

# 基于 ES-RF 模型的材料裂纹故障分析研究

刘天畅

(中国商飞上海飞机试飞工程有限公司, 上海 201323)

**摘要:** 针对飞机材料裂纹故障检测中目击检查困难、手工检查耗时长且准确率低的问题, 对 A、D 两种类型裂纹故障的智能识别方法进行了研究; 采用专家系统与随机森林相结合的 ES-RF 模型, 对材料裂纹故障进行分析识别; 通过专家系统验证了材料裂纹故障发生与多个检测参数的相关性, 运用决策树算法实现了对材料裂纹故障的自动分析; 实验结果显示 ES-RF 模型对材料裂纹故障评估的训练准确率达到 98.98%, 测试准确率达到 97.93%; 该方法为飞机维修检查中材料裂纹故障的高效准确识别提供了技术支撑。

**关键词:** 试飞测试; 特征检测; 模式识别; 决策树

## Analysis of Material Crack Fault Based on ES-RF Model

LIU Tianchang

(Shanghai Aircraft Flight Test Co., Ltd., Shanghai 201323, China)

**Abstract:** To address the problems of difficult visual inspection, time-consuming manual inspection, and low accuracy in aircraft material crack fault detection, research on an intelligent recognition method for crack faults of types A and D is carried out, which adopts the ES-RF model combining an expert system and a random forest to analyze and identify material crack faults. The correlations between material crack faults and multiple detection parameters are verified through the expert system, and material crack faults are automatically analyzed by applying the decision tree algorithm. Experimental results demonstrate that the ES-RF model achieves a training accuracy of 98.98% and a testing accuracy of 97.93% for the assessment of material crack faults. This method provides technical support for efficient and accurate identification of material crack faults in aircraft maintenance inspections.

**Keywords:** flight test; feature detection; pattern recognition; decision tree

## 0 引言

随着我国航空体系的不断完善, 各大航空公司引进的客机数量大幅增长带来运营压力的不断增加, 如何在有限的人力和时间内更加高效的实现对飞机本体故障识别与分析愈发重要<sup>[1]</sup>, 特别是在结构组件和蒙皮裂纹检测方面。

近年来, 集成了先进传感器技术、人工智能方法和决策算法的专家系统在无损检测和结构健康监测领域日益突出<sup>[2-5]</sup>。新型多频涡流技术通过同步激励不同频率信号, 结合图像质量评估算法可同时探测表面与次表面裂纹, 在铝制飞机蒙皮检测中实现 0.3 mm 级裂纹识别精度, 平面几何远场涡流技术更是突破传统穿透深度限制, 可在 3 mm 厚铝板叠层中检测第二层裂纹<sup>[6-7]</sup>。相控阵超声系统和柔性阵列涡流传感器可贴合复杂曲面实现全向扫描, 通过全聚焦算法与深度学习结合, 使钛合

金叶片微裂纹检出率从 78% 提升至 93%<sup>[8-9]</sup>。激光超声技术突破接触式局限, 在复合材料冲击损伤检测中空间分辨率提升至 0.5 mm, 适用于高温部件在线监测<sup>[10]</sup>。射线检测技术通过动态范围扩展使图像灰度级从 12 bit 提升至 16 bit, 结合计算机层析成像与相位衬度成像可分辨铝合金中 10 μm 级疲劳裂纹<sup>[11-12]</sup>。针对复杂结构检测难和微小裂纹早期识别难的技术瓶颈, 研究者通过神经网络优化信号处理使紧固孔边裂纹信噪比提升 8 dB<sup>[13-15]</sup>, 太赫兹成像与锁相热像技术融合可穿透 8 层碳纤维预浸料检测分层缺陷, 非线性超声谐波检测技术的灵敏度比常规超声高 2 个数量级, 微磁检测技术通过巴克豪森噪声分析在镍基合金叶片上实现 50 μm 级裂纹识别, 整体技术发展朝着更高精度、更强穿透能力和更智能化的方向发展<sup>[16-18]</sup>。

针对复杂结构和微小裂纹问题, 目前国外已有航空公司如汉莎航空、美联航等在航线运行及 A、B 级

收稿日期:2025-05-18; 修回日期:2025-07-17。

作者简介:刘天畅(1992-),男,硕士,工程师。

引用格式:刘天畅. 基于 ES-RF 模型的材料裂纹故障分析研究[J]. 计算机测量与控制, 2025, 33(11):1-10.

