

数据驱动的发动机剩余使用寿命直接预测*

梁佳鑫^{1,2}, 马志赛^{1,2}, 丁千^{1,2}, 隋鑫³

(1. 天津大学机械工程学院 天津, 300350) (2. 天津市非线性动力学与控制重点实验室 天津, 300350)

(3. 中国运载火箭技术研究院 北京, 100076)

摘要 针对发动机剩余使用寿命(remaining useful life, 简称RUL)间接预测时失效阈值难以准确设置、直接预测时监测数据与RUL之间复杂映射关系难以建立的问题, 提出了一种改进的发动机RUL直接预测方案。首先, 为降低监测数据中的噪声干扰, 在多传感器数据融合阶段引入滑动平均滤波对一维健康指标进行降噪以提升数据质量; 其次, 为改善退化模式特征的提取效果, 提出指数函数与二次多项式函数混合交替的优化策略, 通过相关向量机模型学习得到退化模式特征与RUL之间的直接映射关系, 实现数据驱动的发动机RUL在线直接预测; 最后, 基于航空发动机的仿真数据集对提出方案的有效性进行验证。结果表明, 所提出的直接预测方案无需设置失效阈值或估计未知的健康状态, 能够显著提升发动机RUL预测精度, 其均方根误差和Score评分函数指标值均有明显降低, 有助于避免发动机服役后期的滞后预测问题。

关键词 剩余使用寿命; 特征提取; 相关向量机; 数据驱动方法

中图分类号 TH17; V263.6

引言

发动机作为飞行器的重要部件, 长期运行在高温、高压、高转速以及高负荷的环境中, 其性能会随着服役时间的延长而发生退化, 甚至影响飞行安全^[1-2]。因此, 开展准确的剩余使用寿命预测对制定检修策略、减小维护成本、降低故障风险和确保机械设备安全稳定运行具有重要意义^[3-4]。RUL预测方法中, 基于数据驱动的方法不需要关注复杂的物理失效机理, 对使用者经验的要求度也较低, 是现阶段的研究热点^[5-7]。

在基于数据驱动的RUL预测方法中, 多传感器数据比单传感器数据能更好地捕捉并反映发动机的状态变化, 可提升预测结果的准确性。彭鸿博等^[8]融合多传感器数据构建健康指标, 利用相关向量机(relevance vector machine, 简称RVM)模型实现了发动机的RUL预测。陈雄姿等^[9]融合多传感器数据并结合RVM回归和离线辨识方法, 得到发动机退化模型参数, 预测了发动机的RUL。以上方法为间接预测方案, 需预设失效阈值, 静态阈值设置不准确会带来较大的预测误差, 动态自适应阈值又难以选定。因此, 失效阈值的设置已成为间接预测方案

的瓶颈问题。

有学者提出RUL的直接预测方案, 即借助机器学习算法直接学习传感器监测数据与RUL之间的映射关系。文献[10]利用支持向量机(support vector machine, 简称SVM)建立了从传感器监测数据到RUL之间的映射关系, 准确预测了发动机的RUL。Xu等^[11]分别采用D-S证据理论回归、循环神经网络和SVM学习传感器监测数据与RUL之间的映射关系, 并将3种预测结果进行融合, 有效提升了发动机的RUL预测精度。上述预测方案在退化形式简单、退化速率恒定时较为有效。若退化形式复杂, 直接建立监测数据与RUL之间的映射关系难度较大。因此, 部分学者提出了先从数据中挖掘退化模式特征, 再建立其与RUL之间的直接映射关系的方法。Khelif等^[12]将监测数据分割成多个时间窗口, 先使用线性回归模型提取窗口内数据的退化模式特征, 再将其输入SVM模型得到发动机的RUL。周俊^[13]先对窗口数据进行二次多项式函数拟合, 提取退化模式特征, 再输入小波RVM模型得到发动机的RUL。研究表明, 利用机器学习算法建立退化模式特征与RUL之间的非线性映射关系, 能够取得较好的预测效果。

* 国家自然科学基金资助项目(12272258, 11802201); 航空科学基金资助项目(2020Z009048001); 天津市青年人才托举工程资助项目(TJSQNTJ-2020-01)

