

基于双尺度相似性的发动机寿命预测*

赵洪利, 陈天铭

(中国民航大学 航空工程学院, 天津 300300)

摘要: 针对基于欧氏距离的移动相似性对不同时间序列相似度的刻画准确度不高和预测精度不高的问题, 提出一种基于曼哈顿距离和斜率双尺度的改进相似性寿命预测方法。通过传感器数据变化幅度、各项参数出厂时的数值差异和下发时的数值差异这三个标准筛选传感器数据, 并基于筛选结果构建一维健康指数; 基于曼哈顿距离和斜率结合固定匹配和移动匹配进行初步寿命预测; 利用移动匹配的特性建立筛选标准, 并筛选获得最终预测结果; 采用NASA的数据集对该方法进行验证。结果表明: 该方法的预测精度相比当前的相似性预测方法提升30.35%, 证明该改进方法对不同时间序列之间的相似度有更加精确的刻画。

关键词: 航空发动机; 健康指数; 时间序列; 双尺度; 相似性; 寿命预测

中图分类号: V267 **文献标识码:** A **文章编号:** 1001-4055 (2022) 11-210342-08

DOI: 10.13675/j.cnki. tjjs. 210342

Engine Life Prediction Based on Two-Scale Similarity

ZHAO Hong-li, CHEN Tian-ming

(School of Aeronautical Engineering, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aiming at the problem of low accuracy on portraying similarity and life prediction for moving similarity by using Euclidean distance for different time series similarities, an improved similarity life prediction method based on Manhattan distance and slope was proposed. Firstly, the sensor parameters were screened by three criterion which are the sensor parameters variation range, the value difference of each sensor parameter at engine leaving the factory, and value difference of each sensor parameter at engine removal, and based on a comprehensive analysis on the selected sensor parameters, a one-dimensional health index was set up. Then Manhattan distance and slope were used to combine with the fixed matching and moving matching, and a preliminary life prediction was performed. The moving matching was used to set up the filtering rules and the final results were achieved. Finally, the method was verified by NASA data set, and the results show that the prediction accuracy of this method is 30.35% higher than the current ones, which proves that the proposed method is more accurate on portraying the similarity among different time series.

Key words: Aeroengine; Health index; Time series; Two-scale; Similarity; Life prediction

1 引言

保持高安全水平,使运输航空每百万小时重大及以上事故率低于0.15,是《中国民用航空发展第十

三个五年规划》的五大目标之一^[1]。而民航客机的安全水平与飞机维修水平息息相关。近年来,在飞机维修领域,预测与健康管(Prognostics and health management, PHM)由于能够有效提升飞机安全水

* 收稿日期: 2021-06-01; 修订日期: 2021-09-07。

通讯作者: 赵洪利, 硕士, 副教授, 研究领域为航空发动机维修和维修管理。

引用格式: 赵洪利, 陈天铭. 基于双尺度相似性的发动机寿命预测[J]. 推进技术, 2022, 43(11):210342. (ZHAO Hong-li, CHEN Tian-ming. Engine Life Prediction Based on Two-Scale Similarity[J]. *Journal of Propulsion Technology*, 2022, 43(11):210342.)

平、降低维修成本而越来越受到重视^[2]。剩余使用寿命预测作为PHM的关键技术之一,其研究也受到许多研究人员的青睐。

经过多年研究,剩余使用寿命预测方法大致可分为基于物理失效模型的方法、基于数据驱动的方法和混合方法三大类^[3]。基于数据驱动的预测方法是当前主要的研究方向并有较大进展。黄亮等^[4]提出基于多阶段非线性Wiener过程来进行航空发动机实时剩余寿命预测;王玺等^[5]采用考虑非线性和三源不确定性的Wiener过程,解决发动机性能衰退所带来的非线性和三源不确定性问题;马奇友等^[6]结合深度学习和长短期记忆构造深度长短期记忆网络,其预测效果优于其他传统方法;Zhang等^[7]基于变分自编码器和双判别器对抗式生成网络进行模型训练,再利用长短时记忆网络实现预测,经验证有较高的预测精度;Xia等^[8]集成卷积神经网络和双向长短时记忆网络,结合加权平均法预测剩余使用寿命。