检修过程中收集大量数据，为裂纹检测提供数据积累和指导。这类数据记录了飞机运行过程中的气象数据，起降数据，载客数据，定位数据，加速度数据，大型系统数据，检修情况数据等等，数据量大，对照因素简单，表征信息全面，采用专家系统和决策树方法对这类维修数据进行有效的分析，可有效识别故障的主要成因及相关诱发因素，并据此制定维修检查方案，优化构型设计<sup>[19]</sup>。

专家系统在飞机裂纹检测中结合了先进传感技术与智能算法，自动解释数据并做出明智的决策。集成过程通常由多个模块协同工作，以实现高检测精度和可靠性。现代专家系统利用 SHM 为飞机结构状态提供互补的洞察。基于残差分析的传感器验证方案被采用以确定传感器可靠性和早期检测故障。压电传感器、光纤传感器和其他传感器类型的集成确保了表面和内部缺陷得到有效监控。SHM 系统旨在利用内置传感器网络对结构完整性进行连续、实时的监测。这些系统集成了各种传感器类型，包括光纤和压电传感器，用于测量应变、温度和其他关键参数。与计划中的无算检测相比，SHM 提供持续的工况监测，从而实现基于状态的维护，可以显著减少维护工作量和成本<sup>[20-21]</sup>，有助于异常检测、模式识别和损伤量化，从而提高检测过程的可靠性和准确性<sup>[22]</sup>。

随机森林在故障诊断领域的融合应用呈现多元化发展趋势，主要体现在深度学习融合和专家系统融合两个方向。在深度学习融合方面，1D-CNN 与随机森林的结合通过卷积层提取振动信号频域特征并进行分类，实现了 98.2% 的轴承故障识别准确率<sup>[23]</sup>；基于多粒度级联森林（rgfc-Forest）的创新架构通过随机多粒度特征融合机制，在小样本条件下（仅 50 个训练样本）达到 92.3% 的裂纹识别准确率，有效解决了小样本适应性问题<sup>[24-27]</sup>。在专家系统融合方面，研究热点集中在分层诊断框架、知识驱动特征工程和动态规则协同更新等领域：分层混合架构通过 OCSVM 状态检测结合随机森林分类，将故障诊断误报率降至 2.1% 并支持增量学习<sup>[28]</sup>；知识驱动的特征工程方法将专家系统故障树逻辑转化为特征选择准则，在滚动轴承诊断中将特征维度从 120 维降至 28 维的同时保持 97.8% 准确率<sup>[29]</sup>；双阶段协同框架通过离线随机森林数据挖掘与在线专家系统推理的结合，在飞机作动器故障诊断中实现召回率提升 18%<sup>[30]</sup>。

针对在检修过程中数据量大，有效信息率低，检查内容跨度长，机型种类多样等因素导致使用人工处理方式效率低，有效样本量率低使得计算机处理准确性差的问题，本文以国外某航空公司数据集为样本，提出 ES-RF 模型，模型运用统计学和决策树模型，分析数据集中材料裂纹故障与变量间的相互关系，研究在不同变量

不同参数的作用下，材料裂纹故障的发生情况，并建立在多类别变量参数分析基础上的材料裂纹故障评估网络，根据已有数据对后续级别检修中材料裂纹故障的发生进行评估。

## 1 模型与方法

### 1.1 ES-RF 模型

ES-RF（专家分析一决策树判断）模型是对材料裂纹故障关联数据分析评估的模型，架构如图 1。ES-RF 模型架构遵循标准的数据处理和机器学习流程，主要包括以下几个阶段：数据输入作为整个流程的起点，负责将原始数据导入到系统中；数据预处理对原始数据进行清洗、转换和准备，以便后续分析和建模；数据导入将具体的多类别数据进行导入；数据查看对导入的数据进行初步查看，了解数据结构、内容和潜在问题；数据分组统计按特定维度对数据进行分组统计分析，发现数据规律；归一化对数据进行缩放处理，使其处于相似的数据值范围，避免某些特征对模型产生过大影响；数据分析在预处理后的数据上进行探索性数据分析（EDA），发现数据特征和关系；统计图生成各种统计图表直观展示数据分布和关系；相关系数矩阵热力图计算并可视化特征之间的相关性，帮助理解特征之间的关联程度；特征提取从原始数据中构建或选择出对模型有用的特征，构建变量特征和异常特征提取；ES 特征工程利用数据的标签信息，通过监督信息指导特征的创建、选择或转换从而最大化模型性能；模型训练与分析使用经过特征提取后的数据训练机器学习模型，并对训练过程进行分析；模型评估使用独立的测试数据集评估训练好的模型的性能；RF 分析与评估在模型训练阶段使用了随机森林算法并深入分析和性能评估。ES-RF 模型架构结合了显式监督特征工程和随机森林模型的优点，利用监督信息指导特征工程，可以生成与预测目标更相关的特征，提高特征的有效性；通过专家系统设计的监督特征可以帮助模型更好地捕捉数据中的模式，从而提升预测精度；采用显式监督的方法有助于发现数据中不容易通过无监督方法找到的与标签相关的特征，发现隐含关联；采用随机森林方法通过组合多个决策树的结果，可