收稿日期: 2023-08-09; 修回日期: 2023-11-16

除了发展机器学习算法以增强非线性映射能力之外,还需要重点关注退化模式特征的提取方式。牟含笑等^[14]利用双向长短期记忆网络提取健康指标的时序信息和退化趋势,提高了RUL预测的准确度。张晓东等^[15]利用双向长短期记忆网络提取时序特征,卷积长短期记忆网络提取时空特征,提高了RUL预测精度。这些特征提取方式大多依赖深度神经网络,存在模型结构复杂、模型参数难以确定且计算量较大等问题。

笔者提出一种改进的发动机RUL直接预测方案。首先,对发动机多传感器数据进行融合,得到一维健康指标,并采用滑动平均滤波进行降噪;其次,发展指数函数与二次多项式函数混合交替策略进行退化模式特征的提取,以达到优化退化模式和特征提取方式、提升RUL预测精度的目的;最后,通过航空发动机的仿真数据集完成所提出方案的有效性验证。

1 多传感器数据融合和特征提取

1.1 多传感器数据融合

传感器监测数据通常是多维的,为量化发动机的退化程度,考虑利用线性回归模型将多维数据融合为一维健康指标(health indicator,简称HI)来表征其健康状态^[16-17]。这样不仅有效降低发动机预测模型的复杂度、保留了原始退化趋势,还不会对预测精度造成显著影响。

假设 $s_i^j(t)$ 为第 i 个($1 \leq i \leq L$)发动机的第 j 个($1 \leq j \leq M$)传感器在 $t(t \geq 0)$ 时刻采集到的性能退化监测数据, L 为被监测的发动机个数。采用线性回归模型^[9],融合多传感器监测数据后第 i 个发动机的一维HI可表示为

$$HI_i(t) = \theta_0 + \sum_{j=1}^M \theta_j s_i^j(t) + \epsilon_i \quad (1)$$

其中: θ_0 为偏置项; θ_j 为第 j 个传感器对应的模型参数; M 为表征发动机退化的传感器个数; ϵ_i 为第 i 个发动机的噪声值。

为了求解式(1),需要提前构建训练样本集。挑选发动机运行开始阶段的前 D_1 个时刻和结束阶段的后 D_0 个时刻的监测数据,分别存储在矩阵 $S_1 \in \mathbb{R}^{D_1 \times M}$ 和 $S_0 \in \mathbb{R}^{D_0 \times M}$ 中,对应的HI分别设置为元素全为1的向量 $H_1 \in \mathbb{R}^{D_1 \times 1}$ 和零向量 $H_0 \in \mathbb{R}^{D_0 \times 1}$ 。通常 $D_1 = D_0 \approx 5\% N_i$, N_i 为第 i 个发动机的性能退化监测数据的长度。通过上述操作,得到用于训练

的输入矩阵 $S = [S_1; S_0]$ 和输出向量 $H = [H_1; H_0]$ 。将 S^* 设置为元素全为1的 $(D_1 + D_0) \times 1$ 维向量,与输入矩阵 S 合并后,得到 $\bar{S} = [S^*, S]$ 。根据输入-输出关系 $H = \bar{S}\theta$,得到

$$\theta = (\bar{S}^T \bar{S})^{-1} \bar{S}^T H \quad (2)$$

其中: $\theta = (\theta_0, \theta_1, \dots, \theta_M)^T$,为线性回归模型的参数。

假设第 i 个发动机对应的监测时刻为 $t_i = \{t_{i,0}, t_{i,1}, \dots, t_{i,N_i}\}$,在求得线性回归模型参数之后,基于监测数据离线或在线获得HI序列,即

$$h_i = \{h_{i,0}, h_{i,1}, h_{i,2}, \dots, h_{i,N_i}\} \quad (3)$$

其中: $h_{i,k} = HI_i(t_{i,k}), k = 0, 1, \dots, N_i$ 。

1.2 数据降噪

传感器的监测数据含有噪声,导致数据融合后的HI序列中也含有噪声。由于直接用含噪声的HI进行分析会影响RUL预测结果的准确性,因此有必要对其进行降噪处理,获得平滑后的HI序列。

