for accurate identification of CAD ECG signals[J]. *Computers in Biology and Medicine*, 2018, 94: 19-26.
- [28] YANG Jing, GUO Ying-qing, ZHAO Wan-li. Long short-term memory neural network based fault detection and isolation for electro-mechanical actuators[J]. *Neurocomputing*, 2019, 360: 85-96.
- [29] LEI Jin-hao, LIU Chao, JIANG Dong-xiang. Fault diagnosis of wind turbine based on long short-term memory networks[J]. *Renewable Energy*, 2019, 133: 422-432.
- [30] ZHANG Bin, ZHANG Shao-hui, LI Wei-hua. Bearing performance degradation assessment using long short-term memory recurrent network[J]. *Computers in Industry*, 2019, 106: 14-29.
- [31] SMITH W A, RANDALL R B. Rolling element bearing diagnostics using the Case Western Reserve University data: a benchmark study[J]. *Mechanical Systems and Signal Processing*, 2015, 64/65: 100-131.
- [32] BOUDIAF A, MOUSSAOUI 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 and Prevention*, 2016, 16(2): 271-284.