

文章编号: 1000-8055(2024)10-20220191-10

doi: 10.13224/j.cnki.jasp.20220191

## 航空发动机磨损故障多目标融合诊断

马佳丽<sup>1</sup>, 陈果<sup>2</sup>, 康玉祥<sup>1</sup>, 王雨薇<sup>1</sup>, 苗慧慧<sup>3</sup>, 曹桂松<sup>3</sup>

- 南京航空航天大学 民航学院, 南京 210016;
- 南京航空航天大学 通用航空与飞行学院, 江苏 溧阳 213300;
- 中国航发商用航空发动机有限责任公司, 上海 200241)

**摘要:** 针对多种油液分析数据的特点, 建立了航空发动机磨损故障融合诊断方法, 实现基于油液分析数据的航空发动机磨损状态综合评估。该故障融合诊断方法包括磨损故障定性分析、定位分析和定因分析。定性分析以光谱、铁谱和颗粒计数原始分析数据为输入, 基于(Dempster-Shafer)证据理论获得发动机磨损故障定性诊断结果; 在定位分析部分, 建立了基于深度学习的滚动轴承故障部位识别模型, 以能谱分析原始数据作为模型输入, 实现了航空发动机磨损部位的智能识别; 最后, 在定性分析部分, 利用定性结果和定位结果, 根据领域专家的经验, 建立了基于 if-then 的知识规则, 找出发动机磨损故障原因; 利用实际油液监测数据对所提方法的有效性和可靠性进行验证, 诊断精度最高可达到 100%, 结果充分表明了该方法的正确性、有效性。

**关键词:** 滚动轴承; 磨损故障; 融合诊断; D-S 证据理论; 一维卷积残差网络

中图分类号: V263.6

文献标志码: A

### Multi-objective fusion diagnosis of aeroengine wear failure

MA Jiali<sup>1</sup>, CHEN Guo<sup>2</sup>, KANG Yuxiang<sup>1</sup>, WANG Yuwei<sup>1</sup>,  
MIAO Huihui<sup>3</sup>, CAO Guisong<sup>3</sup>

- College of Civil Aviation,  
Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
- College of General Aviation and Flight,  
Nanjing University of Aeronautics and Astronautics, Liyang Jiangsu 213300, China;
- Commercial Aircraft Engine Company Limited,  
Aero Engine Corporation of China, Shanghai 200241, China)

**Abstract:** According to the characteristics of various oil analysis data, an aeroengine wear fault fusion diagnosis method was established to realize comprehensive evaluation of aeroengine wear state based on oil analysis data. The fault fusion diagnosis method included wear fault qualitative analysis, location analysis and cause analysis. Taking the original analysis data of spectrum, Ferrography and particle count as the input, the qualitative diagnosis results of engine wear fault were obtained based on D-S evidence theory through qualitative analysis; in the location analysis, a rolling bearing fault location identification model based on deep learning was established, and the original data of energy spectrum analysis were used as the model input to realize the intelligent identification of aeroengine wear location; finally, in the cause analysis, using the qualitative results and positioning results, according to the experience of domain experts, the knowledge rules based on if-then were established to find out the cause

收稿日期: 2022-04-04

基金项目: 国家科技重大专项(J2019-IV-004-0071); 国家自然科学基金(51675263); 中国航发商用航空发动机有限责任公司项目

作者简介: 马佳丽(1998—), 女, 硕士生, 主要从事航空发动机故障诊断方面的研究。

引用格式: 马佳丽, 陈果, 康玉祥, 等. 航空发动机磨损故障多目标融合诊断[J]. 航空动力学报, 2024, 39(10): 20220191. MA Jiali, CHEN Guo, KANG Yuxiang, et al. Multi-objective fusion diagnosis of aeroengine wear failure[J]. Journal of Aerospace Power, 2024, 39(10): 20220191.

20220191-1

of engine wear fault. The effectiveness and reliability of the proposed method were verified by using the actual oil monitoring data, the diagnostic accuracy can reach up to 100%, and the results fully showed the correctness and effectiveness of the method.

**Keywords:** aero-engine; wear failure; fusion diagnosis; D-S evidence theory; one dimensional convolution residual network

为保证航空发动机运行的安全性、可靠性和高效性,其运行状态监测与故障诊断技术已成为当今的研究热点<sup>[1-2]</sup>。磨损是航空发动机早期故障的主要原因,严重影响发动机的运行健康状态,而滑油监测是对航空发动机磨损故障最有效的状态评估手段之一<sup>[3]</sup>。滑油监测技术主要有在线和离线两种。其中在线监测技术主要通过在线油路中安装具有感应功能的磁堵零部件来实现。在线监测主要以定量分析为主,当达到预警条件后,通过人工拆卸发动机进行故障分析。而以光谱分析、理化分析、铁谱分析等为代表的离线油液检测技术能够准确有效地实现滚动轴承的磨损状态、位置的诊断,已成为当前针对航空发动机磨损诊断的主要方法<sup>[4-6]</sup>。

单一的滑油分析方法准确率有限,容易造成重大安全事故。因此,目前许多研究已经开始充分利用多种油液分析数据,对发动机磨损故障进行诊断研究<sup>[7]</sup>。姜旭峰等<sup>[8]</sup>基于光谱数据和铁谱数据能够有效发现滑油中超标元素以及磨损类型和故障部位。孔祥兴等<sup>[9]</sup>应用模糊证据理论算法对油液多指标信息进行状态的融合和评估,有效地解决了监测信息不一致时油液状态无法表征的问题。张鹏飞等<sup>[10]</sup>基于光谱分析和自动磨粒检测 2 种滑油分析方法的结果评估出发动机的实际磨损状态。於迪等<sup>[11]</sup>监测机器润滑油的理化污染指标和磨损状态指标对磨辊的润滑与磨损状态进行了有效监控。马安祥等<sup>[12]</sup>基于人工免疫系统,并结合油液分析技术,提出了一种航空发动机磨损故障智能诊断方法。张海涛<sup>[13]</sup>采用油液的黏度、含水量、磨粒浓度 3 种特征信息判断船

