

一种基于试飞数据的航空发动机 滑油金属含量预测方法



尤黎明

中国飞行试验研究院, 陕西 西安 710089

摘 要:航空发动机工作时轴承和齿轮等传动部件相互摩擦产生的金属屑会随着润滑系统流入滑油箱、附件机匣等部位,而不同工作状态与环境造成的磨损程度不同,因此滑油中金属含量一定程度上可反映发动机的磨损状态。以某型航空发动机的试飞数据与滑油光谱数据为基础,通过分析润滑系统运行机理,确定了滑油金属含量的主要影响因素,采用信息扩散结合支持向量机的方法建立了滑油金属含量预测模型,解决了小样本数据限制的问题。模型预测结果的相对误差不大于5.7%,能够满足实际工程的精度需求,所建立的滑油金属含量预测模型对航空发动机磨损故障有积极的预防作用。

关键词:滑油金属含量预测; 试飞数据; 信息扩散; 支持向量机; 小样本数据

中图分类号:V317.1

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2022.05.002

在高温、高速、高振动的恶劣环境下工作,航空发动机的轴承、齿轮等传动部件会承受较大的载荷,容易发生磨损故障,严重影响发动机的安全工作。据统计,80%的航空发动机故障与磨损有着直接或间接的联系,更是早期故障的最主要原因^[1]。因此,航空发动机都设有循环工作的润滑系统对磨损部位进行润滑,以减少磨损程度。而润滑油在发动机中循环使用的过程中,流经磨损部位后将摩擦所产生的金属屑等磨损微粒溶入滑油中,携带了发动机零部件磨损的重要信息。可通过光谱技术对航空发动机润滑油中的金属含量进行检测和分析,掌握发动机内部诸如轴承、齿轮、花键等传动部件与摩擦部件的磨损情况,有助于发现润滑部件的早期损伤,视情开展相应的检查和维护,消除潜在隐患^[2]。因此,对滑油金属屑的监测是保障航空发动机运行安全的重要手段之一。

目前,国内针对航空发动机滑油金属含量预测技术的研究主要集中在发动机地面试验以及对滑油光谱序列数据本身的分析等方面,如丁刚等^[3]提出了一种基于Elman过程神经网络的预测方法,对滑油光谱历史数据进行预测。尉询楷等^[4]提出了一种基于支持向量机的发动机滑油预测模型,利用支持向量回归对滑油光谱数据的时间序列进行多

步预测。李本威等^[5]提出了一种基于克隆选择的免疫粒子群优化算法,改善了滑油金属屑预测模型的预测精度。曾力等^[6]通过建立粒子散射模型,优化了基于支持向量回归机的滑油金属含量预测模型,提高了预测精度。以上研究将滑油光谱数据视为时间序列进行分析,但由于数据的随机性、离散性和强耦合性等限制因素,较少考虑飞机以及发动机的不同工作状态和工作环境对发动机磨损的影响。

而在飞行过程中,飞机的特技飞行等大机动作往往伴随着法向过载的大幅度变化,发动机工作状态也会频繁变化,从而对发动机内部摩擦部件与润滑系统的平衡产生影响,最终造成了润滑部件的不同程度磨损。传动部件所产生的疲劳裂纹通常不易察觉,采用滑油光谱技术可在一定程度上进行监测^[7]。因此,需要考虑飞机以及发动机的工作状态及环境的变化,有必要建立滑油金属含量预测模型,以实现滑油系统工作状态的健康监测。

本文提出了一种基于试飞数据的滑油金属含量预测方法,采用信息扩散结合支持向量机建立预测模型,将飞机与发动机的试飞数据进行分析与处理,作为预测模型输入数据,进行滑油金属屑含量预测研究。由于航空发动机内部摩擦部件材料的元素成分主要以铁、铝、铜(Fe、Al、Cu)为

收稿日期: 2021-10-10; 退修日期: 2022-01-15; 录用日期: 2022-03-16

引用格式: You Liming. A method for predicting lubricating oil metal element of aero-engine based on flight test data[J]. Aeronautical Science & Technology, 2022, 33(05): 12-17. 尤黎明. 一种基于试飞数据的航空发动机滑油金属含量预测方法[J]. 航空科学技术, 2022, 33(05): 12-17.