在数据驱动方法中,利用发动机性能数据相似性的预测方法也是近些年的一个研究方向。该研究主要通过分析测试样本和各个训练样本变化趋势的相似性,寻找与测试样本最相似的训练样本。Shi等^[9]结合相关向量机和多模型相似性匹配进行发动机寿命预测。但是该方法所采用的相似性匹配方法较为简单,在时间序列的匹配上效果较差使得预测误差区间较大。张妍等^[10]利用低维正交多变量退化特征进行时延相似性匹配,并通过权重分配进行多模型剩余寿命预测。该方法利用时延相似性匹配提高时间序列的匹配精度,同时利用多模型共同预测避免因单模型预测而带来偏差过大的问题;Yu等^[11]提出无中心化相似性匹配,结合有中心化的匹配方式进行综合的发动机寿命预测。该方法虽然取得较高的预测精度,但是通过去中心化来达到时间序列的高度匹配,可能对数据的真实性造成影响。

上述通过相似性匹配进行寿命预测的方法中缺乏结合发动机性能变化规律,使得在构建健康指数时,可能会导致筛选出来的传感器数据与发动机性能变化关联性不高,同时相似性匹配的匹配方法和匹配尺度刻画的准确性还可以进一步提高。因此本文基于发动机参数特性建立传感器参数筛选标准,利用筛选数据构建一维健康指数;将获取的健康指数通过固定匹配和移动匹配进行相似性匹配,分析获取阈值用于筛选结果,同时引入新的匹配尺度辅助寿命预测;最终通过数据集验证该方法的有效性。

2 方法

2.1 健康指数的构建

随着寿命预测研究越来越深入,可以发现任何单一的传感器数据都很难较好地表征发动机性能衰退状态,因此采用单参数进行寿命预测已经无法满足当前的预测精度。许多学者研究通过融合多参数构建健康指数来进行寿命预测,如深度卷积网络^[12]、受限玻尔兹曼机^[13]等。但是这些方法缺乏考虑发动机的性能特性以及发动机个体差异。若构建的健康指数没有较好地融合表征发动机性能状态的参数,则会影响寿命预测精度。因此,本文基于传感器的敏感性差异和发动机个体差异对传感器数据进行筛选,以筛选出能够更好表征发动机性能的传感器数据。

在航空发动机上安装有各种传感器,用来测量不同站位或者不同部件的工作参数。而这些工作参数对发动机性能状态的敏感性存在差异^[14]。如果参数对发动机性能状态的变化比较敏感,随着发动机性能变化会出现比较大的变化幅度;反之,相对的变化幅度会比较小。所以选取的第一个筛选标准是传感器数据变化幅度。传感器数据变化幅度的计算公式为

$$r_j = \frac{1}{I} \sum_{i=1}^I \frac{x_{t,i,j} - x_{s,i,j}}{(x_{t,i,j} + x_{s,i,j})/2} \quad (1)$$

式中 r_j 为第 j 个传感器数据的变化幅度, $x_{s,i,j}$ 和 $x_{t,i,j}$ 分别为第 i 个发动机第 j 个传感器数据的出厂数值和下发数值。

由于生产上的差异,航空发动机出厂时相同站位的参数测量值不一定相同,但是都需要符合相应的标准^[15-16]。这些标准对于影响发动机性能较大的传感器数据会有更高的要求,使这些参数保持在较小的误差之内。同样的,根据相关适航条例,判断同一型号的发动机是否因为某原因而下发时,通常会测量相关的参数,分析测量的数据是否符合下发条件范围^[17-18]。由于这个下发条件范围一般都较小,因此,对于能够更好表征发动机性能状态的传感器数据在同一型号的发动机失效时所测得的值差异相对比较小。在同一种故障引起的发动机下发的数据集里,这种现象会得到更好的反映。所以选取的第二个筛选标准和第三个筛选标准是传感器数据出厂数值差异和下发数值差异。而传感器数据的量级和变化幅度会影响出厂数值和下发数值。为了避免传感器数据量级和变化幅度带来的影响,传感器数据出

厂数值差异和下发数值差异的计算公式为

$$SD_j = \frac{\max_{s,j} - \min_{s,j}}{\left(\max_{s,j} + \min_{s,j}\right)/2} r_j \quad (2)$$

$$FD_j = \frac{\max_{t,j} - \min_{t,j}}{\left(\max_{t,j} + \min_{t,j}\right)/2} r_j \quad (3)$$