舶发动机故障。以上的多种油液分析诊断方法均未能充分利用多种油样分析数据的互补性,对发动机磨损故障性质、发生的部位以及产生严重磨损的原因进行全面的融合诊断。

因此,针对目前研究工作的不足,本文提出基于多种油液分析数据的航空发动机磨损故障多目标融合诊断的方法。对多种油液分析数据进行融合,利用各种油液分析数据的互补性依次实现故障的定性、定位和定因诊断,最后利用实际发动机试验数据验证了本文方法的正确性、有效性。

## 1 多目标融合诊断流程图

基于油液分析的航空发动机磨损故障多目标融合诊断是采用多源数据,实现磨损故障的定性、定位和定因诊断。表 1 为各种油液分析数据对故障定性、定位、定因诊断的有效性。从表 1 中可以看出:对于定性诊断,光谱、颗粒计数和铁谱诊断的有效性最高,能谱数据和理化数据几乎不能提供信息,因此,采用光谱数据、颗粒计数数据和铁谱数据来实现故障的定性融合;对于定位诊断,除能谱数据外,其他数据均无法有效地对故障进行定位,因此,将能谱数据作为定位部分的诊断数据;对于定因诊断,铁谱数据和理化分析数据携带了大多数故障原因信息,颗粒计数数据次之,而光谱数据和能谱数据无定位诊断能力,因此在定位部分选择铁谱数据和理化分析数据。

诊断具体流程如图 1 所示,该方法主要以油液分析结果数据为输入,依据定性诊断结果决定是否进行定位诊断;然后基于 if-then 的知识规则进行定因诊断;最后输出定性、定位和定因诊断

表 1 各种油液分析数据对故障诊断的有效性分析

Table 1 Effectiveness analysis of various oil analysis data for fault diagnosis

参数	光谱数据	颗粒计数数据	铁谱数据	能谱数据	理化数据
定性	***	***	***	—	*
定位	*	—	—	***	—
定因	—	**	***	—	***

