

DOI: 10.3969/j.issn.0254-0150.2023.04.018

文献引用: 苗慧慧, 曹桂松, 孙智君, 等. 基于深度学习的航空发动机磨损部位识别方法[J]. 润滑与密封, 2023, 48(4): 136-144.

Cite as: MIAO Huihui, CAO Guisong, SUN Zhijun, et al. Aero engine wear location identification method based on deep learning[J]. Lubrication Engineering, 2023, 48(4): 136-144.

## 基于深度学习的航空发动机磨损部位识别方法\*

苗慧慧<sup>1</sup> 曹桂松<sup>1</sup> 孙智君<sup>1</sup> 康玉祥<sup>2</sup> 马佳丽<sup>2</sup> 陈果<sup>3</sup>

(1. 中国航发上海商用航空发动机制造有限责任公司 上海 200241; 2. 南京航空航天大学民航学院 江苏南京 210016; 3. 南京航空航天大学通用航空与飞行学院 江苏溧阳 213300)

摘要: 针对航空发动机润滑系统中摩擦副部件复杂、磨损颗粒能谱监测元素众多, 靠人工经验难于进行磨损部位精确识别的问题, 提出一种基于深度学习的航空发动机润滑系统磨损部位识别方法。该方法应用一维卷积核为计算单元, 搭建一维卷积残差网络模型。以航空发动机润滑油中磨损颗粒能谱分析数据为输入, 采用所搭建的一维卷积残差网络模型实现对能谱数据的特征提取以及航空发动机磨损部位的定位识别; 以某型航空发动机润滑油中磨损颗粒实测能谱数据验证该方法的有效性, 并和 Resnet18、Resnet34、CNN 等网络模型进行对比验证。结果表明, 所提方法对航空发动机磨损部位的识别精度达到 95% 以上。为了验证模型的鲁棒性和泛化能力, 在真实的某型航空发动机能谱数据基础上, 对含氧数据和噪声数据分别进行测试, 进一步说明该模型用于对磨损定位识别的有效性, 具备实际应用的可行性。

关键词: 航空发动机; 能谱分析; 磨损; 一维卷积残差网络; 深度学习

中图分类号: V23

## Aero Engine Wear Location Identification Method Based on Deep Learning

MIAO Huihui<sup>1</sup> CAO Guisong<sup>1</sup> SUN Zhijun<sup>1</sup> KANG Yuxiang<sup>2</sup> MA Jiali<sup>2</sup> CHEN Guo<sup>3</sup>

(1. AECC Commercial Aircraft Engine Manufacturing Co., Ltd., Shanghai 200241, China; 2. Civil Aviation College, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 210016, China; 3. College of General Aviation and Flight, Nanjing University of Aeronautics and Astronautics, Liyang Jiangsu 213300, China)

**Abstract:** Because of the complex friction pair components and many wear particle energy spectrum monitoring elements in aero-engine lubrication system, it is difficult to accurately identify the wear parts by manual experience. A wear part identification method of aero-engine lubrication system based on deep learning was proposed. In which a one-dimensional convolution residual network model was established by using one-dimensional convolution kernel as the calculation unit. Taking the energy spectrum analysis data of the wear particles in the aero-engine oil as the input, using the one-dimensional convolution residual network model, the feature extraction of energy spectrum data and the location and recognition of aeroengine wear parts were realized. The effectiveness of the method was verified by the measured energy spectrum data of the wear particles in an aeroengine oil, and compared with resnet18, resnet34, CNN and other network models. The results

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

收稿日期: 2021-12-13; 修回日期: 2022-02-28

作者简介: 苗慧慧 (1989—), 女, 硕士, 工程师, 主要从事发动机润滑油理化分析、摩擦磨损监测。E-mail: nwumiaoh@163.com。

show that the recognition accuracy of aeroengine wear parts by the proposed method is more than 95%. In order to verify the robustness and generalization ability of the model, the oxygen data and noise data were tested respectively on the basis of the real aero-engine energy spectrum data, which further verified the effectiveness of the model in wear location and identification and the feasibility of practical application.

**Keywords:** aero engine; energy spectrum analysis; wear; one dimensional convolution residual network; deep learning

航空发动机润滑系统中包含大量摩擦副, 因其工作在高转速的环境中, 导致大量的磨损颗粒游离于润滑油中<sup>[1]</sup>。而这些金属磨粒成分及含量能够反映发动机磨损状态及磨损部位等信息, 通过能谱分析检测出金属磨粒中各元素的相对含量, 可为实现航空发动机磨损部位识别提供依据。而如何将能谱分析的数据映射至发动机磨损部位, 是实现航空发动机磨损部位端到端智能识别的前提与关键。