式中 SD_j 和 FD_j 分别是第 j 个传感器数据的出厂数值差异和下发数值差异; $\max_{s,j}, \min_{s,j}$ 为第 j 个传感器数据在样本库中起始时的最大值和最小值; $\max_{t,j}, \min_{t,j}$ 为第 j 个传感器数据在样本库中失效时的最大值和最小值。

通过以上三个标准进行筛选后,需要对筛选结果进行综合分析,以确定最终用于构建健康指数的传感器数据。综合筛选值 h_j 的公式为

$$h_j = \frac{r_j}{\sum_{j=1}^J r_j} - \frac{SD_j}{\sum_{j=1}^J SD_j} - \frac{FD_j}{\sum_{j=1}^J FD_j} \quad (4)$$

式中 J 为总的传感器数据数量。筛选出来的传感器数据要满足 h_j 为正数,即满足传感器数据的变化幅度大于出厂数值差异和下发数值差异之和。

将符合标准的传感器数据筛选出来之后,得到 Z 个符合标准的传感器数据 x'_1, x'_2, \dots, x'_z 以及对应的综合筛选值 h'_1, h'_2, \dots, h'_z , 结合各参数的权重进行一维健康指数的构建,具体步骤如下:

(1) 分析每个传感器数据所对应的权重占比 w_z , 计算公式为

$$w_z = \frac{h'_z}{\sum_{z=1}^Z h'_z} \quad (5)$$

(2) 将筛选出来的传感器数据所对应的数据集进行滤波和去量纲。

(3) 分析各个传感器数据 x_z 的变化趋势,利用以下计算公式为各个传感器数据 x_z 配置相应的权重 w_z , 构建一维健康指数 y 。

$$y = \sum_{z=1}^Z w_z x'_z \quad (6)$$

2.2 基于双尺度的相似性预测

基于双尺度的相似性匹配流程如图 1 所示。相似性匹配是基于一定的度量尺度以一定的匹配方式度量预测时间序列与样本库中时间序列的相似度。其目的是为了寻找相似性匹配中相似度最高的时间序列。

2.2.1 曼哈顿距离和斜率结合的匹配尺度

在相似性匹配中,通常采用欧几里得距离作为

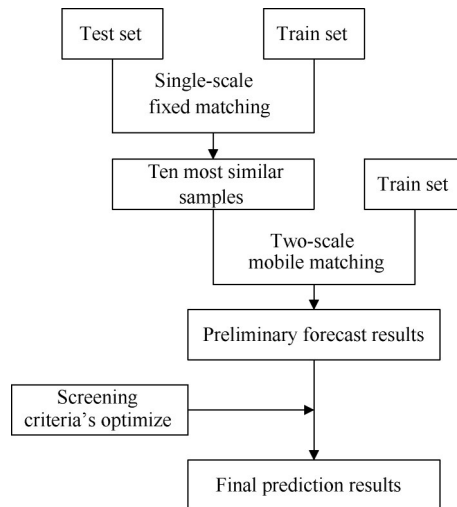


Fig. 1 Prediction method based on dual scales similarity

距离尺度来度量相似度。但是针对发动机的性能变化数据,Zhang 等^[19]研究欧几里得距离和曼哈顿距离对相似性匹配预测精度的影响,最终证明采用曼哈顿距离有更好的预测效果。因此,本文采用曼哈顿距离作为距离尺度,定义固定匹配和移动匹配时两个时间序列之间的距离分别为

$$D_{\text{fixed}} = \sum_{l=1}^L |\bar{y}_l - y_{l,i}| \quad (7)$$

$$D_{\text{moving},N} = \sum_{l=1}^L |\bar{y}_l - \bar{y}_{l+N,i}| \quad (8)$$

式中 D_{fixed} 为两个时间序列在固定匹配时的曼哈顿距离, $D_{\text{moving},N}$ 为预测时间序列移动 N 个运行循环后与样本时间序列匹配的曼哈顿距离, \bar{y}_l 为测试时间序列在第 l 个运行循环的值, $y_{l,i}$ 为第 i 台发动机在第 l 个运行循环的值, $y_{l+N,i}$ 为第 i 台发动机在第 $l+N$ 个运行循环的值。

虽然利用距离尺度进行度量时可以较好地反映相似度,但是仅能确定时间序列间的绝对距离,没办法反映两个时间序列的位置关系,即无法确定当前匹配的时间序列是在预测时间序列的上下哪一侧。