主,其中Fe元素占比较大,如在齿轮以及轴承中的质量分数可超过70%^[8],本文以滑油中Fe元素为对象,建立金属含量预测模型。在实际试飞中,由于单个飞行日只进行一次滑油光谱检测,光谱分析样本量较小,通过采用信息扩散方法对数据样本进行模糊处理,扩散后的数据在一定程度上弥补了小样本的不完备性等缺陷,改善了数据样本的质量,提高了模型的预测精度。计算表明,该模型具有较好的预测精度,为发动机滑油金属含量的预测提供了有效的技术手段。

1 模型参数分析

1.1 航空发动机滑油系统机理分析

航空发动机在运行过程中会对轴承、齿轮、花键等摩擦部件造成磨损,由于航空发动机一般采用循环润滑系统,因此磨损产生的金属屑会随润滑油流入滑油箱中,而飞机与发动机所处的工作状态与工作环境变化会导致磨损程度不同。滑油中的金属含量可在一定程度上反映磨损程度。所以可通过对试飞数据的分析,以及发动机滑油系统的工作原理与特点来确定预测模型的输入参数。

航空发动机常规滑油系统简图如图1所示,系统包括供油、回油和通风三个主要部分。发动机运作时供油泵将滑油箱内的滑油抽出并加压,再经滑油滤过滤后分成若干油路送往各轴承及传动部件进行润滑和散热;润滑过后含有大量空气的高温滑油经回油泵抽取,进入油气分离器,最终返回滑油箱;由于滑油因受热而部分汽化、滑油喷嘴的喷射、飞溅以及部分压缩空气可能经封油装置进入滑油系统内形成大量滑油蒸气,导致滑油润滑、冷却效果变差,因此需经通风部分将这些蒸气引出^[9]。

1.2 模型参数的优化和确定

通过以上分析可知,供油路以及各轴承与传动部件本身状态是影响滑油中金属含量的主要因素。主要影响因素如下。

(1) 滑油压差。滑油泵组中设置有调压阀,用来调节供油压力和轴承腔腔压之差(即滑油压差),滑油压差过小会导致系统润滑不良,加剧传动部件磨损^[10],可用滑油压差表征供油路对系统润滑效果的影响。

(2) 滚转角与法向过载。飞行过程中飞机进行特技飞行等大机动作会导致发动机内部润滑部件润滑环境受到影响,破坏润滑系统与摩擦部件的平衡,从而加剧磨损。同时,也会影响滑油箱、供油管路与滑油喷嘴的相对位置,恶化润滑环境,可采用滚转角与法向过载来表征飞行时机动




图1 航空发动机常规滑油系统简图

Fig.1 Schematic diagram of conventional lubricating oil system of aero engine

动作的剧烈程度对摩擦部件润滑环境的影响。

(3) 慢车状态与高压转子转速。发动机状态也是影响磨损程度的重要因素之一,飞行过程中发动机处于慢车状态时,由于滑油泵等附件直接由高压转子传动,因此滑油系统的供油条件会相应减弱,而此时发动机高低压转子依旧在高速转动,与轴承产生摩擦,加剧磨损。因此,可选择发动机慢车状态及高压转子转速来表征发动机状态对系统磨损程度的影响。

基于以上分析结论,初步确定了以飞机法向过载、主管路滑油压差、滚转角改变大于 $\pm 30^\circ$ 的次数、滚转角改变的持续时间、发动机慢车状态持续时间,以及高压转子转速作为建模所需的输入参数,以滑油中Fe含量作为输出参数进行建模研究。

为了验证所选参数的正确性和合理性,采用平均影响值(mean impact value, MIV)算法对预测模型所用参数进行了敏感性分析。

MIV算法原理为:在模型训练结束后将训练样本 P 中的每一个自变量特征在其原值基础上分别加和减10%构成两组新的训练样本 P_1 和 P_2 ,使用模型对这两组样本进行仿真,得到两组仿真结果 A_1 和 A_2 ,求出 A_1 和 A_2 的差值,即为变动该自变量后对输出产生的影响变化值(impact value, IV),最后将IV按观测例数平均得出该自变量对于因变量即模型输出的MIV。依次算出各自变量的MIV值,即可得到各自变量对网络输出的影响程度大小。滑油光谱Fe元素含量预测模型相关参数的MIV值如图2所示。

从图2中可看出:参数1~8对模型输出的影响程度明显高于参数9~13。表明MIV算法参数敏感性分析结果与前




图2 各参数MIV值

Fig.2 MIV value of each parameter

1—法向过载均值；2—主管路滑油压差；3—滚转角改变大于 $\pm 30^\circ$ 次数；4—滚转角改变持续时间均值；5—滚转角改变持续时间总和；6—慢车状态时间总和；7—慢车状态高压转子平均转速；8—气压高度最大值；9—气压高度均值；10—马赫数均值；11—俯仰角均值；12—加速度最大值；13—飞行日飞行架次数