近年来, 随着模式识别和人工智能技术的发展, 模糊数学、D-S 证据理论、神经网络等理论和方法<sup>[2-3]</sup>在机械磨损部位识别中得到了应用。陈果和左洪福<sup>[4]</sup>提出了基于 BP 神经网络和光谱分析方法的机械磨损部位识别方法, 并验证了所提方法的有效性与实用性。王琳等人<sup>[5]</sup>以光谱数据为输入, 采用 BP 神经网络技术实现了某型航空发动机磨损部位的识别。孙涛和李冬<sup>[6]</sup>采用模糊矩阵和神经网络方法, 以光谱分析数据为基础, 以金属元素浓度为判据, 实现了发动机低压压气机、中介机匣等 8 个部位的磨损识别。闫书法等<sup>[2]</sup>提出了一种基于主元分析和聚类分析的机械传动系统磨损定位与状态识别方法。此外, 研究者还基于磨损信息采用深度学习方法对机械磨损状态、材料牌号识别等进行了研究<sup>[7-8]</sup>。以上磨损部位识别方法中主要以光谱数据输入, 根据元素的浓度值判断发动机相应磨损部位的故障模式, 进而实现发动机磨损部位的识别。该类方法主要依据人工经验实现对数据样本的故障划分, 然后通过训练模型实现磨损故障的识别。这类方法主要的不足在于其无法自主实现端到端的定位识别。此外, 这些算法均假设检测数据为理想数据, 未考虑数据采样的离散性等情况, 且算法容易出现过拟合的情况。

深度学习因具有端到端的学习能力, 近年来, 在各类故障诊断领域取得了不错的效果<sup>[9]</sup>。针对现阶段航空发动机磨损部位识别方法存在的不足, 本文作者基于磨损颗粒扫描电镜能谱分析数据, 提出了基于深

度学习的航空发动机润滑系统磨损部位识别方法模型。为避免在训练过程中模型因梯度消失而导致的精度低的问题, 以一维残差网络为特征提取的主干网络, 在此基础上, 采用能够较好地处理序列特征数据的长短期记忆网络 (Long Short Term Memory Network, LSTM) 实现航空发动机磨损部位的定位识别。最后, 采用航空发动机润滑油能谱分析数据对模型进行验证, 以表明所提方法的正确有效性。

## 1 磨损部位识别的深度学习模型

### 1.1 一维卷积残差网络

当前, 诸如卷积神经网络 (Convolutional Neural Networks, CNN)、残差网络 (Deep Residual Networks, Resnet) 等典型的深度学习模型均以二维的数据为输入, 通过模型映射后实现目标的分类与回归。而航空发动机润滑油中磨损颗粒能谱分析结果为一维序列数据, 在将该数据直接应用于上述模型的过程中需采用一维卷积核作为计算单元, 以达到学习序列数据中抽象特征的目的, 进而实现航空发动机磨损部位识别。此外, 相比于 CNN 模型, 残差网络因引入残差块而提高了网络的训练与泛化能力<sup>[10]</sup>。鉴于此, 文中提出了用于航空发动机磨损部位诊断识别的一维卷积残差网络, 如图 1 所示。其中, 输入为航空发动机润滑油磨损中颗粒经过能谱分析后所得的 33 种元素质量分数, 经过一维卷积残差网络计算后, 输出航空发动机磨损部位的 29 种材料牌号。一维卷积残差网络模型主要由 4 层残差网络、全连接层和 LSTM 网络 (LSTM 通过自身的记忆功能能够较好地处理长序列数据) 组合而成。一维卷积残差网络模型参数设置如表 1 所示。其中卷积核大小为  $1 \times 3$ , 每层有 2 个残差块。

### 1.2 残差网络 (Resnet)

为了解决随着深度的增加, 神经网络出现性能退化以及梯度消失的问题。2015 年 HE 等<sup>[11-12]</sup>提出了 Resnet。Resnet 的经典之处在于其引入了残差块的概念。如图 2 所示为残差块结构。