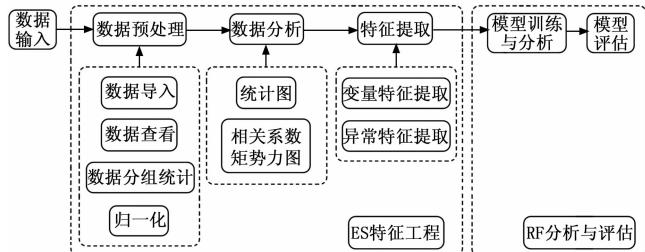


图 1 ES-RF 模型架构

以有效地降低过拟合风险, 提高模型的稳定性和泛化能力, 并给出每个特征对模型预测的贡献程度, 有助于理解数据和模型。

ES-RF 模型架构通过在特征工程阶段融入显式监督信息, 使得提取的特征更具区分度和预测能力, 再结合随机森林强大的集成学习能力, 能够构建出高性能、鲁棒性好的预测模型。这种架构特别适用于需要从复杂数据中挖掘有效特征并进行准确预测的场景。

## 1.2 ES 数据映射与统计分析

在构建各种统计模型和依赖于距离计算的机器学习模型时, 不同特征之间量纲和数值范围的不一致性会带来显著的问题。在线性回归模型中, 虽然最终的模型结果不受特征量纲的影响, 但不同量纲的自变量会导致其对应的回归系数大小差异巨大, 使得回归系数无法直接进行有意义的比较和解读, 无法仅凭回归系数的绝对值来判断特征贡献度。同时在许多依赖于样本点之间距离计算的机器学习算法中, 特征的数值范围差异会直接影响距离计算结果。根据距离公式(如欧式距离), 具有较大数值范围的特征会天然地在距离计算中占据主导地位, 使得点之间的距离主要由这些“大数”特征决定, 而那些数值范围较小但包含丰富信息的特征对距离的贡献变得微乎其微, 导致模型对数据的相似性度量产生偏差, 从而影响模型的性能和结果的合理性, 甚至使模型难以收敛或收敛到局部最优。

通过归一化可将原始数据从各自不同的量值范围映射到指定区间, 同时将有量纲的表达式转化为无量纲的表达式, 使得不同传感器采集的不同单位或量级的不同物理量指标能够进行比较和加权。研究采用 min-max 归一化和 Z-score 标准化方法对原始数据进行处理: Min-max 归一化, 即最小—最大归一化方法, 该方法将原始数据重新缩放要素范围至  $[0, 1]$  或指定区间, 如式(1)~(2)所示:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

$$x' = m + \frac{(x - \min(x))(m - n)}{\max(x) - \min(x)} \quad (2)$$

式(1)为将原始数据映射到  $[0, 1]$  的归一化方法, 式(2)为将数据映射到指定区间  $[m, n]$  的归一化方法。Z-score 标准化使数据中每个特征的值具有零均值和单位方差。此方法广泛用于许多机器学习算法的标准化, 如支持向量机、逻辑回归和人工神经网络等, 如式(3)所示:

$$x' = \frac{x - \text{avg}(x)}{\sigma} \quad (3)$$

其中:  $\text{avg}(x)$  为特征向量的均值,  $\sigma$  是其标准偏差。

相关系数是用以反映变量之间相关性密切程度的统

计指标, 通过对变量的相关系数进行分析可以在后续的分析中剔除独立性低的样本变量。在本研究中, NS、BL、……、Sbz\_1、Sbz\_2 是经过数据标准化与归一化后的样本, 每个样本均有多个观测, 分别计算两两样本间的相关系数, 如式(4):

$$r_{ij} = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2(y - \bar{y})^2}} \quad (4)$$

将各个样本间的相关系数构成矩阵形式, 在每个样本有  $k$  个观测时, 相关系数矩阵如式(5):

$$\begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1k} \\ r_{21} & r_{22} & \cdots & r_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ r_{k1} & r_{k2} & \cdots & r_{kk} \end{bmatrix} \quad (5)$$

由于各个变量与自己的相关系数为 1, 式(5)可改写为式(6):

$$\begin{bmatrix} 1 & r_{12} & \cdots & r_{1k} \\ r_{21} & 1 & \cdots & r_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ r_{k1} & r_{k2} & \cdots & 1 \end{bmatrix} \quad (6)$$

## 1.3 随机森林模型

数据进行 ES 特征工程后, 得到新的可用于机器学的数据集, 将数据集输入到 RF 分析与评估模块进行模型训练, 通过数据映射和相关系数分析后, 可以获得独立性较高的裂纹故障关联参数, 使用随机森林通过构建并结合多棵决策树来提升预测的准确性和稳定性, 并减少单一决策树容易出现的过拟合问题。在随机森林中构建决策树的关键是选择最优划分属性, 在决策树叶节点不断延展时, 希望其样本的纯度逐步提升, 使用信息熵来度量, 如式(7):

$$Ent(D) = - \sum_{k=1}^{|y|} p_k \log_2 p_k \quad (7)$$

式中,  $p_k$  为当前样本集合  $D$  中第  $k$  类样本所占比例,  $Ent(D)$  值越小, 纯度越高。通过信息增益来对纯度提升量进行分析, 信息增益如式(8),  $D^v$  表示第  $v$  个分支节点包含了  $D$  中所有在属性  $a$  上取值为  $a^v$  的样本。