文所述参数分析结果一致,证明了通过对发动机滑油系统工作原理及发动机工作分析确定影响滑油金属含量方法的可行性。

1.3 建模所用数据

建模采用的数据样本来源于某型发动机不同工况下的试飞数据和滑油光谱检测数据,发动机数据涵盖了飞行包线的大部分范围,相关参数的最小值和最大值见表1。

表1 相关参数的最小值和最大值

Table 1 Minimum and maximum values of related parameters

参数	最小值	最大值
气压高度 h/m	376	16548
飞行马赫数 Ma	0.20	1.72
大气总温 t/K	236.8	355.0
法向过载	-1.2	5.9
滑油压差 p/kPa	0	341.12
滚转角 $\theta/(^\circ)$	-179.7	179.9
高压转速 $n_2/\%$	0	115.2
Fe元素增量 $S/10^{-6}$	0.40	6.22

2 信息扩散方法

由于滑油金属屑样本数量较少,属于小样本问题,而小样本问题的实质是信息不足,不能反映整个样本空间的分布情况。

信息扩散是一种对样本进行集值化的模糊数学处理方

法,可以将单值样本变成集值样本。信息扩散的原理是当用不完备的数据估计一种关系时,一定存在合理的扩散方式将观测值变为模糊集,以填充由数据不完备性造成的部分缺陷,从而改进非扩散估计^[11],以改进或优化建模数据样本的质量或提升预测模型的性能。对数据的扩散是通过扩散函数实现的,其中最常用的扩散函数是正态扩散函数

$$\mu(x, u) = \exp\left(-\frac{(x - u)^2}{2h^2}\right), \quad x \in X, u \in U \quad (1)$$

式中: $X = \{x_i | i = 1, 2, \dots, n\}$ 为样本集, n 为原始样本数量; $U = \{u_j | j = 1, 2, \dots, m\}$ 为等距的监测集, m 为等距监测点数量; h 为扩散系数,可以按照式(2)进行计算。

$$h = \begin{cases} 0.6841(b - 1), & n = 5 \\ 0.5404(b - 1), & n = 6 \\ 0.4482(b - a), & n = 7 \\ 0.3839(b - a), & n = 8 \\ 2.6851(b - a)/(n - 1), & n \geq 9 \end{cases} \quad (2)$$

式中: $b = \max_{1 \leq i \leq n} \{x_i\}$, $a = \min_{1 \leq i \leq n} \{x_i\}$ 。

通过扩散函数,可以将 X 扩散为 U 上的模糊集。

3 支持向量机回归模型

支持向量机(SVM)于1995年被正式提出,是一种基于统计学习理论中的风险最小化原则的机器学习算法。它一开始是针对二分类任务所设计,采用核函数的方法将样本从原始空间映射到一个更高维的特征空间,使得样本在高维特征空间内线性可分^[12]。

支持向量回归(SVR)问题的主要思想与分类问题较为相似,不同之处仅在于输出的取值范围不同。在分类问题中,输出只允许取有限个值,而在回归问题中,输出可取任意实数。因此,回归模型的建立相当于在高维空间中通过式(3)来拟合训练样本 (x_i, y_i) , $i = 1, 2, \dots, n$, 其中 x_i 为输入值, y_i 为输出值。

$$y = \omega \cdot \varphi(x) + b \quad (3)$$

于是,支持向量回归问题可转变为

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n l_\varepsilon(f(x_i) - y_i) \quad (4)$$

式中: C 为正则化常数; l_ε 为不敏感损失函数。

引入松弛变量 ξ_i 和 $\hat{\xi}_i$, 可将式(4)重写为

$$\min_{\omega, b, \xi_i, \hat{\xi}_i} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \hat{\xi}_i) \quad (5)$$

$$\text{s.t. } f(x_i) - y_i \leq \varepsilon + \xi_i$$

$$y_i - f(x_i) \leq \varepsilon + \hat{\xi}_i$$

$$\xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, n$$

对式(4)引入 Lagrange 函数与核函数 $k(x_i, x_j)$, 并采用式(5)的对偶形式, 最终得到高维空间的线性拟合函数

$$f(x) = \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i) k(x_i, x_j) + b \quad (6)$$