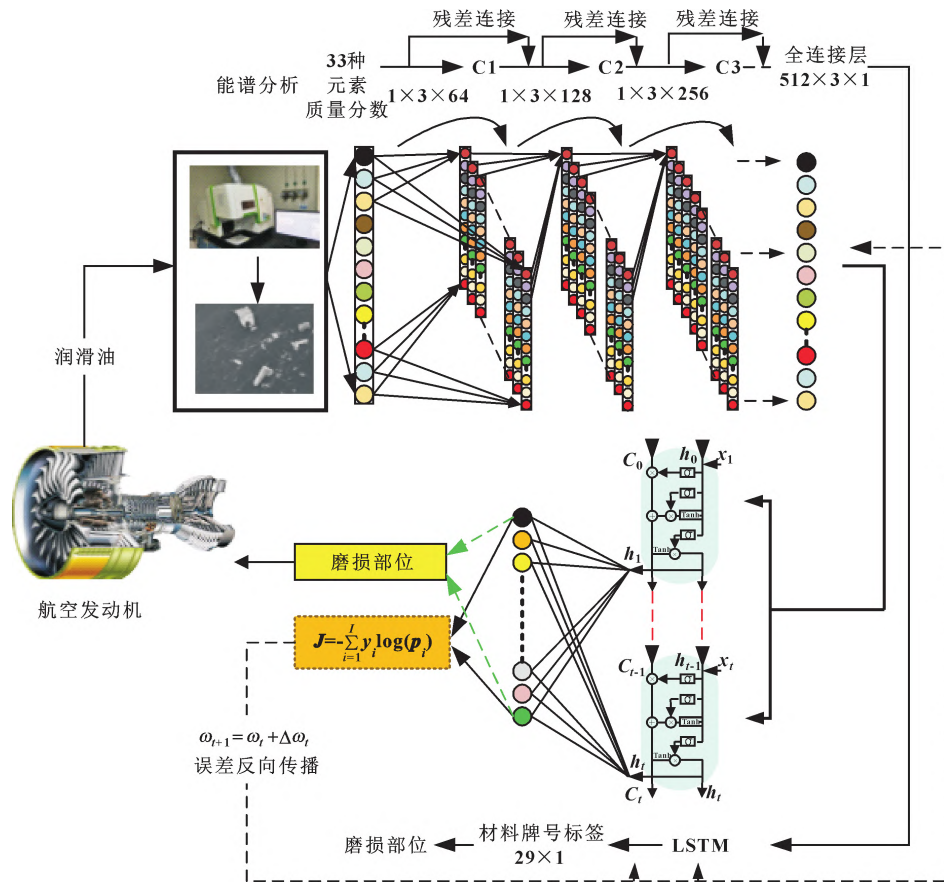


图 1 航空发动磨损部位识别一维卷积残差网络模型

Fig. 1 One dimensional convolution residual network model of the identification of aero engine wear parts

表 1 一维卷积残差网络参数

Table 1 One dimensional convolution residual network parameters

结构	卷积核参数	输出大小
第一层	$(1 \times 3 \times 64) \times 2$	$1 \times 31$
第二层	$(1 \times 3 \times 128) \times 2$	$1 \times 15 \times 128$
第三层	$(1 \times 3 \times 256) \times 2$	$1 \times 7 \times 256$
第四层	$(1 \times 3 \times 512) \times 2$	$1 \times 3 \times 512$
FC	$512 \times 3 \times 1$	$1 \ 536 \times 1$
LSTM	$1 \ 536 \times 3 \times 200$	$200 \times 1$
FC	全连接层	$29 \times 1$

$$g(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (1)$$

图 2 中,  $x_l$  为第  $l$  个残差块的输入;  $f(x_l)$  为经过卷积、批归一化、激活函数的残差映射输出;  $h(x_l)$  是恒等映射输出, 该映射的目的是使得输入  $x_l$  和  $f(x_l)$  具有相同尺寸, 文中  $h = x_l$  表示为残差直连结构。  $g$  为 Relu 激活函数, 如式 (1) 所示。




图 2 残差结构块  
Fig. 2 Residual unit

由图 2 中残差块结构可知, 多个残差块连接的残差网络数学模型为

$$x_{l+1} = x_l + f(x_l, w_l) \quad (2)$$

则第  $L$  层的输出为

$$x_L = x_l + \sum_{i=1}^{L-1} f(x_i, w_i) \quad (3)$$

根据文献 [11], 可得网络每层的梯度为

$$\frac{\delta \mathcal{E}}{\delta x_l} = \frac{\delta \mathcal{E}}{\delta x_L} \frac{\delta x_L}{\delta x_l} = \frac{\delta \mathcal{E}}{\delta x_L} \left\{ 1 + \frac{\delta}{\delta x_L} \left[ \sum_{i=1}^{L-1} f(x_i, w_i) \right] \right\} \quad (4)$$

式中:  $w_l$  表示第  $l$  层的权重;  $w_i$  表示网络第  $i$  层的权重。

式 (4) 表明, 通过多个残差块的串联, Resnet 在误差反向传播的过程中, 能够保证梯度  $\frac{\delta \mathcal{E}}{\delta x_l} > 0$ , 因此网络不会出现梯度消失的问题。

### 1.3 长短期记忆网络 (LSTM)

LSTM 神经网络是一种随时间递归的神经网络<sup>[13]</sup>, 其在 RNN 的基础上加入了 cell, 用来判断信息有用与否从而将其保留, 且 LSTM 引入了“门限” (Gate) 的概念, 如图 3 所示为 LSTM 的主要结构。




图 3 LSTM 隐藏层 Cell 结构  
Fig. 3 The cell structure of LSTM

其前向计算方法可以表示为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t \tanh C_t \quad (10)$$