这可能会使得在融合多模型进行寿命预测时引入过多预测时间序列上方或者下方的时间序列,导致预测精度降低。因此引入斜率作为第二个匹配尺度,在距离尺度的基础上刻画时间序列的位置,并用其确定时间序列的上下阈值和匹配的发动机模型。时间序列之间的斜率差异 K 定义为

$$K = \frac{\bar{y}_l - \bar{y}_1}{l} - \frac{y_{l,i} - y_{1,i}}{l} \quad (9)$$

式中 \bar{y}_l 和 \bar{y}_1 为预测时间序列在第 l 个和第 1 个运行循环的值, $y_{l,i}$ 和 $y_{1,i}$ 为第 i 台发动机的时间序列在第 l 个

和第1个运行循环的值。

但是使用该尺度时有可能出现斜率很接近而相似度比较低的情况,如图2所示。预测样本和训练样本从起始点A运行到第10个运行循环点B时,两个样本的斜率相同,但是在该区间内两者的相似度较低。所以该尺度在以曼哈顿距离尺度为主要匹配尺度的基础上,作为次要匹配尺度辅助刻画相似度。

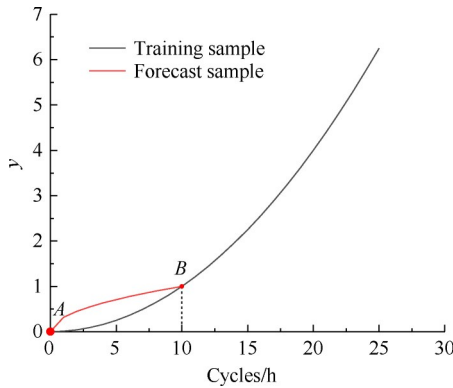


Fig. 2 Drawbacks of using slope characterization

2.2.2 固定匹配和移动匹配相结合的匹配方式

为了研究固定匹配和移动匹配对于预测效果的影响,进而获得两种匹配方式更有效的结合形式,本文分别用固定匹配和移动匹配进行预测。预测误差结果如图3所示。

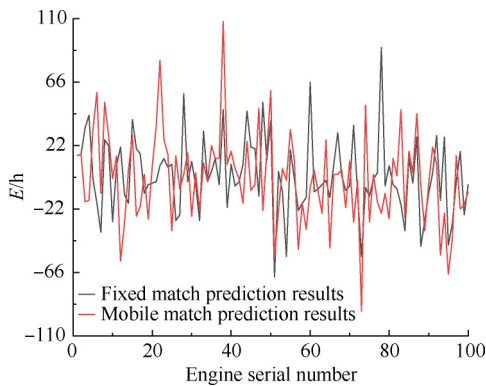


Fig. 3 Prediction error of fixed matching and moving matching

通过图3可以发现在固定匹配的预测下,预测误差基本都在50以下,整体的预测误差偏小,但是缺少预测精度较高的结果;在移动匹配的预测下,存在预测误差较小的结果,但是有些结果误差比较大。为了结合两种匹配方式各自的优势,本文将在固定匹配的基础上再进行移动匹配,以在保证没有极端误

差的前提下提高预测精度。具体的步骤如下:

(1)构建预测样本的一维健康指数时间序列 $\bar{y} \{ \bar{y}_1, \bar{y}_2, \dots, \bar{y}_n \}$, 获取样本库中第*i*台发动机前*n*个运行循环的一维健康指数时间序列 $y_i \{ y_{1,i}, y_{2,i}, \dots, y_{n,i} \}$, 将 \bar{y} 和 y_i 基于曼哈顿距离进行相似性匹配, 得到 $D_{fixed,i}$ 。

(2)重复(1),将样本库中所有发动机进行匹配,得到所有发动机的固定匹配结果 $D_{fixed} \{ D_{fixed,1}, D_{fixed,2}, \dots, D_{fixed,l} \}$, 选出相似度最高的十台发动机以及对应的完整的时间序列 $y'_1, y'_2, \dots, y'_{10}$ 。