滑动平均滤波是一种时间序列非参数降噪方法,无需繁杂的参数选取过程,通过在当前时刻附近截取一维的滑动窗口,将窗口内数据的平均值作为当前时刻值来实现噪声抑制。当选定用于滤波的滑动窗口长度为 n_w 时,滑动平均滤波^[18]表示为

$$\tilde{h}_{i,j} = \frac{1}{n_w} \sum_{k=j-n_w+1}^j h_{i,k} \quad (4)$$

其中: $h_{i,k}$ 和 $\tilde{h}_{i,j}$ 分别为滤波处理前、后第 i 个发动机在 $t_{i,k}$ 和 $t_{i,j}$ 时刻的HI。

1.3 退化模式特征提取

为建立某时刻退化模式特征与该时刻RUL的直接映射关系,需要从平滑后的HI序列中提取退化模式特征。图1为退化模式特征的优化提取策略示意图。以平滑后的第 i 个发动机的HI序列为例,具体步骤如下。

1) 重构HI序列。利用滑动窗口将平滑后的HI序列分割成长度为 L_w 的时间窗口,窗口间隔为 L_s ,则第 i 个发动机平滑后的HI序列中的第 k 个窗口数据表示为

$$Z_{ik} = \{\tilde{h}_{i,(k-1)L_s}, \tilde{h}_{i,(k-1)L_s+1}, \dots, \tilde{h}_{i,(k-1)L_s+L_w-1}\} \quad (5)$$

2) 拟合窗口数据。采用不同的函数模型对窗口数据进行拟合,常用的拟合函数模型如表1所示。

拟合系数 $a_{ik} = (a_0, a_1, a_2, a_3)$ 表征性能的退化趋势,窗口数据 Z_{ik} 的均值 m_{ik} 表征退化量的大小。




图1 退化模式特征的优化提取策略示意图

Fig.1 Schematic diagram of optimized extraction strategy for degraded pattern features

表1 常用的拟合函数模型

Tab.1 Commonly used fitting functional models

函数名	函数表达式
一次多项式函数	$h(t) = a_1 t + a_0$
二次多项式函数	$h(t) = a_2 t^2 + a_1 t + a_0$
三次多项式函数	$h(t) = a_3 t^3 + a_2 t^2 + a_1 t + a_0$
指数函数	$h(t) = a_2 \exp(a_1 t) + a_0$

因此,将拟合系数和均值的组合 $x_{ik} = (a_{ik}, m_{ik})$ 作为该窗口数据的退化模式特征。拟合后的第 i 个发动机的第 k 个窗口数据可表示为

$$\hat{Z}_{ik} = \{\hat{h}_{i, (k-1)L_s}, \hat{h}_{i, (k-1)L_s+1}, \dots, \hat{h}_{i, (k-1)L_s+L_w-1}\} \quad (6)$$

其中: $\hat{h}_{i, (k-1)L_s}$ 为拟合函数模型在 $t_{i, (k-1)L_s}$ 时刻的函数值。

3) 优化拟合方式。提出一种基于混合交替思想的退化模式特征优化提取策略,根据均方根误差 $RMSE_{ik} = \sqrt{(\hat{Z}_{ik} - Z_{ik})^2}$ 对拟合函数模型与窗口数据的匹配程度进行定量评价。以匹配程度为标准,交替选择最优拟合函数模型,以便提升退化模式特征的提取效果。单一提取策略采用某一固定函数拟合,得到拟合系数 a_{ik}^f ;而混合交替提取策略分别采用2种函数模型 f_1 和 f_2 进行拟合,对应的拟合系数分别为 $a_{ik}^{f_1}$ 和 $a_{ik}^{f_2}$,选取误差较小的函数模型作为该窗口下的最优拟合。

4) 设置RUL标签。把每个窗口的最后时刻视为当前时间,RUL定义为失效时间与当前时间的差值,第 k 个窗口的RUL标签为

$$y_{ik} = RUL_{ik} = N_i - [(k-1)L_s + L_w - 1] \quad (7)$$

5) 构建训练数据集。将提取的退化模式特征与RUL相关联,得到第 i 个发动机的训练数据集为

$$X_i = \{(x_{i1}, y_{i1}), (x_{i2}, y_{i2}), \dots, (x_{ik}, y_{ik})\} \quad (8)$$