注:“\*\*\*”表示有效性最高;“\*\*”表示有效性中等;“\*”表示有效性较差;“—”为无效。

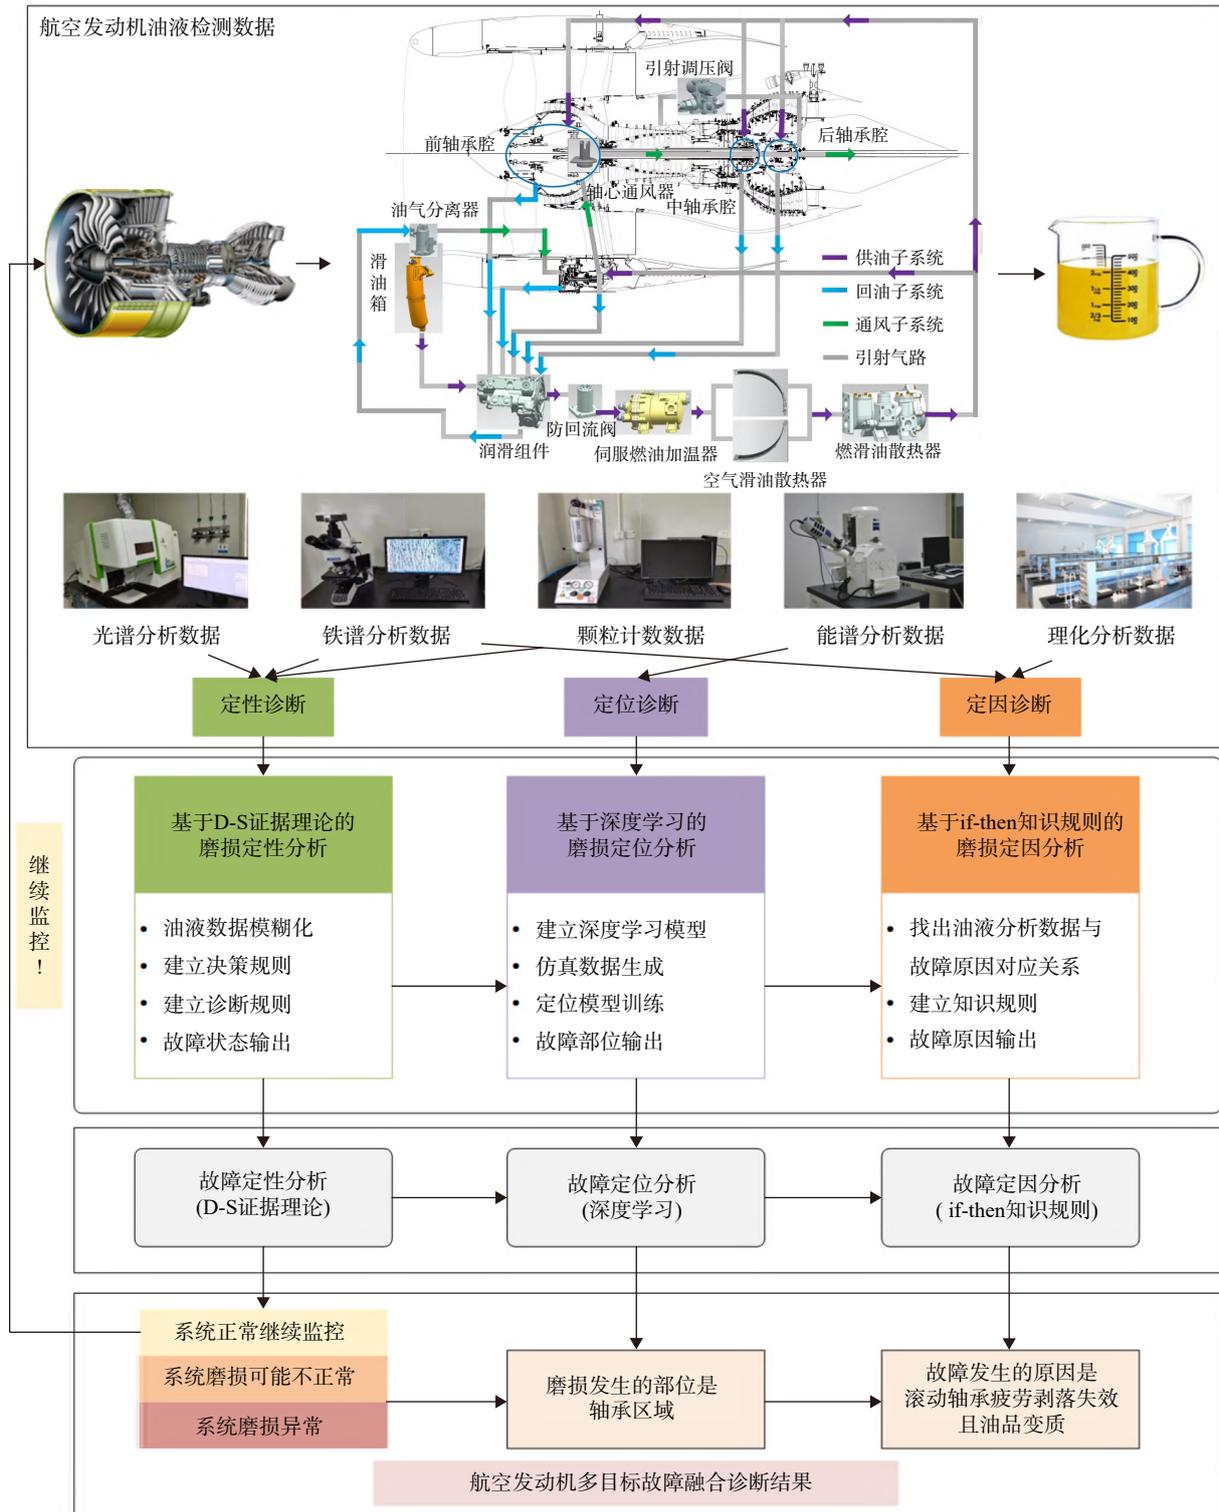


图 1 基于多种油液分析数据的航空发动机磨损故障多目标融合诊断流程图

Fig. 1 Multi-objective fusion diagnosis of aeroengine wear fault based on multiple oil analysis data oil analysis flow chart

结果。

## 2 发动机磨损故障定性分析

发动机磨损故障定性分析是实现定位分析和定因分析的前提与基础。为了定位分析和定因分

析,必须先对故障状态进行判断,进而实现航空发动机磨损故障多目标融合诊断。

### 2.1 数据预处理

由于各种油液分析方法得到的数据具有不同的量纲和量纲单位,本文引入了模糊集合的概念,

通过构建模糊逻辑隶属度函数模型, 获得各个油液检测参数的可信度。

首先利用自定义隶属度函数对油液检测数据进行模糊化处理, 隶属度函数表达式如式(1)所示。

$$U(x_i, a_1, a_2) = \begin{cases} 0.5 \times \frac{x_i}{a_1} & 0 \leq x_i \leq a_1 \\ 0.5 \times \frac{x_i - a_1}{a_2 - a_1} + 0.5 & a_1 < x_i \leq a_2 \\ 1 & x_i > a_2 \end{cases} \quad (1)$$

式中  $x_i$  为第  $i$  个证据的输入值,  $a_1$ 、 $a_2$  为第  $i$  个证据的警告界限值和异常界限值, 输出值  $U$  为第  $i$  个证据的可信度。图 2 给出了式(1)所描述的隶属度函数的曲线图。

根据专家经验和实际的统计分析结果得到的界限值将油液分析数据划分为“正常、警告、异常”3 种状态。

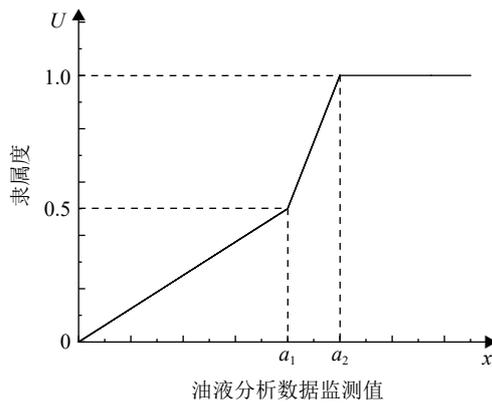


图 2 自定义隶属函数

Fig. 2 User defined membership function

### 2.2 D-S 证据理论模型

D-S 证据理论因其在不确定性问题上的高鲁棒性和完善的理论基础<sup>[14]</sup>, 被广大学者广泛应用到航空发动机故障诊断中<sup>[15-16]</sup>。因此, 本文选择 D-S 证据理论模型作为定性分析的诊断模型。

设光谱数据、铁谱数据和颗粒计数数据为证据  $E_i, i=1, 2, \dots, n$ , 其中  $n$  为油液数据的征兆个数。设需要诊断的故障为“故障 F 发生”。

1) 建立“故障”与“油液分析数据”之间的规则: IF:  $E_i$  异常, ( $A_i$ ), THEN:  $F$  发生, ( $B_i$ )。

其中  $E_i$  表示第  $i$  个证据,  $A_i$  为第  $i$  个证据的可信度。为计算各油液分析数据的证据可信度, 采用式(1)对相关数据进行模糊化, 并将模糊化后的值设定为该数据的证据可信度, 即  $A_i = U(x_i, a_1, a_2)$ ;  $B_i$  为每条规则的可信度, 在基于大量的专家知识和试验数据的基础上, 根据每个证