(3)将 \bar{y} 与 y' 从起始运行循环开始进行曼哈顿距离和斜率的相似性匹配, 获取第一台发动机在初始运行循环时的 $D_{moving,1,1}$ 和 $K_{1,1}$ 。随后 y' 从起始运行循环开始每次移动一个运行循环, 获取与 \bar{y} 循环数相同的一段时间序列进行匹配, 实现一次计算, 直至时间序列 y' 抵达最后一个运行循环, 得到第一台发动机的移动匹配结果 $D_{moving,1} \{ D_{moving,1,1}, D_{moving,1,2}, \dots, D_{moving,1,f-n} \}$ 和 $K_1 \{ K_{1,1}, K_{1,2}, \dots, K_{1,f-n} \}$, 提取出相似度最高的 $D_{moving,1,best}$ 以及对应的 $K_{1,best}$ 和对应的剩余寿命 $RUL_{1,best}$ 。

(4)重复(3),完成十台发动机的相似性匹配, 获得 $D_{moving} \{ D_{moving,1,best}, D_{moving,2,best}, \dots, D_{moving,10,best} \}$, $K \{ K_{1,best}, K_{2,best}, \dots, K_{10,best} \}$ 和 $RUL \{ RUL_{1,best}, RUL_{2,best}, \dots, RUL_{10,best} \}$ 。

通过以上四个步骤可以得到初步的符合标准的发动机模型及预测结果。为了进一步筛选发动机模型和优化预测结果, 本文将设定优化筛选标准。通过两种匹配方式的分析, 可以发现移动匹配出现高匹配度和高预测精度的可能性较大。基于移动匹配的特点, 确定距离匹配度的筛选标准, 对初步预测结果进行筛选, 可以达到一定程度的结果优化。建立优化筛选标准的过程是将 \bar{y} 与样本库中所有发动机进行移动匹配, 获取相似度第十高的发动机所对应的 $D'_{moving,10,best}$, 并以 $D'_{moving,10,best}$ 作为标准筛选 D'_{moving} , 以防止过度筛选。最终得到符合标准的 D'_m 以及对应的 K' 和 RUL' 。

在最终的寿命预测时, 分析 K' , 获取 K' 中最小的正值 K'_{min} 和最大的负值 K'_{max} , 并得到对应的剩余寿命 RUL'_{min} 和 RUL'_{max} 。 RUL'_{min} 为预测剩余寿命的下阈值, RUL'_{max} 为预测剩余寿命的上阈值。预测的剩余寿命 RUL_p 通过以下式子进行计算

$$RUL_p = (RUL'_{min} + RUL'_{max}) / 2 \quad (10)$$

如果预测结果只有下阈值或者上阈值, 则预测的剩余寿命 RUL_p 为下阈值或者上阈值。

3 结果与讨论

3.1 数据来源

本文采用由 C-MAPSS 仿真出来的 FD001 数据集来进行方法验证^[20]。该数据集被许多学者应用到发动机剩余使用寿命预测领域,而且是该领域用于方法验证最广泛的一套数据集。在这套数据集中包含 100 台发动机的全寿命训练数据和 100 台发动机的不完整寿命测试数据及其对应的剩余使用寿命。这些数据都是在飞行高度 0 英尺、油门角度 100°、马赫数 0.84 的运行模式下由 21 个传感器获取,其反映的性能退化是由高压压气机故障引起的。

3.2 构建健康指数

通过对数据集进行初步研究,可以发现在 21 个传感器数据中有 7 个传感器数据在任意运行循环都不存在波动。这些参数分别是第 1、第 5、第 6、第 10、第 16、第 18 和第 19 个参数。将这些参数剔除后剩余的 14 个参数,其中包括低压压气机 (Low pressure compressor, LPC)、高压压气机 (High pressure compressor, HPC)、低压涡轮 (Low pressure turbine, LPT) 和高压涡轮 (High pressure turbine, HPT) 等部件的参数,如表 1 所示。

Table 1 Preliminary screening of sensor data

Number		Specific meaning
1	T_{24}	Total temperature at LPC outlet
2	T_{30}	Total temperature at HPC outlet
3	T_{50}	Total temperature at LPT outlet
4	P_{30}	Total pressure at HPC outlet
5	N_f	Physical fan speed
6	N_c	Physical core speed
7	p_{s30}	Static pressure at HPC outlet
8	ϕ	Ratio of fuel flow to p_{s30}
9	N_{Rf}	Corrected fan speed
10	N_{Rc}	Corrected core speed
11	BPR	Bypass ratio
12	h_{Bleed}	Bleed enthalpy
13	W_{31}	HPT coolant bleed
14	W_{32}	LPT coolant bleed