2 基于RVM的RUL预测

2.1 RVM回归模型

RVM是一种基于贝叶斯训练框架的稀疏概率模型^[19],既能处理高维、非线性等问题,又具有良好的稀疏性和泛化能力^[3],相较于神经网络,RVM模型具有待优化参数少、模型复杂度低和计算代价小等优势,在大数据背景下更具竞争力,其工作原理如下。

给定样本集 $(x_i, y_i)_{i=1}^N$,输入向量与目标值的关系为

$$y_i = f(x_i) + \epsilon_i \quad (9)$$

其中: f 为RVM模型函数; ϵ_i 为服从均值为0、方差为 σ^2 的高斯分布; x_i 为由输入特征组成的向量; y_i 为相应目标值。

$f(x)$ 为核函数的线性组合^[3],表示为

$$f(x; w) = w_0 + \sum_{i=1}^N w_i K(x, x_i) \quad (10)$$

其中: w_0 为偏置参数; w_i 为权值参数; $K(x, x_i)$ 为核函数。

根据贝叶斯推理,整个样本集的似然函数表示为

$$p(\mathbf{y}|\mathbf{w}, \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{\|\mathbf{y} - \Phi\mathbf{w}\|^2}{2\sigma^2}\right\} \quad (11)$$

其中: $\mathbf{y} = [y_1, y_2, \dots, y_N]^T$, 为由偏置参数组成的权值向量; $\mathbf{w} = [w_0, w_1, \dots, w_N]^T$, 为由权值参数组成的权值向量; $\Phi = [\phi(x_1), \phi(x_2), \dots, \phi(x_N)]^T$, 为 $N \times (N+1)$ 维矩阵; $\phi(x_i) = [1, K(x_i, x_1), K(x_i, x_2), \dots, K(x_i, x_N)]^T$; σ^2 为噪声方差。

为防止过拟合, 给权值向量 $\mathbf{w}$ 加上约束条件, 假设其概率分布服从零均值的高斯先验分布^[20], 即满足

$$(\mathbf{w}|\alpha) = \prod_{i=1}^N N(w_i|0, \alpha_i^{-1}) \quad (12)$$

其中: $\alpha = [\alpha_0, \alpha_1, \dots, \alpha_N]^T$, 为权值向量 $\mathbf{w}$ 对应的超参数。

已知参数的似然分布式和先验分布式, 根据贝叶斯定理计算其后验分布^[9]为

$$p(\mathbf{w}|\mathbf{y}, \alpha, \sigma^2) = \frac{p(\mathbf{y}|\mathbf{w}, \sigma^2) p(\mathbf{w}|\alpha)}{p(\mathbf{y}|\alpha, \sigma^2)} \quad (13)$$

由式(12)可推导出权值向量 $\mathbf{w}$ 的后验分布服从多变量高斯分布, 即

$$p(\mathbf{w}|\mathbf{y}, \alpha, \sigma^2) = N(\mu, \Sigma) \quad (14)$$

其中: $\mu = \sigma^{-2} \Sigma \Phi^T \mathbf{y}$, 为均值; $\Sigma = (A + \sigma^{-2} \Phi^T \Phi)^{-1}$, 为协方差; $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$ 。

为了计算 μ 和 Σ , 需要先估计超参数 α 和噪声方差 σ^2 , 其估计值 α_{MP} 和 σ_{MP}^2 可通过期望最大迭代估计法^[21]求解。对于先验分布为均匀分布的超参数, 只需最大化似然函数 $p(\mathbf{y}|\alpha, \sigma^2)$, 即

$$(\alpha_{MP}, \sigma_{MP}^2) = \arg \max_{\alpha, \sigma^2} p(\mathbf{y}|\alpha, \sigma^2) \quad (15)$$

如果上述估计过程收敛, 当给定一个新的输入样本 $\mathbf{x}$ 时, 则对应的输出 y 的概率分布为

$$p(y_*|\mathbf{y}, \alpha_{MP}, \sigma_{MP}^2) = \int p(y_*|\mathbf{w}, \sigma_{MP}^2) p(\mathbf{w}|\mathbf{y}, \alpha_{MP}, \sigma_{MP}^2) d\mathbf{w} \quad (16)$$