由于目前在国际上并没有通用的核函数选择方法, 因此在这里根据经验选择最常用的高斯核函数, 其表达式为

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (7)$$

式中: $\sigma > 0$ 为高斯核的带宽。

4 预测模型参数优化

采用 K 折交叉验证的方法来优化预测模型的参数。首先, 将数据集 D 划分为 k 个大小相似的互斥子集, 即

$$D = D_1 \cup D_2 \cup \dots \cup D_k, D_i \cap D_j = \emptyset, i \neq j \quad (8)$$

式中: D_i 为样本集的每个子集。

每个子集 D_i 都通过从 D 中分层采样得到。然后每次用 $k-1$ 个子集的并集作为训练集, 余下的子集作为测试集, 可获得 k 组训练集, 从而可进行 k 次训练和测试, 最终返回 k 次测试结果的均值。 K 折交叉验证可以有效地避免模型过学习以及欠学习状态的发生, 最后得到的结果也比较具有说服力。 K 折交叉验证的示意图如图3所示。




图3 K 折交叉验证示意图

Fig.3 Schematic of K -fold cross validation

5 试验验证

采用某型航空发动机滑油光谱中 Fe 元素含量的增量以及相应的试飞数据共 20 组数据作为样本集, 其中前 16 组为训练数据, 后 4 组为预测数据。

第一步, 对原始样本数据进行归一化处理, 采用最大最小法将数据归一化到 $[0, 1]$ 区间内; 第二步, 采用信息扩散原理将归一化后的样本集进行扩充, 其中监测集 U 也选择为 $[0, 1]$ 区间, 间距为 0.2, 将原 16 组样本扩充为模糊集中的 96 组; 第三步, 建立支持向量回归预测模型, 如前所述, 选择高斯径向基函数作为核函数, 采用 K 折交叉验证法来选取回归模型的最佳参数 c 和 g 来优化模型的预测性能, 先进行粗略的寻找, 观测粗略寻找的结果后再进行精细选择, 图4、图5为粗略与精细寻找的结果图; 最后, 将预测集样本输入模型中测试其泛化能力。




图4 粗略寻找结果图

Fig.4 Roughly looking result graph

模型的训练与预测结果如图6所示, 图中虚线左侧为进行信息扩散后的训练样本, 右侧为4组预测样本结果, 可看出实际预测结果较为准确。

表2对未采用信息扩散方法的原始样本预测结果与进行扩散后的样本预测结果进行了比较。可以看出, 未进行信息扩散前的原始样本训练的模型的预测结果平均相对误差为 18.4%, 而采用信息扩散方法后的平均相对误差为 5.7%, 其他如平均平方误差 (MSE)、平方相关系数等参数指标均有较大的提升。这表明了采用信息扩散与支持向量机进行结合的方法的可行性与有效性。





图5 精细选择结果图
Fig.5 Fine selection result graph




图6 模型训练与预测结果
Fig.6 Model training and prediction results

6 结论

通过研究,可以得出以下结论:

(1) 本文通过对发动机滑油系统工作原理与实际试飞数据的分析,总结出影响滑油金属含量的主要因素来自飞

表2 采用信息扩散优化前后预测结果对比

Table 2 Comparison between prediction results before and after using information diffusion optimization

Fe元素实际 增量/ 10^{-6}	预测结果/ ppm		相对误差/%		平均相对 误差/%		平均平方 误差		平方相关 系数	
	未优 化	优化	未优 化	优化	未优 化	优化	未优 化	优化	未优 化	优化
0.74	0.56	0.69	24.4	6.2	18.4	5.7	0.24	0.01	0.68	0.96
0.88	0.55	0.82	38.1	6.9						
0.49	0.51	0.53	4.3	8.1						
0.56	0.52	0.55	6.8	1.3						

机的机动动作以及滑油系统的工作状态两方面。

(2) 本文结合信息扩散原理与支持向量回归方法建立滑油金属含量预测模型,模型预测结果较好,能够满足实际工程的精度需求,表明了在小样本情况下采用信息扩散原理建立预测模型的可行性与有效性。