利用传感器数据变化幅度、传感器数据出厂数值差异和传感器下发数值差异这三个筛选标准对这 14 个参数进行筛选后,进行综合分析,得到的结果如图 4~图 7 所示。

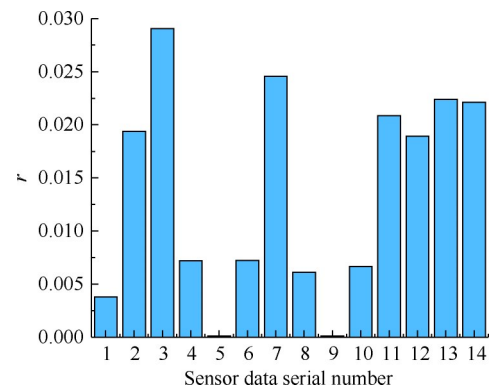


Fig. 4 Analysis of sensor data variation amplitude

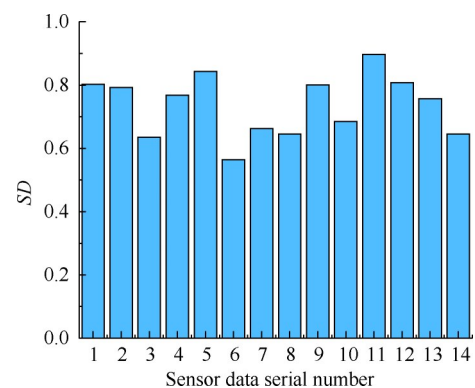


Fig. 5 Analysis of the difference between the sensor data values at engine leaving the factory

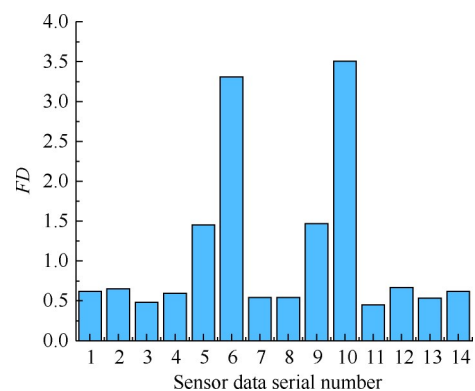


Fig. 6 Analysis of the difference between the sensor data values at engine removal

通过前文可以发现,传感器数据的变化幅度越大、出厂数值差异和下发数值差异越小,则该传感器与发动机性能退化的关联程度较高的可能性越大。经过综合筛选,分析出 h 值为正数的传感器数据有四个,分别是第 3、第 7、第 13 和第 14 个传感器数据,即低压涡轮出口总温、高压压气机出口静压、高压涡轮冷却引气量和低压涡轮冷却引气量。而数据集 FD001 为高压压气机故障导致发动机失效。高压压气机故障会导致其效率下降,增压能力下降,从而引

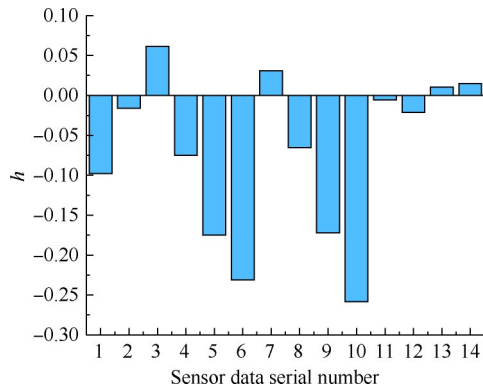


Fig. 7 Comprehensive analysis

起燃油消耗增加,燃烧室后各站位的温度变化幅度加大;另外也会影响涡轮的冷却空气的引气量。这与筛选出来的传感器正好符合。由于这些原始数据中带有白噪声且量纲不同,所以本文先通过一维数字滤波器对这四个传感器的数据进行滤波,然后采取去量纲处理和稳健局部加权回归对数据进行平滑处理。最后结合表2的权重构建一维健康指数。随机获取一台发动机的健康指数的变化趋势如图8所示。

Table 2 Selected sensor data and weight values

Number	Name	Weights
3	Total temperature at LPT outlet	0.52173
7	Static pressure at HPC outlet	0.26273
13	HPT coolant bleed	0.12447
14	LPT coolant bleed	0.09107