式中:  $x_t$  为一维卷积残差网络经过全连接层后的第  $t$  个输出;  $f_t$  表示一个被遗忘的阈值, 指示输入阈

值;  $o_t$  表示输出阈值;  $C_{t-1}$  是前一时刻的细胞状态或候选向量;  $C_t$  是当前细胞状态 (当前循环发生);  $h_{t-1}$  是前一时刻的单位输出;  $h_t$  是当前单元格的输出;  $\sigma(\cdot)$  是  $\sigma$  函数;  $\tanh$  是双曲正切激活函数;  $W$  表示权重因子矩阵, 分为为长短期记忆网络中的一个 LSTM 单元中的  $W_f$ 、 $W_i$ 、 $W_c$  和  $W_o$ , 分别对应遗忘门、输入门、细胞状态和输出门; 网络参数  $b$  分别为 LSTM 单元中的  $b_f$ 、 $b_i$ 、 $b_c$  和  $b_o$ 。

适合算法验证的信息仍然存在, 否则信息被遗忘, 二进制提取的原理可以增加算法在重复运算中的训练精度和准确率。

### 1.4 网络训练

采用 Relu 激活函数对 LSTM 网络的输出进行激活操作, 应用如式 (11) 所示的交叉损失函数<sup>[14]</sup>; 优化算法为 Adam 算法; 学习率为 0.000 1。

$$J = - \sum_{i=1}^I y_i \log(p_i) \quad (11)$$

式中:  $I$  为分类类别总数;  $p_i$  为 Softmax 分类函数的输出, 如式 (12) 所示, 表示第  $i$  个类别的概率;  $y_i$  为真实样本标签;  $v_i$  表示模型输出的 29 个数值 (材料牌号) 中第  $i$  个元素。

$$p_i = \frac{e^{v_i}}{\sum_{i=1}^I e^{v_i}} \quad (12)$$

## 2 模型训练与验证

为了验证所提模型用于航空发动机磨损部位识别的有效性, 首先根据某型航空发动机所采用的 29 种材料牌号及每种材料牌号相应的 33 种元素质量分数 (如表 2 所示为其中 8 种材料名称及部分元素质量分数), 采用式 (13) 计算元素质量分数, 基于仿真的方法, 获得 29 000 组样本数据及相应的样本标签 (其中, 每种材料的仿真样本数量为 1 000 个); 然后按照 7 : 3 的比例划分训练集和测试集后, 对模型进行训练和测试; 最后对训练完成的模型采用真实的某型航空发动机润滑油能谱分析数据对所训练的模型进行验证, 并和 Resnet18、Resnet34、CNN、LSTM 等模型进行对比验证。

$$k_m = (u_b - u_l) \times r_1 + u_l \quad (13)$$

式中:  $k_m$  为材料的第  $m$  个元素质量分数;  $u_b$ 、 $u_l$  分别为元素含量的上限和下限;  $r_1$  为  $[0, 1]$  之间的随机数。

单个样本生成过程中, 首先产生 33 个随机数  $r_1$ , 然后采用式 (13) 计算每个元素对应的质量分数。

表 2 部分材料元素质量分数  
Table 2 Element mass fraction of some materials

单位:  $10^{-6}$   
Unit:  $10^{-6}$

材料牌号	Fe		Cr		C		Ni		Mn	
	下限	上限	下限	上限	下限	上限	下限	上限	下限	上限
0Cr17Ni7Al-H1/2	70.85	76.75	16	18	0	0.09	6.5	7.5	0	1
0Cr17Ni4Cu4Nb	69.91	78.85	15	17.5	0	0.07	3	5	0	1
0Cr18Ni9	67.07	75	17	19	0	0.07	8	11	0	2
1Cr11Ni2W2MoV	81.99	85.97	10.5	12	0.1	0.16	1.4	1.8	0	0.6
1Cr13	83.93	87.92	12	14	0.08	0.15	.....	0	0	0.8
1Cr17Ni2	77.67	82.39	16	18	0.11	0.17	1.5	2.5	0	0.8
.....	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....
1Cr18Ni9Ti	0	96.22	0	0	0	0.12	0	0	0	2

2.1 模型训练与测试

为说明一维卷积残差网络模型用于发动机磨损部位识别中的优势, 选用一维 Resnet18、Resnet34、CNN 以及 LSTM 4 种模型进行对比试验验证。4 种模型的网络参数如表 3 所示。试验中采用的 GPU 为 NVIDIA GTX1660 6G, 处理器为 i5-9600K, 内存为 8 G, 运行系统为 Windows10, 编程语言为 Python3.7, 深度学习框架为 Tensorflow1.15。设置批处理样本量为 64, 迭代训练 100 次。