$$Gain(D, a) = Ent(D) - \sum_{v=1}^v \frac{|D^v|}{|D|} Ent(D^v) \quad (8)$$

其信息增益率使用  $Gain\_ratio(D, a)$  表示, 如式(9)使用基尼指数划分数据集属性, 属性  $a$  的基尼指数如式(10):

$$Gain_{ratio(D,a)} = \frac{- \sum_{k=1}^{|y|} p_k \log_2 p_k - \sum_{v=1}^v \frac{|D^v|}{|D|} Ent(D^v)}{- \sum_{v=1}^v \frac{|D^v|}{|D|} \log_2 \frac{|D^v|}{|D|}} \quad (9)$$

$$Gini\_index(D, a) = \sum_{v=1}^v \frac{|D^v|}{|D|} \left(1 - \sum_{k=1}^{|y|} p_k^2\right) \quad (10)$$

模型构建中,结合材料裂纹关联参数和计算性能对进行设置,其设置方式与依据见表 1。

表 1 RF 模型参数设置

参数名	设置方式与依据
决策树数量	根据模型在验证集上的准确率表现进行调优确定最优数量,初步探索范围设定为 0 到 50 之间。
决策树分类标准	考虑到数据集由量值特征构成,且各特征携带信息量相对均衡,为有效衡量划分后节点的不纯度并提升模型处理数据不确定性的能力,分裂标准选择为基尼指数。
决策树分类深度	基于特征数量和计算资源考量,决策树的最大深度不严格定义,设定为直到节点中的所有样本属于同一类别时停止分裂,有助于单个决策树充分捕捉数据特征间的复杂关系。
内部节点分割的最小样本数	考虑到数据集的样本数量相对有限,为允许模型在内部节点进行更细致的划分以提高对局部模式的识别能力,同时避免过度拟合,将内部节点进行分裂所需的最小样本数设定为 2。
叶节点的最小样本数	为使决策树能够学习到更精细的决策边界并将训练样本尽可能地细分,将叶节点中所需的最小样本数设定为 1,有助于模型对训练数据进行更充分的拟合。
样本权重系数	由于经过预处理后的数据集,各样本之间展现出相对独立的趋势,且特征已进行标准化与归一化处理,样本间的差异主要体现在特征值上,因此在训练过程中无需考虑样本权重,权重系数设为默认值。
最大叶子节点数	根据模型在验证集上的准确率表现进行调优确定最大叶子节点数,初步探索范围设定为 0 到 50 之间。该参数通过限制叶节点数量来控制树的复杂度,有助于防止过拟合。
纯净度	设置为 0,即节点内所有样本属于同一类别时停止进一步分裂。
样本选取方式	在构建每棵决策树时从原始训练数据集中采用有放回抽样的方式选取样本,保证了每棵树训练数据的随机性,有助于提高模型的鲁棒性和多样性。
泛化精度袋外样本估计	利用袋外样本对模型的泛化性能进行内部评估和估计

## 2 结果与讨论

### 2.1 数据预览

某航线运营飞机材料裂纹影像如图 2 所示。

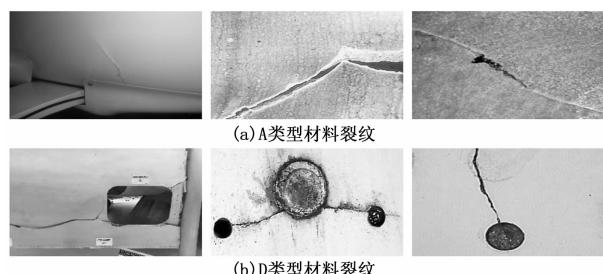


图 2 不同类型材料裂纹影像

其运行中关联的统计数据(部分)如表 2 所示,数据来源为公开数据库(数据值与变量名均已处理)。分析该航空公司在运营过程中的材料裂纹 A 类型与 D 类型故障发生与否与多个飞机参数、子系统参数等的运行指标相关。

表 2 中分别记录了 NS, BL, ……, Sbz\_2 等多个子系统在不同维修检查周期对应的材料裂纹故障发生情况时的影响值,其数据编号涵盖 8670—911321202 等大量数据。

对数据进行分组统计,统计数据包括均值,标准差,最小值,最大值,四分位数,节选部分统计结果如表 3 所示。

从表 3 中可看出数据分布不满足正态分布规律,表明数据集中各变量与材料裂纹故障的发生现象不具有完全随机性;同时标准差波动较大,表明不同变量的分布均匀性低。表明数据集中材料裂纹故障与变量间有相互影响的关系,不是随机影响变量,可以采用 ES 特征工程与 RF 分析评估模块进行深入分析。