由于积分项是高斯函数的乘积形式, 因此积分后的结果为

$$p(y_*|\mathbf{y}, \alpha_{MP}, \sigma_{MP}^2) = N(\mu_*, \sigma_*^2) \quad (17)$$

$$\mu_* = \mu^T \phi(x_*) \quad (18)$$

$$\sigma_*^2 = \sigma_{MP}^2 + \phi(x_*)^T \Sigma \phi(x_*) \quad (19)$$

其中: μ_* 为 RVM 的预测输出期望; σ_*^2 为预测的置信度。

2.2 RUL 预测流程

如图2所示, 发动机 RUL 的预测流程由离线的模型训练和在线的 RUL 预测2部分组成, 具体步骤如下。

1) HI 序列构建。由式(2)求解线性回归模型参数, 根据式(1)和式(3)将多传感器数据融合转变为含噪声的 HI 序列。

2) HI 序列降噪。采用滑动平均滤波方法, 根据式(4)对含噪声的 HI 序列进行降噪, 得到平滑后的 HI 序列。

3) 退化模式特征提取。选取合适的滑动窗口长度 L_w 和窗口间隔 L_s , 根据式(5)对平滑后的 HI 序列进行重构, 并提取退化模式特征。

4) 训练数据集构建。将退化模式特征 x_{ik} 作为模型输入, 根据式(7)设置 RUL 标签 y_{ik} 作为相应的输出, 对用于训练的所有发动机数据进行相同操作, 构建如式(8)所示的训练数据集。

5) RVM 模型的离线训练。利用步骤4构建的数据集对 RVM 模型进行训练, 学习退化模式特征 x_{ik} 和 RUL 标签 y_{ik} 之间的映射关系, 得到合适的模型参数。




图2 发动机 RUL 的预测流程

Fig.2 Flow chart of RUL prediction for engines

6) RUL 在线预测。对于待测试发动机的传感器监测数据,执行步骤 1~3,得到退化模式特征作为 RVM 模型的输入,在已知 RVM 模型参数的基础上,根据式(18)计算得到当前时刻的 RUL 预测值。

2.3 模型评价指标

为了验证 RUL 预测方法的有效性,采用 Score 评分函数^[5]和均方根误差(root mean square error,简称 RMSE)来评估预测结果的准确性,具体形式分别为

$$\left\{\begin{aligned} \text{Score} &= \sum_{j=1}^{N_s} \text{Score}_j \\ \text{Score}_j &= \begin{cases} e^{-\frac{d_j}{13}} - 1 & (d_j < 0) \\ e^{\frac{d_j}{10}} - 1 & (d_j \geq 0) \end{cases} \end{aligned}\right. \quad (20)$$

$$\text{RMSE} = \sqrt{\frac{1}{N_s} \sum_{j=1}^{N_s} d_j^2} \quad (21)$$

其中: N_s 为待测样本数; $\hat{\text{RUL}}_j$ 和 RUL_j 分别为预测值和真实值; $d_j = \hat{\text{RUL}}_j - \text{RUL}_j$,为 RUL 的预测误差。

图 3 为不同预测误差下 RMSE 和 Score 评分函数指标值的对比。可见,2 种评价指标的数值越小,表明 RUL 预测效果越好,精度越高。值得注意的是,Score_j是关于预测误差 d_j 的非对称函数,当 $|d_j|$ 相同时,滞后预测($d_j \geq 0$)要比超前预测($d_j < 0$)获得更高的得分或惩罚,这是从保障发动机运行安全性角度考虑的,更符合实际应用要求。




图 3 不同预测误差下 RMSE 和 Score 评分函数指标值的对比
Fig.3 Comparison between the Score and RMSE with respect to different prediction errors

3 方法验证

3.1 发动机退化数据集

受限于大型设备寿命加速实验数据获取耗时

长、费用高等条件限制,笔者采用 C-MAPSS 仿真数据集进行 RUL 预测方法验证。C-MAPSS 仿真环节提供了不同工作环境和失效模式下的 4 类仿真数据集^[22],即 FD001、FD002、FD003 和 FD004。笔者选用 FD002 数据集集中的 train_FD002 子集进行验证,包含 260 台发动机从运行开始到结束的全寿命失效数据。

每台发动机数据记录了包括发动机编号、飞行循环次数、3 个发动机工作环境参数(包括飞行高度、飞行马赫数和油门解算器角度)和 21 个传感器的监测数据。以 1 号发动机为例,其 21 个传感器监测数据如表 2 所示。