表 3 4 种模型的网络参数

Table 3 Network parameters of the four models

层数	Resnet18	Resnet34	CNN	LSTM
1	(1×3×64) ×2	(1×3×64) ×3	1×3×64	1×33
2	(1×3×128) ×2	(1×3×128) ×4	1×3×128	33×128
3	(1×3×256) ×2	(1×3×256) ×6	1×3×256	128×128
4	(1×3×512) ×2	(1×3×512) ×3	1×3×512	128×128
FC	512×3×1	512×3×1	512×3×1	128×1
输出	29×1	29×1	29×1	29×1

如图 4 所示为一维卷积残差网络在仿真数据集上每轮训练中测试精度值变化曲线。以在测试集上的最大测试精度为前提, 保存模型的训练结果, 为后续模型验证做准备。图 4 中同时给出了一维 Resnet18、Resnet34、CNN 以及 LSTM 算法的测试精度值变化曲线。可看出, 文中一维卷积残差网络和 Resnet34 网络的最终测试精度最高, 为 100%; 其次是 Resnet18 和 LSTM, 精度分别为 99.32%、98.85%; 最后是 CNN 网络模型, 精度为 97.2%。结果显示相比 Resnet18、LSTM、CNN 等模型, 文中算法具有更高的测试精度, 而 Resnet34 虽然和文中模型具有相同的测

试精度, 但是相比于 Resnet34, 文中模型具有更少的模型参数。

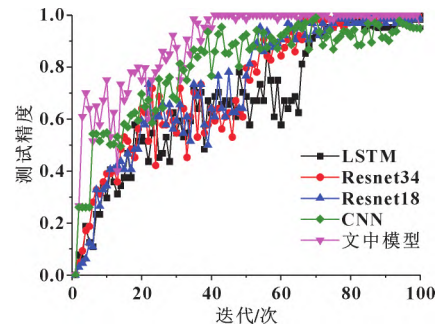


图 4 模型测试结果

Fig. 4 Model test results

为验证算法的有效性, 对每种算法分别进行了 10 次训练, 如图 5 所示为各个算法的 10 次测试结果。图中结果显示, 文中的一维卷积残差网络模型相较其他几种算法的测试精度更高, 且 10 次的计算结果偏差更小。

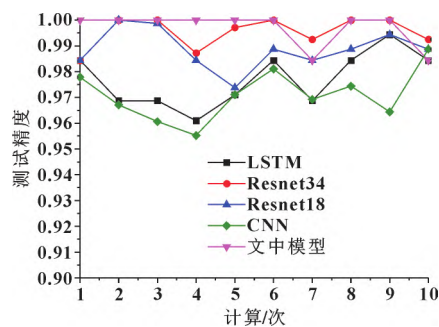


图 5 10 次训练测试结果

Fig. 5 Results of 10 training tests

## 2.2 航空发动机磨损颗粒能谱数据验证

为验证所提算法用于实际航空发动机磨损部位识别的有效性及其精度,采用实际的20例能谱检测数据进行验证,部分检测数据如表4所示。表中列出了经

过扫描电镜能谱分析后所得材料元素的质量分数及由专家诊断后所得的材料牌号及磨损部位。表中未列出的元素质量分数为0。

表4 能谱检测结果及诊断结果

Table 4 Energy spectrum test results and diagnosis results

序号	元素质量分数 $w/10^{-6}$								
	1	2	3	4	5	6	7	8	9
Fe	84.4	18.0	100	0	22.96	21.62	69.03	68.12	86.25
Cr	11.6	28.7	0	0	22.97	17.43	19.35	18.74	11.67
Ni	2.3	53.3	0	0	42.82	51.45	9.34	9.9	0
O	0	0	0	0	0	0	0	0	0
Al	0	0	0	10.55	2.3	0.87	0	0	0
Mn	0	0	0	0	0	0	2.29	2.3	0
W	1.7	0	0	0	0.72	0	0	0	2.08
Ti	0	0	0	84.86	1.53	0.87	0	0.93	0
V	0	0	0	4.59	0	0	0	0	0
Sb	0	0	0	0	0	0	0	0	0
Ag	0	0	0	0	0	0	0	0	0
Mo	0	0	0	0	1.07	2.61	0	0	0
Pb	0	0	0	0	0	0	0	0	0
材料牌号	1Cr11Ni2W2MoV	GH3536	合金结构钢	TC4	GH3536	GH3536	奥氏体不锈钢	奥氏体不锈钢	1Cr11Ni2W2MoV
磨损部位	轴承	蜂窝组件	齿轮	轴承壳体	蜂窝组件	蜂窝组件	齿轮	齿轮	轴承

将表4中的数据输入至已经训练完成的深度学习模型中对模型进行进一步的验证。表5所示为各个模型针对表4中的数据进行识别的结果。表中罗列了输出最大概率的5种材料类别(Top-5<sup>[15]</sup>)中前3种的材料牌号。其中黑体表示该类别与表4中专家给定的类别相同。