### 2.2 ES 数据预处理与特征提取结果

#### 2.2.1 统计图分析结果

对原始数据绘制统计图分析,如图 3 所示。

表 2 材料裂纹故障数据集

Identification_code	Detection_type	NS	BL	E_D	S_D	C_D	A_D	……
8670	D	15.818 672	37.465 884	104.079 78	1395.500 26	0.159 027 96	0.242 643 2	……
8915	A	15.307 072	36.735 03	99.300 502	1 280.714 82	0.130 950 5	0.194 888 32	……
……	……	……	……	……	……	……	……	……
911321201	A	11.869 12	35.311 788	75.608 792	769.025 18	0.123 902	0.116 163 2	……
911321202	A	13.475 544	35.042 526	86.252 152	1 001.204 82	0.108 727 36	0.118 920 96	……
Slt_2	Fin	Rdr_1	Rdr_2	Evt_1	Evt_2	Sbz_1	Sbz_2	……
173.860 8	2 162.876	0.235 146 6	0.457 493 4	0.480 319 7	0.269 643 4	0.488 247 7	0.153 884 61	……
151.867 2	1 515.135 8	0.199 707 3	0.579 033	0.228 566 8	0.265 190 9	0.509 760 2	0.162 577 68	……
……	……	……	……	……	……	……	……	……
115.090 56	926.332 1	0.204 118 2	0.345 508 8	0.235 662	0.147 609 28	0.552 441	0.150 890 97	……
132.379 2	1 286.499 6	0.194 992 2	0.375 511 5	0.237 689 2	0.186 114 5	0.384 643 5	0.132 890 75	……

表 3 材料裂纹故障数据分组统计结果

变量	NS	NS	NS	NS	NS	NS	NS
统计量	mean	std	min	25%	50%	75%	max
A	12.804 734 1	1.995 853 78	7.142 959 2	11.531 464	12.779 768	14.089 464	19.630 061 3
D	18.510 149 2	3.563 673 75	11.204 04	15.818 672	18.366 44	20.760 728	32.767 281 7

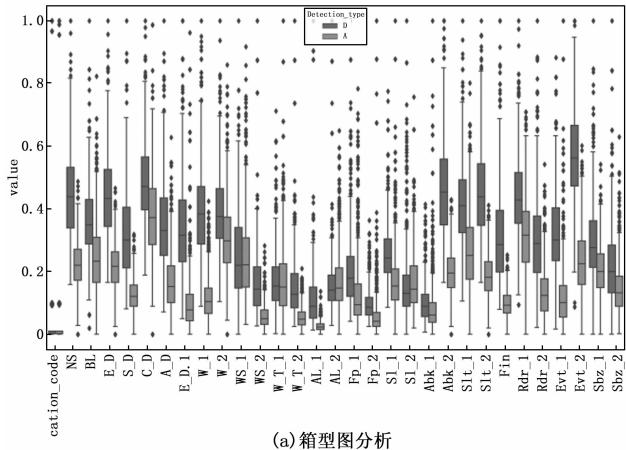
.....

变量	Sbz_2						
统计量	mean	std	min	25%	50%	75%	max
A	0.156 818 63	0.028 545 42	0.105 947 99	0.136 498 47	0.151 236 39	0.170 119 35	0.324 872 4
D	0.182 955 97	0.044 962 29	0.105 621 76	0.151 601	0.175 319 84	0.204 181 6	0.453 640 81

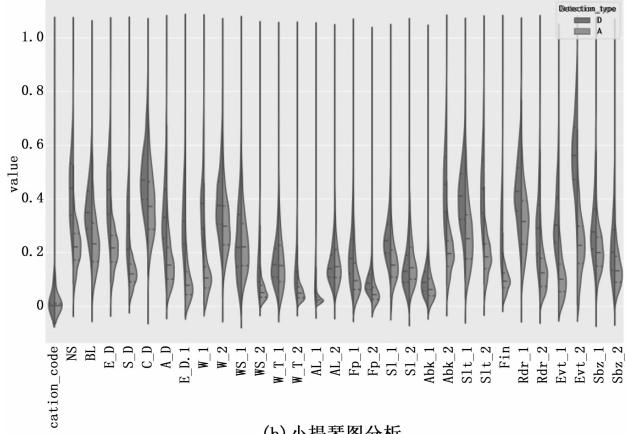
从图 3 (a) 中可以直观地观察到处理后的数据呈现的多个特征。箱形图中上下边缘代表了数据分布在箱体外部但在异常值范围之外的边界, 其涵盖的区间长度显示出处理后的数据在非极端部分的扩展程度是比较合理的, 进一步表明归一化/标准化处理在保留数据相对结构的同时, 有效地控制了数据的整体分布范围。图示中位数线基本处于上四分位数线与下四分位数线之间, 表明在数据的主体部分的分布形态相对均衡或接近对称, 没有明显的偏向性。然而尽管箱体和边缘区域显示出一定的稳定性和合理范围, 但各个变量均出现了数量较多且数值较大的正向异常值。这些异常值是经过归一化/标准化处理后仍然显著偏离主体数据分布的点, 可能代表了数据采集、记录的错误, 或是真实存在的极端情况。大量正向偏离的异常值的存在, 尽管其本身是位于数据分布的尾部, 却对整体数据分布的偏态产生了影响, 使其呈现出负偏态分布。