Fig. 8 Trend of an engine health index

3.3 预测结果

为了更好地体现发动机寿命预测精度并与其他方法进行比较,本文采用较为通用的评价指标均方根误差(Root mean square error, $RMSE$)和评分函数(Scoring function, $Score$)。 $RMSE$ 和 $Score$ 的表达式为

$$E_i = RUL_{a,i} - RUL_{p,i} \quad (11)$$

$$RMSE = \sqrt{\frac{1}{I} \sum_{i=1}^I E_i^2} \quad (12)$$

$$Score = \begin{cases} \sum_{i=1}^I \left(e^{\frac{E_i}{13}} - 1 \right), & \text{for } E_i < 0 \\ \sum_{i=1}^I \left(e^{\frac{E_i}{10}} - 1 \right), & \text{for } E_i \geq 0 \end{cases} \quad (13)$$

式中 $RUL_{a,i}$ 为第*i*个测试发动机的实际剩余使用寿命, $RUL_{p,i}$ 为第*i*台发动机的预测剩余使用寿命, E_i 为两者之差。

通过移动匹配确定的筛选标准如图9所示。结合结果和数据可以发现,影响筛选标准的主要有两个方面,分别是测试样本的运行循环长度和样本库中与测试样本趋势相似的样本数量。如果测试样本已知运行循环越长,样本库中与测试样本趋势相似的样本数量越少,会使得对测试样本的预测结果的筛选标准越低。

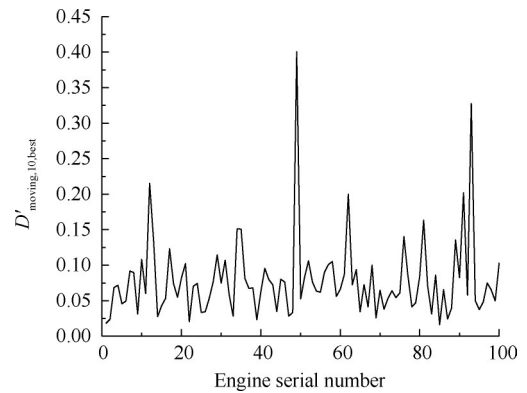


Fig. 9 Screening criteria for prediction results

最终计算的100台发动机的预测结果如图10所示。从预测结果可以看出,大部分预测结果与实际剩余使用寿命非常接近。




Fig. 10 Prediction error

为了进一步验证本文的双尺度相似性匹配(Two-scale similarity matching, TSM)的有效性,本文采用该领域的研究成果和本文的方法进行比较,包括支持向量回归(Support vector regression, SVR)^[21]、深度卷积网络(Deep convolutional neural network, DCNN)^[21]、双向长短时记忆网络(DLSTM)^[6]和基于退化特征的相似性匹配(Similarity matching based on degraded features, SMD)^[9]。表3给出了这几种方法的精度,可以发现本文方法的Score比当前的相似性匹配方法提高30.35%。这是因为本文采用双尺度去刻画时间序列间的相似性,同时研究固定匹配和移动匹配各自的优劣使其得以更好的结合。但是由于样本库的全寿命历史数据有限,没办法形成较为完备的样本库,以致于很难为每个测试样本都匹配出精确的训练样本。

Table 3 Comparison of prediction accuracy of different prediction methods

Method	RMSE	Score
SVR	20.96	1381
DCNN	18.45	1287
DLSTM	18.33	655
SMD	N/A	682
TSM	17.48	475

4 结论

通过本文研究,得到如下结论:

(1)采用的传感器数据筛选标准和综合分析方法能够筛选出与发动机退化关系密切的传感器数据,构建的健康指数能有效表征发动机性能衰退。

(2)引入了斜率与曼哈顿距离形成双尺度,对不同时间序列的相似度有更加精确的刻画。基于固定匹配和移动匹配各自的特点,有效结合这两种相似性匹配方法,同时利用移动匹配出现高匹配度和高预测精度的可能性较大的特点,筛选优化预测结果,以获得更加准确的预测结果。