据建立相应的规则可信度。本文中油样数据 ( $E_i$ ) 的规则可信度如表 2 所示。

表 2 规则可信度  
Table 2 Rule credibility

证据	规则可信度	故障分析方法
Fe	0.5	
Cr	0.05	
Pb	0.05	
Cu	0.1	
Sn	0.05	
Al	0.05	
Ni	0.02	光谱分析
Ti	0.02	
Mn	0.05	
Ag	0.02	
Si	0.05	
Mg	0.02	
Mo	0.02	
疲劳磨粒	0.4	
球状磨粒	0.1	
层状磨粒	0.1	铁谱分析
红色氧化物	0.2	
黑色氧化物	0.2	
>5 μm	0.1	
>15 μm	0.2	颗粒计数分析
>25 μm	0.3	
>50 μm	0.4	

2) 建立综合可信度  $C_i$ :

$$C_i = A_i \times B_i \quad (2)$$

3) 融合诊断结果:

根据第  $i$  个证据所建立的综合可信度  $C_i$  计算多条规则的融合输出结果, 如式(3)所示:

$$y = 1 - \prod_{i=1}^n (1 - C_i) \quad (3)$$

其中  $1 - C_i$  代表综合可信度  $C_i$  补集发生的概率。具体的诊断规则如下所示:

IF:  $0 < y \leq 0.5$

THEN“该故障不发生, 系统正常!”

IF:  $0.5 < y \leq 0.8$

THEN“该故障可能发生, 系统磨损可能不正常!”

IF:  $0.8 < y \leq 1$

THEN“该故障已经发生,系统磨损异常!”

### 3 发动机磨损故障定位分析

发动机磨损故障定位分析的目的是进行故障部位识别,获得故障发生的具体位置,作为接下来进一步分析故障发生原因的参考信息。

#### 3.1 一维卷积残差网络模型

针对传统的数据特征提取方法难以提取滑油能谱数据有效特征的缺陷,本文提出了一种基于残差网络(Residual Networks, Resnet)和长短期记忆(long short-term memory, LSTM)神经网络的网络模型。不仅能实现端到端的发动机故障部位诊断,提高诊断效率,增加的残差网络也可以克服神经网络深层结构导致梯度消失的问题,提高整体分类精度<sup>[17]</sup>。此外,考虑能谱数据在时间维度上的变化,利用 LSTM 网络能获得数据在时间维度上的一维特征<sup>[18]</sup>。因此本文采用一维卷积残差网络模型用于故障部位识别。

该模型主要由 4 层残差网络、全连接层(fully connected layers, FC)和 LSTM 网络组合而成。一维卷积残差网络模型参数设置如表 3 所示。其中卷积核大小为 1×3,每层有 2 个残差块。

表 3 一维卷积残差网络参数

Table 3 One dimensional convolution residual network parameters

结构	卷积核参数	输出大小
第 1 层	(1×3×64)×2	1×31
第 2 层	(1×3×128)×2	1×15×128
第 3 层	(1×3×256)×2	1×7×256
第 4 层	(1×3×512)×2	1×3×512
FC	512×3×1	1536×1
LSTM	1536×3×200	200×1
FC	全连接层	29×1

#### 3.2 模型训练

##### 3.2.1 样本扩充

在实际故障识别应用中,通常存在材料牌号数据量不足的问题,导致故障诊断模型泛化性能不高。本文利用仿真的方法增加训练样本数量以提高模型泛化性能。

根据某型航空发动机材料数据库现有的 29 种材料牌号,将样本标签划分成 29 类,并利用式(4),对现有的样本扩充至 29 000 组,将样本集按照 7 : 3 进行拆分,70% 用于训练,30% 用于测

试,同时添加相应标签,并打乱训练集。

$$k_m = (u_b - u_l) \times r_1 + u_l \quad (4)$$

式中  $k$  为材料的第  $m$  个元素百分比含量;  $u_b$ 、 $u_l$  分别为元素含量的上限和下限;  $r_1 \in [0,1]$  之间的随机数。考虑到每个材料牌号都对应着 33 种元素百分比含量,因此在生成单个样本的过程中,先产生 33 个随机数  $r_1$ 。然后,采用式(4)产生每个元素对应的百分比含量。

##### 3.2.2 网络训练

完成训练样本的准备后,将 Adam 优化算法<sup>[19]</sup>用于模型训练,Adam 优化器可以有效缓解梯度震荡问题。损失函数采用交叉熵损失函数(Cross-entropy loss function),如式(5)所示:

$$J = - \sum_{i=1}^I y_i \log_e(p_i) \quad (5)$$

其中  $I$  表示类别的数量,  $y_i$  表示真实类别标签,  $p_i$  表示观测样本  $i$  属于类别的预测概率。

以最小化损失函数为目标训练网络,训练流程如图 3 所示。

为了验证所构建的模型故障诊断效果,本文分别采用了一维 Resnet18、Resnet34、卷积神经网络(convolutional neural networks, CNN)以及 LSTM 四种模型对航空发动机故障部位进行识别,图 4