图 3 (b) 中部分变量, 例如 NS, C\_D, A\_D, Evt\_2 等多个变量呈现出较为细长的琴身形态, 意味着这些变量的数据在 [0, 1] 的数值区间内分布相对分散, 其概率密度在任一狭小区域内都相对较低, 取值变化范围较广, 波动性相对较大, 数据点没有强烈地聚集在某个特定的数值附近。而另一些变量, 如 WS\_2, WS\_1, WT\_2, AL\_2 等, 小提琴图则显示出较为宽短的琴身, 表明这些变量的数据在某个或某几个数值区域内表现出较高的概率密度, 数据点高度集中于这些区域, 其分布更为紧凑, 波动性相对较小。通过对不同分布变量进行有针对性的特征工程、模型输入处理或结果分析, 能够使得 ES-RF 模型更加充分地利用数据的内在信息, 更准确地捕捉变量与材料裂纹故障之间的复杂关系, 从而提高模型评估的准确率, 并为实际应用提供更可靠的洞察。

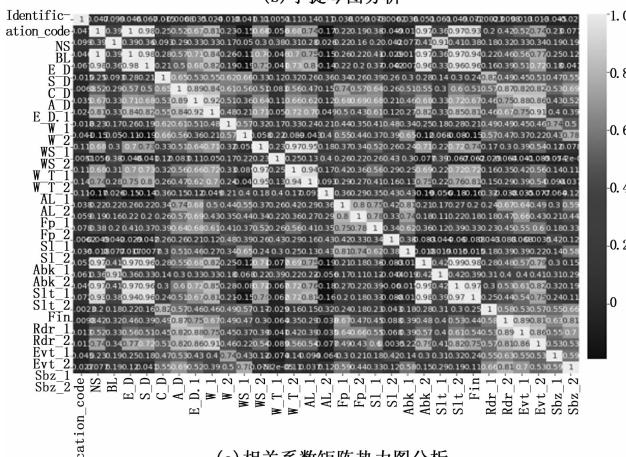
从图 3 (c) 所示的相关系数矩阵热力图中可以直观地观察到数据集各变量之间的线性相关性。热力图中颜色的深浅和对应的数值清晰地揭示了任意两个变量之间的皮尔逊相关系数, 图中显著显示出包括 NS, S\_D,



(a) 箱型图分析



(b) 小提琴图分析



(c) 相关系数矩阵热力图分析

图 3 预处理后的数据统计图分析

E\_D, W\_2, Abk\_2, BL, W\_1 等在内的多个变量之间存在着极高的相关性，表明这些变量的数值变化趋势高度一致或高度相反，这表明数据集中存在着严重的多重共线性问题，导致模型难以收敛或收敛不稳定、训练精度难以提高等问题。

## 2.2.2 异常特征值处理结果

在不同的变量中，标准差的大小反映出数据的离散程度，为了获得离散程度低、分析效果好的数据，并剔除异常数据，需要对数据标准差进行分析。标准差超过阈值视为异常数据，或机器学习非优数据。分别对标准差小于 3, 2, 1 时的数据进行分析。

1) 当标准差小于 3 时候，数据箱型图与小提琴图如图 4 所示。

2) 当标准差小于 2 时候，数据箱型图与小提琴图如图 5 所示。

3) 当标准差小于 1 时候，数据箱型图与小提琴图如图 6 所示。

从图 4~6 的统计分析图中可以清晰地观察到对数据进行基于异常值剔除的效果，其判断标准是基于数据点与对应变量均值之间的标准差距离。随着用于识别和剔除异常值的标准差阈值从相对宽松的 3 逐渐降低至严格的 2，再到更为严格的 1，被认为是“异常”或“非典型”的数据点被移除得越来越多，表明距离均值越近的数据点也可能因为阈值降低而被判定为异常并剔除。因此，被剔除的数据量不断增加，导致用于后续分析和模型训练的数据集合规模持续缩小。从视觉上看，箱型图和小提琴图中代表个体数据点的散点随着阈值降低而显著减少。更严格的数据筛选虽然能有效地移除极端值，但过度地缩小数据集规模会带来严重的过拟合风险。当训练数据量过小或其多样性不足以代表真实世界数据的全貌时，模型容易过度学习训练集中的特定噪声或偶然出现的模式，而不是数据的潜在规律。基于图 4~6 的对比分析，采用 2 倍标准差作为异常值剔除的界限可以在有效地减少极端异常值、使数据分布相对集中的同时，最大程度地保留了足够数量和多样性的数据样本，图中所呈现的数据分布状态表明，此时的数据集既展现了相对集中和清晰的特征分布，又保持了必要的样本规模，为 ES-RF 模型提供了一个在数据质量和数量上达到较好平衡的训练基础，更能帮助 ES-RF 模型学习到数据的通用模式，避免过度拟合训练集中的噪声，从而构建出具有良好泛化能力和较高评估准确率的模型。