(3)通过与当前的相似性匹配方法进行对比,得出本文的改进相似性匹配方法有更高的预测精度,缩小预测结果的误差范围。在与其他机器学习方法的比较上,该方法优于一些机器学习方法。但是数据集集中的样本有限,有些预测样本没办法得到较好的相似性匹配结果。因此,在对于如何使现有样本得到更加深入的挖掘、使有限的样本得到更充分的利用的问题上,还可以继续深入研究。

参考文献

- [1] 中国民用航空局. 中国民用航空发展第十三个五年规划[EB/OL]. http://www.gov.cn/xinwen/2017-02/16/content_5168506.htm, 2017.
- [2] 尉询楷, 杨立, 刘芳, 等. 航空发动机预测与健康管理[M]. 北京: 国防工业出版社, 2014: 132-133.
- [3] Pecht M. Prognostics and Health Management of Slscronics[M]. New Jersey: Wiley Online Library, 2008.
- [4] 黄亮, 刘君强, 贡英杰. 基于一致性检验的航空发动机剩余寿命预测[J]. 系统工程与电子技术, 2018, 40(12): 2736-2742.
- [5] 王玺, 胡昌华, 任子强, 等. 基于非线性Wiener过程的航空发动机性能衰减建模与剩余寿命预测[J]. 航空学报, 2020, 41(2): 195-205.
- [6] 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). (MA Qi-you, LIU Ke-wei, DU Jian, et al. Prediction of Engine Blades Based on Deep Short Term Memory Network [J]. *Journal of Propulsion Technology*, 2021, 42(8).)
- [7] Zhang C, Lim P, Qin A K, et al. Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics[J]. *IEEE Trans Neural Netw Learn Syst*, 2017, 28(10): 2306-2318.
- [8] Xia T B, Song Y, Zheng Y, et al. An Ensemble Framework Based on Convolutional Bi-Directional LSTM with Multiple Time Windows for Remaining Useful Life Estimation[J]. *Computers in Industry*, 2020, 115(10).
- [9] Shi J, Li Y, Wang G, et al. Health Index Synthesis and Remaining Useful Life Estimation for Turbofan Engines Based on Run-to-Failure Datasets [J]. *Maintenance and Reliability*, 2016, 18(4): 621-631.
- [10] 张妍, 王村松, 陆宁云, 等. 基于退化特征相似性的航空发动机寿命预测[J]. 系统工程与电子技术, 2019, 41(6): 1414-1421.
- [11] Yu Wennian, Kim I Y, Me-chefske C. An Improved Similarity-Based Prognostic Algorithm for RUL Estimation Using an RNN Autoencoder Scheme [J]. *Reliability Engineering and System Safety*, 2020, 199(10).
- [12] Guo L, Lei Y G, Li N P, et al. Deep Convolution Feature Learning for Health Indicator Construction of Bearings [C]. *Harbin: Prognostics and System Health Management Conference*, 2017: 1-6.
- [13] Mengru Hou, Dechang Pi, Bingrong Li. Similarity-Based Deep Learning Approach for Remaining Useful

- Life Prediction[J]. *Measurement*, 2020, 159(10).
- [14] 赵洪利, 张 猛. 基于随机维纳过程的航空发动机性能衰退研究[J]. *推进技术*, 2021, 42(3). (ZHAO Hong-li, ZHANG Meng. Research on Performance Degradation of Aeroengines Based on Stochastic Wiener Process [J]. *Journal of Propulsion Technology*, 2021, 42(3).)
- [15] D MIL-HDBK-516C, Airworthiness Certification Criteria [S].
- [16] Benzakein M. Propulsion Strategy for the 21st Century a Vision into the Future[R]. *ISABE 2001-1005*.
- [17] DJSSG 2007B, Joint Service Specification Guide: Engines, Aircraft, Turbine[S].
- [18] FAR 33, Airworthiness Standards: Aircraft Engine[S].
- [19] Zhang J, Wang P, Yan R, et al. Long Short-Term Memory for Machine Remaining Life Prediction [J]. *Journal of Manufacturing Systems, Part C*, 2018, 48: 78-86.
- [20] Sexena A, Kai G, Simon L D, et al. Damage Propagation Modeling for Aircraft Engine Run-to-Failure Simulation[C]. *Denver: IEEE International Conference on Prognostics and Health Management*, 2008.
- [21] Babu G S, Zhao P, Li X L. Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life [C]. *Dallas: International Conference on Database Systems for Advanced Applications*, 2016.

(编辑:朱立影)