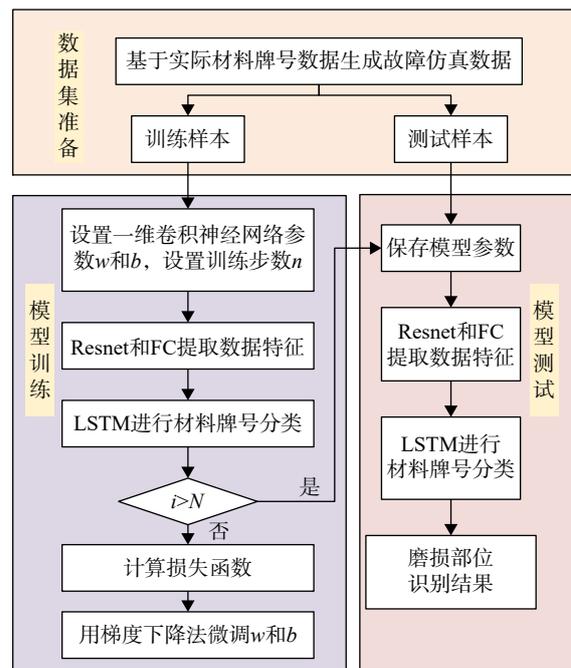


图 3 一维卷积神经网络训练流程图

Fig. 3 One-dimensional convolutional neural network training flow chart

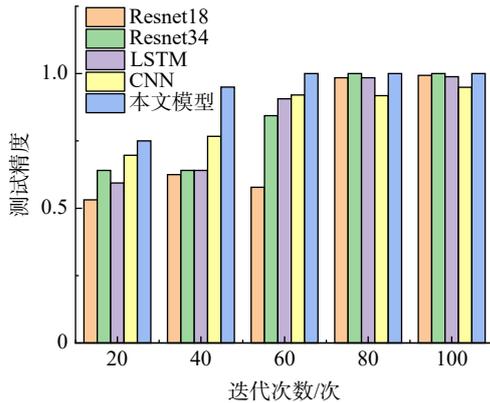


图 4 模型测试结果  
Fig. 4 Model test results

所示为 5 种模型测试精度曲线。

从图 4 可以看出, 每种诊断方法的测试精度都随着迭代次数的增加而提高, 虽然本文所提一维卷积残差网络的最终测试精度和 Resnet34 一样都为 100%, 但是在迭代过程中, 本文模型在测试集上的收敛速度明显快于 Resnet34, 具有明显优势。

#### 4 发动机磨损故障定因分析

经过上述故障定性分析和定位分析之后, 可以有效判断发动机相应的磨损程度及对应磨损部位。为了找出发动机故障原因, 应先获取油液性能参数与故障原因的对应关系, 具体如表 4 所示。

根据表 5 列出的油液的铁谱分析指标和理化指标, 将表 4 中的对应关系转化成知识规则的方法实现故障定因诊断。部分诊断规则如下所示:

Rule1: IF 疲劳磨粒数 < 4 and 球状磨粒数 < 5 and 层状磨粒数 < 2 and 红色氧化物数 < 3 and 黑色氧化物数 < 2, THEN 系统正常;

Rule2: IF 疲劳磨粒数 ≥ 4 or 球状磨粒数 ≥ 5 or 层状磨粒数 ≥ 2, THEN 滚动轴承疲劳剥落失效;

Rule3: IF 红色氧化物数 ≥ 3 or 黏度值 < 22.5 or 水分 > 0.001, THEN 润滑油中混有水分;

Rule4: IF 黑色氧化物数 ≥ 2 or 黏度值 ≥ 27.5 or 酸值 ≥ 0.15, THEN 润滑油供应不足或者长时间高温高负载工作。

表 4 油液性能参数变化与故障原因对照表

Table 4 Comparison between changes of oil performance parameters and fault causes

油液分析类型	油液参数变化	故障发生原因
铁谱分析	疲劳、球状和层状磨粒数量高于警告限	滚动轴承疲劳剥落失效
	红色氧化物数量高于警告限	润滑油中混有水分
	黑色氧化物数量高于警告限	润滑油供应不足, 长时间高温高负载工作
理化分析	水分含量高于警告限	润滑油中混有水分
	杂质含量高于警告限	润滑油中混有硬质颗粒杂质
	黏度含量高于警告限	润滑油供应不足, 长时间高温高负载工作
	黏度含量低于正常限	润滑油中混有水分
	酸值含量高于警告限	润滑油供应不足

表 5 元素故障界限值

Table 5 Element fault limit value

属性	铁谱分析/(个/mL)					理化分析				
	疲劳磨粒	球状磨粒	层状磨粒	红色氧化物	黑色氧化物	黏度/(mm <sup>2</sup> /s)	酸度/(mg/kg)	闪点/t/°C	水分/(mg/kg)	杂质/%
正常值	2	3	1	1	1	25	0.05	258	0	0
警告值	4	5	2	3	2	22.5/27.5	0.15	273	0.001	0.1

#### 5 滚动轴承磨损故障诊断实例

##### 5.1 试验数据获取

为验证本文提出的方法在航空发动机轴承故障监测上的实用性, 基于中国航发商用航空发动机有限责任公司对滑油系统进行健康管理的需求,

现采用实际试验数据证明本文方法的有效性。

航空发动机的轴承极容易发生机械磨损, 其中机械磨损又包括疲劳磨损、磨屑磨损和黏着磨损, 而疲劳磨损是最难预报的磨损类故障。因此, 本文以航空发动机滚动轴承来模拟疲劳磨损过程。

设计了基于 ABLT-1A 型滚动轴承加速疲劳试验采集油液数据。试验用到的轴承型号如图 5 所示的 M50 材料的圆柱滚子轴承, 与某在研发发动机轴承型号参数一致。数据采集装置如图 6 所示。

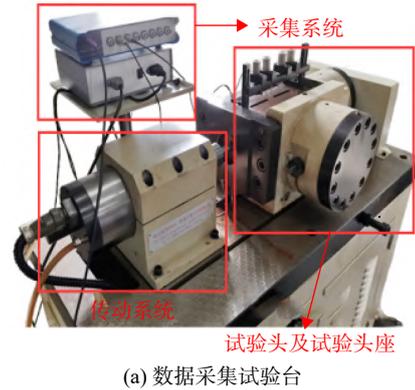


图 5 试验轴承  
Fig. 5 Test bearing

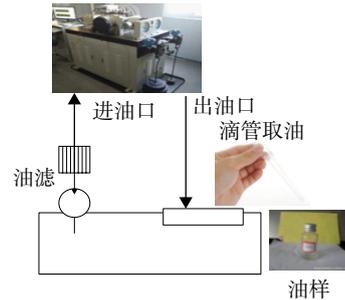
数据采集过程中, 使用美孚石油公司飞马 2 号航空润滑油, 并采用人工滴管方式从油箱进油口位置进行取油。本次试验一共进行了 192 h, 轴承发生严重磨损导致振动超过界限停机。并对采集得到的油液同时进行光谱分析、铁谱分析、颗粒计数分析、能谱分析和理化分析。