表 2 1 号发动机的 21 个传感器监测数据
Tab.2 Monitoring data of 21 sensors for the No.1 engine

飞行循环 次数	传感器					
	1	2	3	...	20	21
1	449.44	555.32	1 358.61	...	14.73	8.81
2	445.00	549.90	1 353.22	...	10.41	6.27
3	462.54	537.31	1 256.76	...	14.08	8.67
⋮	⋮	⋮	⋮		⋮	⋮
148	518.67	643.73	1 605.33	...	38.55	23.01
149	445.00	550.49	1 366.01	...	10.45	6.23

3.2 一维 HI 序列构建

选取编号为 1~200 的发动机全寿命监测数据作为训练数据集。对于 3 个工作环境参数,采用 k -均值算法进行聚类分析,发现其隶属于 6 个聚类,代表 6 种不同工况。对于 21 个传感器监测数据,移除无明显退化趋势的传感器,最终选取第 2、3、4、7、11 和 12 号传感器数据进行融合。由表 2 可知,不同传感器监测数据的数量级各不相同,在数据融合前还需对传感器监测数据进行归一化处理,得到 6 种工况下的回归模型参数,如表 3 所示。

表 3 回归模型参数
Tab.3 Parameters of the regression model

参数	工况					
	1	2	3	4	5	6
θ_0	0.75	0.74	0.76	0.74	0.75	0.74
θ_1	-0.05	-0.03	-0.05	-0.04	-0.05	-0.05
θ_2	-0.06	-0.05	-0.04	-0.05	-0.04	-0.05
θ_3	-0.09	-0.08	-0.08	-0.09	-0.07	-0.09
θ_4	0.01	0.01	0.03	0.01	0.01	0.01
θ_5	-0.14	-0.14	-0.08	-0.09	-0.11	-0.14
θ_6	0.01	0.03	0.05	0.03	0.04	0.01

已知线性回归模型参数后,由式(1)和式(3)计算得到含噪声的一维HI序列。采用滑动平均滤波($n_w=10$)的方法,根据式(4)对含噪声的HI序列进行降噪,得到平滑后的HI序列,以1号、3号和12号发动机为例,获得的HI序列如图4所示。可以看出,使用滑动平均滤波方法能够消除HI序列中存在的噪声波动成分,并保留原有的退化趋势,可显著提升数据质量。值得注意的是,图4(b)中滤波后的HI序列在早期阶段虽有波动现象,但RUL预测通常是从发动机运行的中后期开始进行,因此上述波动现象对后续RUL预测结果的影响并不明显。




图4 1号、3号和12号发动机的HI序列

Fig.4 The HI of the No.1, No.3 and No.12 engines

3.3 RVM模型训练

窗口长度的取值会直接影响退化特征的提取结果,进而影响RUL预测精度。一般情况下,较小的窗口长度难以有效显示时间序列中包含的特征,导致退化模式特征提取效果较差、RUL预测结果不理想;较大的窗口长度包含更丰富的历史信息,提取的退化模式特征更为合理,有助于提高RUL预测精度。需要注意的是,当时间序列本身长度较短时,窗口长度不宜设置过大,否则输入模型的退化模式特征减少,预测误差反而增大。因此,选用窗口长度 $L_w=70$ 、窗口间隔 $L_s=4$ 的滑动窗对平滑后的HI

序列进行重构,并选取常用的高斯核函数为RVM模型的核函数,对应的核宽度取0.005。由于发动机整体性能退化曲线随着运行时间呈现出类似于指数函数或多项式函数的形式,综合考虑拟合精度与计算效率,这里分别采用指数函数、二次多项式函数和两者混合交替的3种方式对窗口数据进行拟合。提取退化模式特征(即拟合系数和均值)作为RVM训练模型的输入,相应地为每个窗口添加RUL标签作为对应的输出。通过学习退化模式特征和RUL标签之间的映射关系,得到合适的RVM模型参数。不同特征提取方式下前200号发动机的拟合误差曲线如图5所示。




图5 不同特征提取方式下前200号发动机的拟合误差曲线
Fig.5 Fitting error curves of the first 200 engines with different feature extraction approaches