针对真实的航空发动机磨损颗粒能谱分析数据,通过统计分析及对多种模型识别结果的对比,可以看出文中的一维卷积残差网络模型能够准确识别出磨损部位的材料牌号,进而实现磨损定位。针对所有样例数据的识别结果表明,LSTM、Resnet34、Resnet18、CNN、文中模型输出的Top-5的识别准确率(Top-5中是否包含正确类别的概率)分别为85.0%、90.0%、80.0%、70.0%、95.0%。结果显示,文中模型能够识别出材料牌号的准确率最高,其次是

Resnet34和LSTM,CNN的识别效果最低。统计结果也进一步说明文中模型用于对磨损定位识别的有效性,可以将该模型用于针对航空发动机的磨损部位识别。

## 2.3 含氧元素的航空发动机磨损数据

实际的航空发动机磨损颗粒经过扫描电镜能谱分析所得的部分结果中氧元素占比较高,严重干扰了航空发动机磨损部位的精确识别。鉴于此,经过专家建议,针对氧元素质量分数大于10%的检测结果,算法直接输出为“氧化物”的结果,对于氧元素质量分数小于10%的数据,采用将氧元素质量分数置零后,其余各元素质量分数再分配的方法,重新计算各元素的质量分数,然后将所得的数据用于磨损部位识别诊断中。表6所示为部分含氧数据处理的结果及相应的文中模型的识别结果。

表 5 模型识别结果  
Table 5 Model recognition results

序号	材料牌号				
	LSTM	Resnet34	Rsnnet18	CNN	文中模型
1	1Cr13	ZL114A-T6	0Cr18Ni9	1Cr11Ni2W2MoV	1Cr17Ni2
	2Cr13	1Cr11Ni2W2MoV	镍石墨	40CrNiMoA	ZG1Cr18Ni9Ti
	1Cr11Ni2W2MoV	18Cr2Ni4WA	1Cr11Ni2W2MoV	1Cr17Ni2	1Cr11Ni2W2MoV
2	0Cr18Ni9	5A06	40CrNiMoV	IN718	ZG1Cr18Ni9Ti
	ZG1Cr18Ni9Ti	GH3536	GH3536	0Cr18Ni9	锻件 9310
	GH3536	0Cr18Ni9	1Cr17Ni2	ZG1Cr18Ni9Ti	GH3536
3	1Cr18Ni9Ti	5A06	1Cr17Ni2	40CrNiMoV	15CrMnMoVA
	镍石墨	2Cr13	40CrNiMoV	1Cr18Ni9Ti	5A06
	65Mn	锻件 9310	GH4169 ,GH3536	40CrNiMoA	40CrNiMoV
4	1Cr17Ni2	镍石墨	1Cr17Ni2	1Cr18Ni9Ti	18Cr2Ni4WA
	0Cr17Ni7Al-H1/2	ZL114A-T6	40CrNiMoV	M50NiL	ZTC4/TC4
	ZTC4/TC4	ZTC4/TC4	GH3536	8Cr4Mo4V	GH3536
5	IN718	ZL114A-T6	铸铁 9310	IN718	ZG1Cr18Ni9Ti
	ZG1Cr18Ni9Ti	GH3536	15CrMnMoVA	0Cr17Ni7Al-H1/2	ZG0Cr16Ni4NbCu3
	GH3536	0Cr18Ni9	1Cr11Ni2W2MoV	0Cr18Ni9	GH3536
6	IN718	5A06	18Cr2Ni4WA	IN718	ZG1Cr18Ni9Ti ,
	ZG1Cr18Ni9Ti	GH3536	GH3536	0Cr18Ni9	ZG0Cr16Ni4NbCu3 ,
	GH3536	2Cr13	IN718	GH3536	GH3536
7	0Cr18Ni9	ZL114A-T6	铸铁 9310	0Cr18Ni9	40CrNiMoA
	0Cr17Ni7Al-H1/2	18Cr2Ni4WA	1Cr18Ni9Ti	ZG1Cr18Ni9Ti	8Cr4Mo4V
	18Cr2Ni4WA	5A06	GH3536	IN718	35Cr2Ni4MoA
8	ZG1Cr18Ni9Ti	5A06	铸铁 9310	ZG1Cr18Ni9Ti	0Cr17Ni4Cu4Nb ,
	IN718	GH3536	1Cr18Ni9Ti	IN718	ZG0Cr16Ni4NbCu3
	0Cr18Ni9	18Cr2Ni4WA	GH3536	0Cr18Ni9	18Cr2Ni4WA
9	1Cr17Ni2	ZL114A-T6	18Cr2Ni4WA	1Cr13	1Cr17Ni2
	1Cr13	1Cr11Ni2W2MoV	1Cr11Ni2W2Mo	2Cr13	ZG1Cr18Ni9Ti
	1Cr11Ni2W2MoV	18Cr2Ni4WA	60Si2MnA	1Cr11Ni2W2MoV	1Cr11Ni2W2MoV