5.2 故障诊断实例

为进行深入分析, 我们分别获取了三组数据。表 6 展示了在光谱、铁谱、颗粒计数和理化分析试验数据的基础上加入白噪声得到的 40 组仿真



(a) 数据采集试验台



(b) 取油方式

图 6 数据采集装置

Fig. 6 Data acquisition device

数据; 表 7 则呈现了实际的磨损颗粒能谱分析数据; 而表 8 同样是基于上述试验数据加入白噪声

表 6 用于定性诊断的油液数据(部分数据)

Table 6 Fluid data for qualitative diagnosis (partial data)

数据	光谱分析/%				铁谱分析/(个/mL)				颗粒计数分析/(个/100 mL)			
	Fe	Ag	Cu	Cr	疲劳磨粒	球状磨粒	层状磨粒	红色氧化物	>5 μm	>15 μm	>25 μm	>50 μm
1	1.054	0.056	0.62	0.36	2.6	3.45	0.64	2.05	2 501.255	181.213	92.736	8.931
2	6.039	0.033	4.33	0.12	3	3.3	0.62	2.23	1 799.37	522.769	290.427	11.405
3	1.162	0.079	0.932	0.21	2.9	3.4	0.53	2.13	2 011.551	42.114	89.304	10.713
4	0.582	0.059	1.313	0	3	3.36	0.64	1.69	5 630.736	213.183	203.268	13.845
5	0.674	0.081	2.063	0.27	2.7	3.38	0.60	1.52	3 112.509	88.515	91.591	15.163
6	1.008	0.094	2.316	0.3	3.6	3.93	0.66	2.1	3 358.563	101.445	109.875	19.181
7	0.799	0.056	2.605	0.29	3.1	3.85	1.22	2.1	3 512.164	233.834	114.392	22.239
40	6.674	0.203	9.99	0.29	7.4	5.2	1.95	2.4	8 088.109	1 221.251	396.159	51.003

表 7 用于定位诊断的油液数据(部分数据)

Table 7 Fluid data for location diagnosis (partial data)

数据	Cu	Zn	Al	Mn	Fe	Sn	Cr	Mo	V	O	C
1	0	0	0	0	89.99	0	4.10	4.80	1.11	0	0
2	0	0	0	0	89.63	0	4.25	4.78	1.35	0	0
3	0	0	0	0	93.81	0	3.54	2.11	0.54	0	0
4	61.98	31.17	3.00	1.84	1.37	0.64	0	0	0	0	0
5	0	0	0	0	69.21	0	0	0	0	30.79	0
6	0	0	0	0	66.45	0	0	0	0	28.67	4.88
7	0	0	63.97	0	17.63	0	0	0	0	4.73	13.67
40	0	0	0	0	94.04	0	0	0.14	0.11	0	5.71

表 8 用于定因诊断的油液数据(部分数据)

Table 8 Fluid data for cause determination diagnosis (partial data)

数据	铁谱分析/(个/mL)					理化分析				
	疲劳磨粒	球状磨粒	层状磨粒	红色氧化物	黑色氧化物	黏度/(mm <sup>2</sup> /s)	酸度/(mg/kg)	闪点/ <i>t</i> /°C	水分/(mg/kg)	杂质/%
1	2.6	3.45	0.64	2.05	0.17	24.87	0.05	256.37	0	0.03
2	3	3.3	0.62	2.23	0	24.83	0.04	256.72	0	0.01
3	2.9	3.4	0.53	2.13	0.28	25.13	0.05	257.3	0	0.1
4	3	3.36	0.64	1.69	0.04	25.01	0.07	258.82	0	0.1
5	2.7	3.38	0.60	1.52	0.03	25.14	0.05	257.78	0	0.12
6	3.6	3.93	0.66	2.1	0.09	25.17	0.05	258.49	0	0.11
7	3.1	3.85	1.22	2.1	0.26	25.12	0.05	259.92	0	0.12
40	7.4	5.2	1.95	2.4	0.95	25.62	0.05	269.43	0	0.155

生成的另一组仿真数据。

对于定性诊断,本文选取表 6 中数据 30 的光谱数据、铁谱数据和颗粒计数数据来对算例进行验证。根据专家经验,该油样数据处于磨损的晚期,由表 9~表 13 的计算结果可知,各油液诊断结果均表示发动机处于故障状态,可以从不同侧面反映出此时发动机处于严重磨损状态,与定性融合诊断结果一致。其中 *A*、*B*、*C* 分别代表证据可信度、规则可信度和综合可信度。

表 9 光谱诊断结果( $\gamma=0.661$ )

Table 9 Spectral diagnosis results ( $\gamma=0.661$ )

证据	<i>A</i>	<i>B</i>	<i>C</i>
Fe	1	0.5	0.5
Ag	0.051 7	0.02	0.001
Cu	1	0.1	0.1
Cr	0.49	0.05	0.245

表 10 铁谱诊断结果( $\gamma=0.743$ )

Table 10 Ferrographic diagnosis results ( $\gamma=0.743$ )

证据	<i>A</i>	<i>B</i>	<i>C</i>
疲劳磨粒	1	0.4	0.5
球状磨粒	0.78	0.1	0.312
层状磨粒	0.65	0.1	0.065
红色氧化物	0.72	0.2	0.144
黑色氧化物	0.33	0.2	0.066

表 11 颗粒计数诊断结果( $\gamma=0.696$ )

Table 11 Particle count diagnostic results ( $\gamma=0.696$ )

证据	<i>A</i>	<i>B</i>	<i>C</i>
>5 $\mu\text{m}$	1	0.1	0.1
>15 $\mu\text{m}$	0.98	0.2	0.196
>25 $\mu\text{m}$	1	0.3	0.3
>50 $\mu\text{m}$	1	0.4	0.4

表 12 光谱和铁谱融合诊断结果( $\gamma=0.912$ )

Table 12 Fusion diagnosis results of spectrum and ferrographic ( $\gamma=0.912$ )