由图5可知,通过采用指数函数与二次多项式函数混合交替的优化提取策略,可降低HI序列的拟合误差,拟合效果优于单一采用指数函数或二次多项式函数的提取方式。降低训练阶段的拟合误差会直接影响后续的RUL预测结果,对提升RUL预测精度具有重要意义。

3.4 发动机RUL预测

选取255号发动机数据作为测试数据集。为获得发动机每一时刻的RUL预测结果,选用窗口长度 $L_w=70$ 、窗口间隔 $L_s=1$ 的滑动窗对平滑后的HI序列进行重构,执行RUL预测流程步骤1~3,在特征提取时分别采用3种特征提取方式获得各个窗口数据的退化模式特征,并将其作为RVM模型的输入。自第200次飞行循环开始进行RUL预测,由式(18)计算得到不同特征提取方式下发动机的RUL预测结果如图6所示。可以看出,单一采用指数函数或二次多项式函数的特征提取方式得到的RUL预测结果波动较大,而采用指数函数与二次多项式函数混合交替的优化提取策略可以获得更加稳




图6 不同特征提取方式下255号发动机RUL预测结果

Fig.6 RUL prediction results of the No.255 engine with different feature extraction approaches

定的RUL预测结果。其主要原因是,使用单一函数进行特征提取可能产生不准确的退化模式特征,影响RVM模型的训练结果,进而影响RUL预测结果的稳定性和准确性。

降低拟合误差能够直接影响RVM模型训练效果,进而显著提升RUL预测精度。综合图5和图6可知,相较于采用固定的单一函数进行特征提取的策略^[12-13],采用指数函数与二次多项式函数混合交替的优化提取策略可以得到更准确的退化模式特征,降低训练阶段的拟合误差,从而获得更加准确的RUL预测结果,提升发动机RUL预测精度。

根据式(20)和(21)给出的2种评价指标,得到不同特征提取方式下发动机RUL预测结果对比如表4所示。

表4 不同特征提取方式下发动机RUL预测结果对比

Tab.4 Comparison of RUL prediction results with different feature extraction approaches

方法	RMSE	Score
指数函数	14.74	543.86
二次多项式函数	14.50	466.25
两者混合交替	11.09	281.16

由表4可以看出,对于2种不同评价指标,采用指数函数与二次多项式函数混合交替的优化提取策略均可取得最小指标值,表明该策略下RUL预测效果最优。此外,由图6中发动机接近失效阶段的RUL预测结果可知,采用指数函数与二次多项式函数混合交替的优化提取策略在发动机服役后期的RUL预测值小于真实值。根据模型评价指标中的Score指标对发动机服役后期的RUL预测结果进行定量评估,发现其对应的Score指标数值偏小,说明上述优化提取策略有助于避免发动机出现滞后预测问题,符合实际应用中的超前预测原则。

4 结 论

1) 提出了一种改进的发动机RUL直接预测方案,无需设置失效阈值或估计未知的健康状态,简单易行,更符合实际工程应用需求。

2) 针对单一传感器难以完全反映发动机退化过程的问题,发展面向多传感器的数据融合方法,构建一维HI以量化发动机的退化程度。

3) 考虑到发动机监测数据存在噪声,将滑动平均滤波引入HI构建过程中,提升数据质量。

4) 在特征提取阶段提出一种指数函数与二次多项式函数混合交替的优化提取策略,相比于传统的单一提取策略,能够显著提升发动机RUL预测精度,其均方根误差降低了20%,Score评分函数指标值降低了40%。

参 考 文 献

- [1] 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.
- [2] 郭晓静, 俞玉晶, 徐晓慧. 基于深度学习方法的航空发动机寿命预测模型[J]. 振动、测试与诊断, 2024, 44(2): 330-336.
GUO Xiaojing, YUN Yujing, XU Xiaohui. Prediction model of aero-engine remaining useful life based on deep learning method[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(2): 330-336. (in Chinese)
- [3] 雷亚国, 陈昊, 李乃鹏, 等. 自适应多核组合相关向量机预测方法及其在机械设备剩余寿命预测中的应用[J]. 机械工程学报, 2016, 52(1): 87-93.
LEI Yaguo, CHEN Wu, LI Naipeng, et al. A relevance vector machine prediction method based on adaptive multi-kernel combination and its application to remaining useful life prediction of machinery[J]. Journal of Mechanical Engineering, 2016, 52(1): 87-93. (in Chinese)
- [4] LU F, HUANG J Q, XING Y D. Fault diagnostics for turbo-shaft engine sensors based on a simplified on-board model[J]. Sensors, 2012, 12(8): 11061-11076.
- [5] 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.