表 6 去掉氧元素的数据处理结果及模型识别结果

单位: %

Table 6 Data processing results and model recognition results with oxygen removed

Unit: %

元素	1		2		3		4	
	处理前质量分数	处理后质量分数	处理前质量分数	处理后质量分数	处理前质量分数	处理后质量分数	处理前质量分数	处理后质量分数
Fe	23.66	23.66	16.54	17.46	13.88	14.38	89.53	99.00
Cr	48.08	48.08	21.77	22.98	18.27	19.83	0	0
Ni	0	0	45.68	48.21	41.33	42.83	0	0
O	28.26	28.26	5.26	0	3.32	0	9.57	0
Al	0	0	0	0	0	0	0.45	0.5
Mn	0	0	0	0	0	0	0	0
W	0	0	1.56	1.65	0	0	0	0
Ti	0	0	0	0	0	0	0	0
Si	0	0	0	0	1.40	1.45	0.45	0.5
C	0	0	0	0	14.55	15.08	0	0
Mo	0	0	9.2	9.71	7.06	7.32	0	0
材料牌号	氧化物		ZG1Cr18Ni9Ti		GH3536		锻件 9310	
文中模型	氧化物		ZG1Cr18Ni9Ti		GH3536		锻件 9310	

表 6 中结果显示, 在将氧元素去除后, 模型能够有效识别出材料的牌号, 说明文中算法具有较好的鲁棒性, 也进一步验证了文中算法能够用于航空发动机磨损部位的识别。

2.4 含噪声的航空发动机磨损数据验证

进一步, 为验证所提模型的泛化能力, 在式 (13) 的基础上增加高斯噪声  $r_2$ , 生成带高斯噪声的样本数据。如式 (14) 所示。

$$k = (u_b - u_1) \times r_1 + u_1 + r_2 \quad (14)$$

采用仿真的方法, 将  $r_2$  分别设置为  $[-2, 2]$  和  $[-5, 5]$  范围内的高斯随机数, 获得两批 29 000 组样本数据, 在对多种方法分别进行训练后, 同样采用上述真实的航空发动机磨损颗粒能谱分析数据对所训练完成的模型进行验证。两批样本数据中各个模型测试的精度曲线如图 6、7 所示。针对  $r_2 \in [-2, 2]$  的情况, 文中所提一维卷积残差网络和 Resnet34 网络的最终测试精度最高, 达到了 100%, 其次是 Resnet18 和 LSTM, 精度分别为 99.09%、97.37%, 最后是 CNN 网络模型, 精度为 96.03%。针对  $r_2 \in [-5, 5]$  的情况, 文中所提一维卷积残差网络和 Resnet34 网络的最终测试精度同样最高, 达到了 100%, 其次是 Resnet18 和 LSTM, 精度分别为 98.56%、97.79%, 最后是 CNN 网络模型, 精度为 96.25%。对比两批噪声样本数据的训练结果可以看出, 文中所提的一维卷积残差网络和 Resnet34 具有更高的精度和更好的收敛性。

进一步, 应用表 3 中的数据对所训练的模型进行验证。取 Top-5 结果中是否包含实际的材料牌号为

依据验证算法的准确性。统计结果如表 7 所示。

表 7 中结果显示, 对于噪声为  $[-5, 5]$  范围内的模型测试结果要普遍低于噪声范围为  $[-2, 2]$  范围内的测试结果。5 种方法中 Resnet34、Resnet18 和文中模型依然具有较高的磨损部位识别精度, 其次是 LSTM, 最后是 CNN 模型。




图 6 噪声为  $[-2, 2]$  的训练结果

Fig. 6 The training result with noise of  $[-2, 2]$




图 7 噪声为  $[-5, 5]$  的训练结果

Fig. 7 The training result with noise of  $[-5, 5]$

表 7 增加噪声后模型识别结果

Table 7 Model recognition results after adding noise

序号	LSTM		Resnet34		Resnet18		CNN		文中模型	
	$[-2, 2]$	$[-5, 5]$	$[-2, 2]$	$[-5, 5]$	$[-2, 2]$	$[-5, 5]$	$[-2, 2]$	$[-5, 5]$	$[-2, 2]$	$[-5, 5]$
1	是	是	是	否	是	是	是	否	是	否
2	是	是	是	否	否	是	是	是	是	是
3	是	是	是	是	是	是	是	是	是	是
4	否	否	是	是	是	是	是	否	是	否
5	否	否	是	是	是	是	否	是	是	是
6	是	否	是	是	是	是	否	是	是	是
7	是	是	是	是	是	否	是	是	是	是
8	是	是	否	是	是	否	否	否	是	是
9	是	是	是	是	是	是	否	否	否	是