证据	<i>A</i>	<i>B</i>	<i>C</i>
Fe	1	0.5	0.5
Ag	0.051 7	0.02	0.001
Cu	1	0.1	0.1
Cr	0.49	0.05	0.245
疲劳磨粒	1	0.4	0.5
球状磨粒	0.78	0.1	0.312
层状磨粒	0.65	0.1	0.065
红色氧化物	0.72	0.2	0.144
黑色氧化物	0.33	0.2	0.066

表 13 定性融合诊断结果( $\gamma=0.973$ )

Table 13 Qualitative fusion diagnosis results ( $\gamma=0.973$ )

证据	<i>A</i>	<i>B</i>	<i>C</i>
Fe	1	0.5	0.5
Ag	0.051 7	0.02	0.001
Cu	1	0.1	0.1
Cr	0.49	0.05	0.245
疲劳磨粒	1	0.4	0.5
球状磨粒	0.78	0.1	0.312
层状磨粒	0.65	0.1	0.065
红色氧化物	0.72	0.2	0.144
黑色氧化物	0.33	0.2	0.066
>5 $\mu\text{m}$	1	0.1	0.1
>15 $\mu\text{m}$	0.98	0.2	0.196
>25 $\mu\text{m}$	1	0.3	0.3
>50 $\mu\text{m}$	1	0.4	0.4

在基于以上发动机严重磨损的状态下,选取表 7 中的第 30 条能谱分析数据对故障进行定位诊断。表 14 列出了不同方法概率大于 50% 的前

表 14 定位诊断结果  
Table 14 Location diagnosis results

序号	Resnet18	Resnet34	LSTM	CNN	本文模型
1	0Cr18Ni9	ZL114A-T6	1Cr13	1Cr17Ni2	<b>1Cr11Ni2W2MoV</b>
	84%	93%	90%	82%	95%
2	镍石墨	<b>1Cr11Ni2W2MoV</b>	2Cr13	40CrNiMoA	2Cr13
	77%	89%	86%	79%	91%
3	1Cr12Ni2WMoVNb	18Cr2Ni4WA	ZG1Cr18Ni9Ti	1Cr13	1Cr13
	77%	76%	84%	66%	89%
4	1Cr17Ni2	1Cr17Ni2	<b>1Cr11Ni2W2MoV</b>	1Cr18Ni9Ti	40CrNiMoA
	72%	74%	79%	64%	85%
5	<b>1Cr11Ni2W2MoV</b>	1Cr12Ni2WMoVNb	1Cr17Ni2	2Cr13	1Cr17Ni2
	65%	71%	73%	53%	80%

5 种的诊断结果。其中黑体表示与专家诊断结果一致。

对比表 14 中的 5 种算法可以看出, 本文提出的一维卷积残差网络模型不论在材料牌号识别的准确率上还是在识别的有效性上, 都体现出了极大的优势, 有力说明了本文方法在故障定位识别具有更好的诊断效果。

某型发动机润滑系统中的轴承、蜂窝组件和齿轮等部位是摩擦副的主要集中点, 摩擦副的材料主要有不锈钢、铜合金、铝合金和钛合金等, 分别对应 29 种材料牌号, 因此根据材料牌号可快速推断出故障发生位置。

进一步地, 根据材料牌号 1Cr11Ni2W2MoV 可以判断出其磨损部位是轴承区域。

获得定性诊断结果和定位诊断结果后, 利用表 8 数据找出故障发生的原因。对照表 5 元素故障界限值, 判断表 8 中第 30 条数据是否处于异常状态, 具体结果如表 15 所示。

表 15 定因诊断结果  
Table 15 Causal diagnosis results

元素值	是否处于异常状态
疲劳磨粒数量>4 个/mL	是
球状磨粒数量>5 个/mL	是
层状磨粒数量<2 个/mL	否
红色氧化物数量<3 个/mL	否
黑色氧化物数量<2 个/mL	否
22.2 mm <sup>2</sup> /s<黏度<27.5 mm <sup>2</sup> /s	否
酸值<0.15 mg/kg	否
闪点值 t<273 °C	否
水分含量<0.001 mg/kg	否
杂质含量<0.1%	否

判断此时理化分析数据均处于正常状态, 铁谱分析数据中仅疲劳磨粒个数和球状磨粒个数超出警告值, 其余磨粒均处于正常状态, 根据制定的故障原因诊断规则(匹配规则: Rule1)获得的故障原因为滚动轴承剥落失效, 与专家诊断结果一致。

## 6 结 论

本文提出了一种新的航空发动机磨损故障多目标融合诊断方法, 在定性诊断结果的基础上, 进行故障部位识别和故障原因判断。并利用实际航空发动机轴承疲劳磨损数据对该方法进行了验证, 结果充分证明了本文方法的有效性。同时该方法可以广泛应用于航空发动机轴承部件的磨损监测, 表明了该方法较高的工程应用价值, 本文方法可以用于针对航空发动机磨损部位的定性、定位和定因识别, 相较于传统方法, 本文方法优点如下:

1) 相较于单一的油液分析方法诊断, 能够综合利用多种油液监测手段对故障进行全面诊断;

2) 能够同时对故障进行定性、定位、定因诊断, 有效提高了发动机故障诊断效率和全面性, 从而为航空发动机故障诊断和状态维修提供更加可靠的指导。

## 参考文献:

[1] 庞梦洋, 索中英, 郑万泽, 等. 基于 RS-CART 决策树的航空发动机小样本故障诊断[J]. 航空动力学报, 2020, 35(7): 1559-1568.  
PANG Mengyang, SUO Zhongying, ZHENG Wanze, et al. Small sample fault diagnosis of aeroengine based on RS-CART decision tree[J]. Journal of Aerospace Power, 2020, 35(7): 1559-1568. (in Chinese)