- [6] CHEN J X, LI D P, HUANG R Y, et al. Aero-engine remaining useful life prediction method with self-adaptive multimodal data fusion and cluster-ensemble transfer regression[J]. Reliability Engineering & System Safety, 2023, 234: 109151.
- [7] FERREIRA C, GONÇALVES G. Remaining useful life prediction and challenges: a literature review on the use of machine learning methods[J]. Journal of Manufacturing Systems, 2022, 63: 550-562.
- [8] 彭鸿博, 蒋雄伟. 基于相关向量机的发动机剩余寿命预测[J]. 科学技术与工程, 2020, 20(18): 7538-7544.
- PENG Hongbo, JIANG Xiongwei. Remaining useful life prediction for aeroengine based on relevance vector machine[J]. Science Technology and Engineering, 2020, 20(18): 7538-7544.(in Chinese)
- [9] 陈雄姿, 于劲松, 陆文高, 等. 基于综合健康指数与RVM的系统级失效预测[J]. 系统工程与电子技术, 2015, 37(10): 2298-2305.
- CHEN Xiongzi, YU Jinsong, LU Wengao, et al. System-level failure prognostics using synthesized health index and relevance vector machine[J]. Systems Engineering and Electronics, 2015, 37(10): 2298-2305.(in Chinese)
- [10] GARCÍA NIETO P J, GARCÍA GONZALO E, SÁNCHEZ LASHEERAS F, et al. Hybrid PSO-SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability[J]. Reliability Engineering & System Safety, 2015, 138: 219-231.
- [11] XU J P, WANG Y S, XU L. PHM-oriented integrated fusion prognostics for aircraft engines based on sensor data[J]. IEEE Sensors Journal, 2014, 14(4): 1124-1132.
- [12] 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.
- [13] 周俊. 数据驱动的航空发动机剩余使用寿命预测方法研究[D]. 南京: 南京航空航天大学, 2017.
- [14] 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]. 航空学报, 2022, 43(7): 308-319.
- MU Hanxiao, ZHENG Jianfei, HU Changhua, et al. Remaining useful life prediction of multivariate degradation equipment based on CDBN and BiLSTM[J]. Acta Aeronautica ET Astronautica Sinica, 2022, 43(7): 308-319.(in Chinese)
- [15] 张晓东, 秦子轩, 李敏, 等. 基于多特征融合的航空发动机剩余寿命预测[J]. 计算机系统应用, 2023, 32(3): 95-103.
- ZHANG Xiaodong, QIN Zixuan, LI Min, et al. Remaining useful life prediction of aeroengine based on multi-feature fusion[J]. Computer Systems & Applications, 2023, 32(3): 95-103.(in Chinese)
- [16] LEI Y G, LI N P, GUO L, et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal Processing, 2018, 104: 799-834.
- [17] KHELIF R, MALINOWSKI S, CHEBEL-MORELLO B, et al. RUL prediction based on a new similarity-instance based approach[C]//2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE). Istanbul, Turkey: IEEE, 2014: 2463-2468.
- [18] MERIGÓ J M, YAGER R R. Aggregation operators with moving averages[J]. Soft Computing, 2019, 23(21): 10601-10615.
- [19] TIPPING M E. Sparse bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research, 2001, 1(3): 211-244.
- [20] WIPF D P, RAO B D. Sparse Bayesian learning for basis selection[J]. IEEE Transactions on Signal Processing, 2004, 52(8): 2153-2164.
- [21] TIPPING M E. The relevance vector machine[C]//13th Annual Conference on Neural Information Processing Systems (NIPS). Denver, CO, USA: MIT Press, 2000: 652-658.
- [22] 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.



第一作者简介:梁佳鑫,女,1996年12月生,硕士生。主要研究方向为发动机剩余使用寿命预测。

E-mail: ljx_258369@tju.edu.cn

通信作者简介:马志赛,男,1988年6月生,博士、副教授。主要研究方向为航空航天结构动力学与控制。

E-mail: zhisai.ma@tju.edu.cn