## 2.2.3 数据清洗结果

对原始数据集进行主特征提取并剔除标准差绝对值小于 2 的数据后，生成新的数据集，特征提取及处理的统计图和相关系数矩阵热力图对比如图 7、图 8 所示。

从图 7~8 中可以看出，经过 ES-RF 模型中的 ES

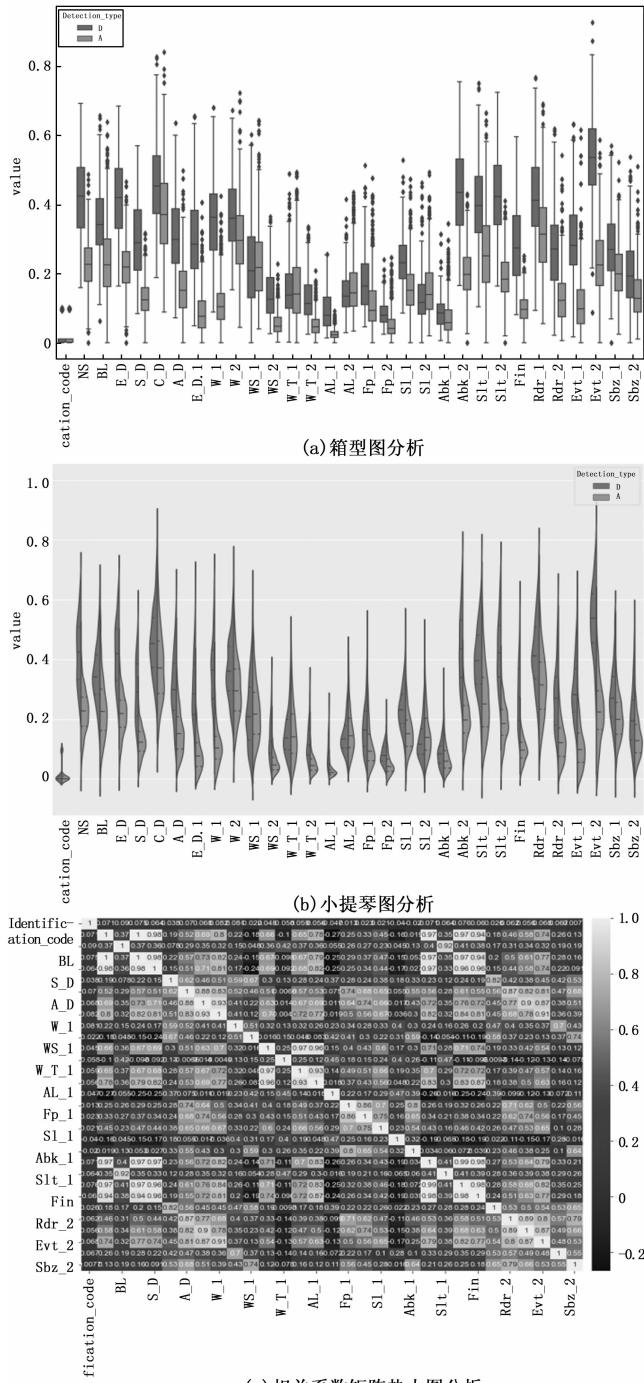
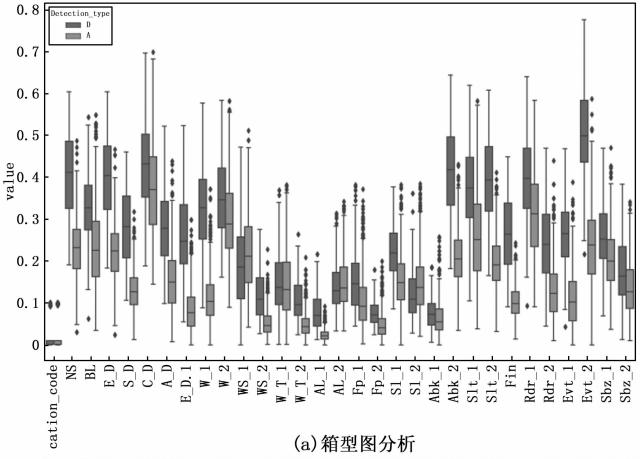


图 4 删除标准差小于 3 时的数据统计分析图

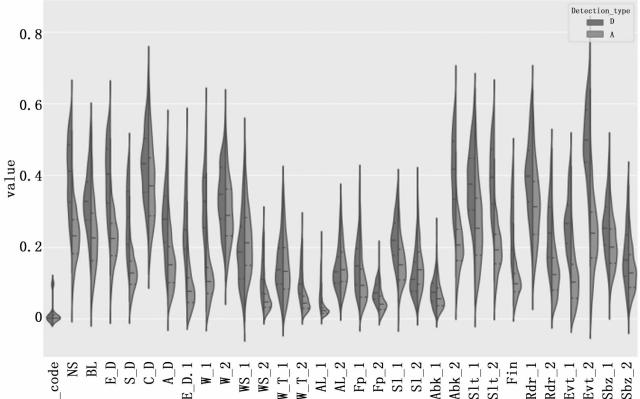
特征工程模块后，数据波动进一步降低，数据稳定性进一步提高。对数据进行主特征提取并剔除异常特征值后，数据量值范围合理，同时数据集中区域的分布合理，既保证了数据集的信息表达能力，又降低了训练后的模型存在过拟合的风险。