- [2] ZHAO Yongping, WANG Jianjun, LI Xiaoya, et al. Extended least squares support vector machine with applications to fault diagnosis of aircraft engine[J]. ISA Transactions, 2020, 97: 189-201.
- [3] DUAN Zhihe, WU Tonghai, GUO Shuaiwei, et al. Development and trend of condition monitoring and fault diagnosis of multi-sensors information fusion for rolling bearings: a review[J]. The International Journal of Advanced Manufacturing Technology, 2018, 96(1): 803-819.
- [4] MURALI S, XIA Xingao, JAGTIANI A V, et al. Capacitive coulter counting: detection of metal wear particles in lubricant using a microfluidic device[J]. Smart Materials and Structures, 2009, 18(3): 037001.
- [5] 王洪伟, 陈果, 陈立波, 等. 一种航空发动机滚动轴承磨损故障监测技术[J]. 航空动力学报, 2014, 29(9): 2256-2263.  
WANG Hongwei, CHEN Guo, CHEN Libo, et al. A fault monitoring technique for wear of aero-engine rolling bearing[J]. Journal of Aerospace Power, 2014, 29(9): 2256-2263. (in Chinese)
- [6] 张赟, 林学森, 王琳, 等. 采用监督局部切空间排列算法的航空发动机磨损故障诊断[J]. 西安交通大学学报, 2020, 54(4): 179-185.  
ZHANG Yun, LIN Xuesen, WANG Lin, et al. Aero-engine wear fault diagnosis with supervised locally tangent space alignment[J]. Journal of Xi'an Jiaotong University, 2020, 54(4): 179-185. (in Chinese)
- [7] 陈果. 基于神经网络和 D-S 证据理论的发动机磨损故障融合诊断[J]. 航空动力学报, 2005, 20(2): 303-308.  
CHEN Guo. Fusion diagnosis of engine wearing fault based on neural networks and D-S evidence theory[J]. Journal of Aerospace Power, 2005, 20(2): 303-308. (in Chinese)
- [8] 姜旭峰, 宗莹, 阮少军. 基于光谱-铁谱分析的航空发动机磨损故障诊断应用研究[J]. 化工时刊, 2020, 34(4): 1-5.  
JIANG Xufeng, ZONG Ying, RUAN Shaojun. Application Research of wear fault diagnosis of aero-engine based on spectrum-ferrography analysis[J]. Chemical Industry Times, 2020, 34(4): 1-5. (in Chinese)
- [9] 孔祥兴, 潘燕, 武通海. 考虑多监测指标不确定性的滑油状态综合评估方法[J]. 航空发动机, 2020, 46(4): 71-77.  
KONG Xiangxing, PAN Yan, WU Tonghai. Comprehensive assessment method of oil status considering uncertainty of multiple monitoring index[J]. Aeroengine, 2020, 46(4): 71-77. (in Chinese)
- [10] 张鹏飞, 李本威, 韦祥, 等. 基于滑油监控信息的发动机磨损状态融合评估[J]. 航空发动机, 2015, 41(4): 93-97.  
ZHANG Pengfei, LI Benwei, WEI Xiang, et al. Evaluation of aeroengine wear condition fusion based on oil monitoring information[J]. Aeroengine, 2015, 41(4): 93-97. (in Chinese)
- [11] 於迪, 贺石中, 何伟楚, 等. 基于油液监测的立磨磨辊故障诊断分析[J]. 润滑油, 2019, 34(3): 45-49, 54.  
YU Di, HE Shizhong, HE Weichu, et al. Fault diagnosis analysis of vertical grinding roller based on oil monitoring[J]. Lubricating Oil, 2019, 34(3): 45-49, 54. (in Chinese)
- [12] 马安祥, 李艳军, 曹愈远, 等. 基于免疫理论的航空发动机磨损故障智能诊断[J]. 航空学报, 2015, 36(6): 1896-1904.  
MA Anxiang, LI Yanjun, CAO Yuyuan, et al. Intelligent diagnosis for aircraft engine wear fault based on immune theory[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(6): 1896-1904. (in Chinese)
- [13] 张海涛. 基于在线油液监测的船舶发动机故障分析[J]. 机械设计与制造工程, 2020, 49(3): 113-116.  
ZHANG Haitao. Fault analysis on the marine engine based on online oil monitoring[J]. Machine Design and Manufacturing Engineering, 2020, 49(3): 113-116. (in Chinese)
- [14] BASIR O, YUAN X. Engine fault diagnosis based on multi-sensor information fusion using Dempster-Shafer evidence theory[J]. Information Fusion, 2007, 8(4): 379-386.
- [15] 陈果, 陈立波, 宋兰琪. 一种磨损故障融合诊断新方法及其应用[J]. 机械科学与技术, 2009, 28(9): 1157-1161.  
CHEN Guo, CHEN Libo, SONG Lanqi. A new approach to fusion diagnosis of wear faults and its application[J]. Mechanical Science and Technology for Aerospace Engineering, 2009, 28(9): 1157-1161. (in Chinese)
- [16] 王古常, 成坚, 鲍传美, 等. 模糊推理和证据理论融合的航空发动机故障诊断[J]. 航空动力学报, 2011, 26(9): 2101-2106.  
WANG Guchang, CHENG Jian, BAO Chuanmei, et al. Diagnosis method of aero-engine fault based on fuzzy inference and evidence theory[J]. Journal of Aerospace Power, 2011, 26(9): 2101-2106. (in Chinese)
- [17] ZHUANG Zilong, LV Huichun, XU Jie, et al. A deep learning method for bearing fault diagnosis through stacked residual dilated convolutions[J]. Applied Sciences, 2019, 9(9): 1823.
- [18] WANG Youming, CHENG Lin. A combination of residual and long-short-term memory networks for bearing fault diagnosis based on time-series model analysis[J]. Measurement Science and Technology, 2021, 32(1): 015904.
- [19] 张西宁, 向宙, 唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用[J]. 西安交通大学学报, 2018, 52(7): 1-8, 59.  
ZHANG Xining, XIANG Zhou, TANG Chunhua. A deep convolutional auto-encoding neural network and its application in bearing fault diagnosis[J]. Journal of Xi'an Jiaotong University, 2018, 52(7): 1-8, 59. (in Chinese)

(编辑: 张 雪)