AST

参考文献

- [1] 吴振锋,左洪福. 航空发动机磨损故障分析及诊断技术评述[J]. 航空工程与维修,2002(6):42-43.
Wu Zhenfeng, Zuo Hongfu. The commentary of the wearing faults analysis and diagnosis technology of aero-engine[J]. Aviation Maintenance and Engineering, 2002(6): 42-43. (in Chinese)
- [2] 曲昌琦,周锐,杜宝,等. 航空装备故障预测与健康管理的数
据体系研究[J]. 航空科学技术,2020,31(12):61-67.
Qu Changqi, Zhou Rui, Du Bao, et al. Research on PHM data
system architecture for aviation equipment[J]. Aeronautical
Science & Technology, 2020, 31(12): 61-67. (in Chinese)
- [3] 丁刚,钟诗胜,栾圣罡. 航空发动机滑油金属含量预测及其控
制研究[J]. 润滑与密封,2006(9):52-54.
Ding Gang, Zhong Shisheng, Luan Shenggang. Research on
aeroengine lubricating oil metal element concentration
prediction and its control[J]. Lubrication Engineering, 2006(9):
52-54. (in Chinese)
- [4] 尉询楷,李应红,王硕,等. 基于支持向量机的航空发动机滑
油监控分析[J]. 航空动力学报,2004,19(3):392-397.
Wei Xunkai, Li Yinghong, Wang Shuo, et al. Aeroengine
lubrication monitoring analysis via support vector machines[J].
Journal of Aerospace Power, 2004, 19(3): 392-397. (in Chinese)
- [5] 李本威,张赞,孙涛. 基于免疫粒子群算法的滑油屑末支持向量
机预测模型设计[J]. 航空动力学报,2009,24(7):1639-1643.

- Li Benwei, Zhang Yun, Sun Tao. Design of forecasting model for aero-engine lubrication debris support vector machines based on immune-particle swarm optimization algorithm[J]. Journal of Aerospace Power, 2009, 24(7): 1639-1643. (in Chinese)
- [6] 曾力, 龙伟. 基于SVR的航空发动机滑油金属含量预测方法[J]. 四川大学学报, 2016, 48(2): 161-164.
- Zeng Li, Long Wei. Prediction method of metal content of aero engine lubricating oil based on SVR[J]. Journal of Sichuan University, 2016, 48(2): 161-164. (in Chinese)
- [7] 袁慎芳, 李晓泉, 陈健. 疲劳裂纹扩展的卷积神经网络辨识[J]. 航空科学技术, 2020, 31(7): 64-71.
- Yuan Shenfang, Li Xiaoquan, Chen Jian. Convolutional neural network based fatigue crack growth identification[J]. Aero nautical Science & Technology, 2020, 31(7): 64-71. (in Chinese)
- [8] 陈果. 航空发动机磨损故障的智能融合诊断[J]. 中国机械工程, 2005, 16(4): 299-306.
- Chen Guo. Intelligent fusion diagnosis of aeroengine wear faults[J]. China Mechanical Engineering, 2005, 16(4): 299-306. (in Chinese)
- [9] 张帅. 基于滑油分析的航空发动机磨损监测技术研究[D]. 沈阳: 沈阳航空航天大学, 2012.
- Zhang Shuai. Research on technologies of aeroengine wear monitoring based on lubrication oil analysis[D]. Shenyang: Shenyang Aerospace University, 2012. (in Chinese)
- [10] 许艳芝, 李志鹏, 郭政波. 某型涡扇发动机滑油压差异常故障分析[J]. 科学技术与工程, 2019, 19(17): 341-346.
- Xu Yanzhi, Li Zhipeng, Guo Zhengbo. Failure analysis of abnormal oil pressure difference drop for a turbofan engine[J]. Science Technology and Engineering, 2019, 19(17): 341-346. (in Chinese)
- [11] Huang C F. Principle of information diffusion[J]. Fuzzy Sets and Systems, 1997, 91(1): 69-90.
- [12] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- Zhou Zhihua. Machine learning[M]. Beijing: Tsinghua University Press, 2016. (in Chinese)

A Method for Predicting Lubricating Oil Metal Element of Aero-Engine Based on Flight Test Data

You Liming

Chinese Flight Test Establishment, Xi'an 710089, China

Abstract: When the aero-engine works, the metal scraps produced by the friction between the transmission parts such as bearings and gears will flow into the lubricating oil tank, accessory casing and other parts along with the lubrication system, and the degree of wear caused by different working conditions and environments is different, so the metal content in the lubricating oil can reflect the wear state of the engine to some extent. Based on the flight test data and oil spectrum data of an aero-engine, the main influencing factors of oil metal content are determined by analyzing the operation mechanism of the lubrication system. The prediction model of oil metal content is established by using the method of information diffusion combined with support vector machine, which solves the problem of limited small sample data. The relative error of the prediction result of the model is less than 5.7%, which can meet the precision requirement of practical engineering. The established prediction model of lubricating oil metal content has positive preventive effect on aero-engine wear fault.

Key Words: lubricating oil metal element prediction; flight test data; information diffusion; support vector machine; small sample data