## 3 结论

(1) 提出一种基于一维卷积残差网络的航空发动机磨损部位识别模型, 该模型不需要人工特征提取, 直接将原始油液数据作为模型的输入, 在模型的输出端即为磨损部位的识别结果, 节省了使用者的操作难度; 引入四层残差网络, 通过直接映射的方式, 避免了模型拟合和梯度消失问题; 采用的 LSTM 网络能够较好地处理序列特征数据, 更好地实现了航空发动机磨损部位的定位识别。

(2) 采用某型发动机的滑油监测检测数据, 通过多种深度学习模型比较, 验证了所提算法具有很高的磨损部位识别精度, 证明算法具有较高的工程应用价值, 可以用于针对航空发动机磨损部位的识别。

## 参考文献

- [1] 侯志强, 薛立彤, 柳文林. 基于润滑油光谱数据的发动机磨损部位识别[J]. 润滑与密封, 2010, 35(1): 89-92.  
HOU Z Q, XUE L T, LIU W L. The fault parts identifying of aero-engine based on the lubricating oil spectral data[J]. Lubrication Engineering, 2010, 35(1): 89-92.
- [2] 闫书法, 马彪, 郑长松, 等. 非线性状态监测数据下的磨损定位与状态识别[J]. 吉林大学学报(工学版), 2019, 49(2): 359-365.  
YAN S F, MA B, ZHENG C S, et al. Wear localization and identification under nonlinear condition monitoring data[J]. Journal of Jilin University (Engineering and Technology Edition), 2019, 49(2): 359-365.
- [3] SHAHID M A, KHAN T M, LONTIN K, et al. Multiple point contact wear prediction and source identification scheme using a single channel blended airborne acoustic signature[J]. IFAC-Papers On Line, 2020, 53(3): 283-288.
- [4] 陈果, 左洪福. 基于神经网络的机械磨损故障光谱定位诊断法[J]. 摩擦学学报, 2004, 24(3): 263-267.  
CHEN G, ZUO H F. Diagnosis of wear-induced breakdown of machine by spectrometric analysis based on artificial neural network[J]. Tribology, 2004, 24(3): 263-267.
- [5] 王琳, 张代国, 叶晨, 等. 基于 BP 神经网络的航空发动机磨损部位识别[J]. 系统仿真技术, 2018, 14(4): 275-279.  
WANG L, ZHANG D G, YE C, et al. Identification of aero-engine wearing parts based on BP neural network[J]. System Simulation Technology, 2018, 14(4): 275-279.
- [6] 孙涛, 李冬. 基于模糊矩阵和神经网络的航空发动机磨损部位故障识别[J]. 燃气涡轮试验与研究, 2019, 32(6): 50-53.
- [7] SUN T, LI D. The wearing part fault identification of aero-engine based on fuzzy matrix and neural network[J]. Gas Turbine Experiment and Research, 2019, 32(6): 50-53.
- [8] FAN S L, ZHANG T H, GUO X X, et al. FFWR-Net: a feature fusion wear particle recognition network for wear particle classification[J]. Journal of Mechanical Science and Technology, 2021, 35(4): 1699-1710.
- [9] WANG G D, JING Z S, QIN G W, et al. Wear particles recognition based on improved LBP[J]. Applied Mechanics and Materials, 2013, 427/428/429: 1874-1878.
- [10] 雷高伟, 张清华, 苏乃权, 等. 基于深度学习与电子听诊器的轴承故障诊断[J]. 机床与液压, 2022, 50(9): 210-214.  
LEI G W, ZHANG Q H, SU N Q, et al. Rolling bearing fault diagnosis based on electronic stethoscope and deep learning[J]. Machine Tool & Hydraulics, 2022, 50(9): 210-214.
- [11] 周兴康, 余建波. 基于深度一维残差卷积自编码网络的齿轮箱故障诊断[J]. 机械工程学报, 2020, 56(7): 96-108.  
ZHOU X K, YU J B. Gearbox fault diagnosis based on one-dimension residual convolutional auto-encoder[J]. Journal of Mechanical Engineering, 2020, 56(7): 96-108.
- [12] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [13] HE K M, ZHANG X Y, REN S Q, et al. Identity mappings in deep residual networks[M]. Berlin: Springer international Publishing, 2016.
- [14] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [15] 康玉祥, 陈果, 尉询楷, 等. 深度残差对冲网络及其在滚动轴承故障诊断中的应用[J]. 航空学报, 2022, 43(8): 63-74.  
KANG Y X, CHEN G, WEI X K, et al. Deep residual hedging network and its application in fault diagnosis of rolling bearings[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(8): 63-74.
- [16] WONGPANICH A, PHAM H, DEMMEL J, et al. Training EfficientNets at supercomputer scale: 83% ImageNet top-1 accuracy in one hour[C]//Proceedings of IEEE International Parallel and Distributed Processing Symposium Workshops. Portland, OR: IEEE, 2021: 947-950.