## 2.3 RF 分析与评估结果

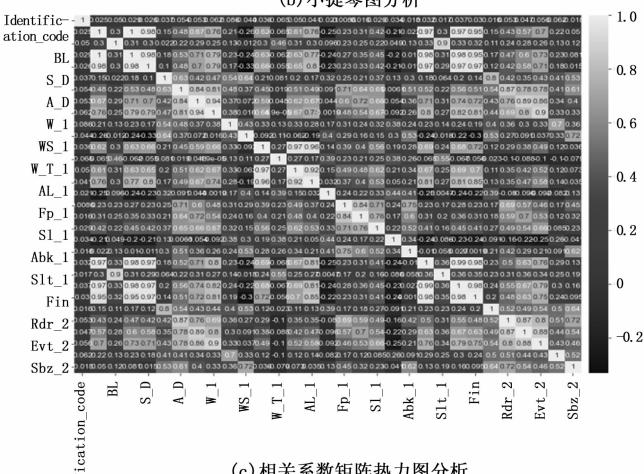
为了提高训练与测试的准确率，对 RF 模型中不同的树节点与叶节点进行分析，训练数据的准确率如表 3 所示。



(a) 箱型图分析



(b) 小提琴图分析



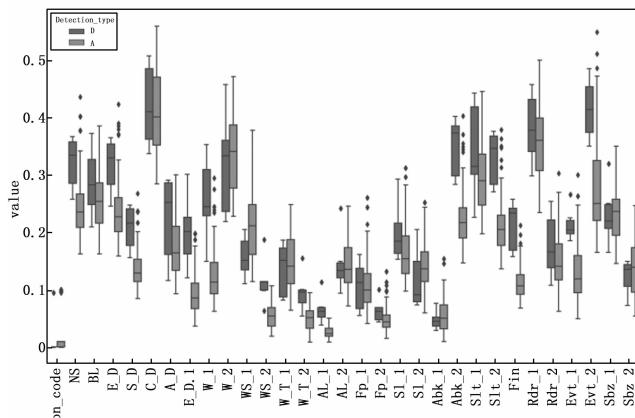
(c) 相关系数矩阵热力图分析

图 5 删除标准差小于 2 时的数据统计分析图

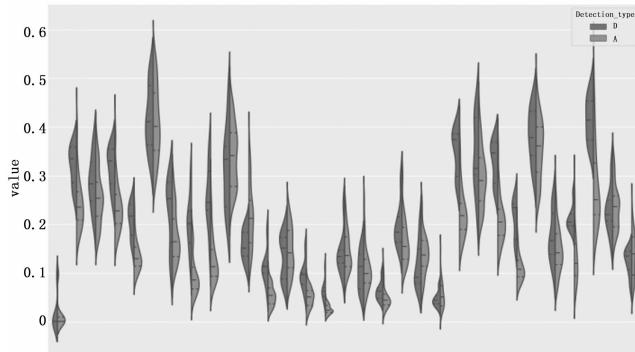
表 3 不同树节点与叶节点训练数据准确率

Estimators & Leaf nodes	2	3	...	16	17
2	0.852 775	0.876 557	...	0.921 857	0.927 52
3	0.884 485	0.928 652	...	0.941 11	0.942 242
...	...	...	...	...	...
17	0.967 157	0.978 482	...	0.989 807	0.987 542

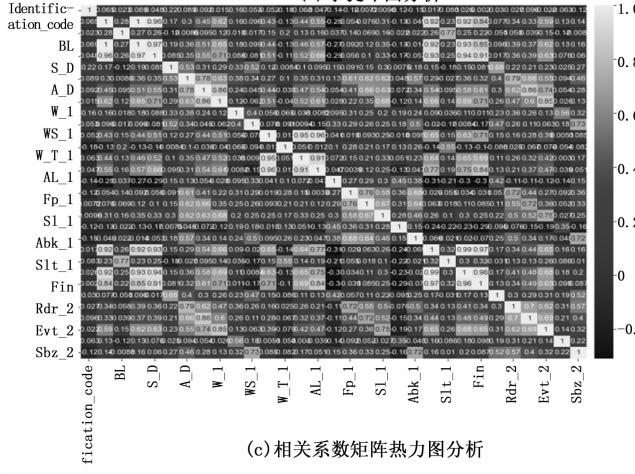
根据表 3 数据散点绘制三维曲面图, 如图 9 所示。



(a) 箱型图分析



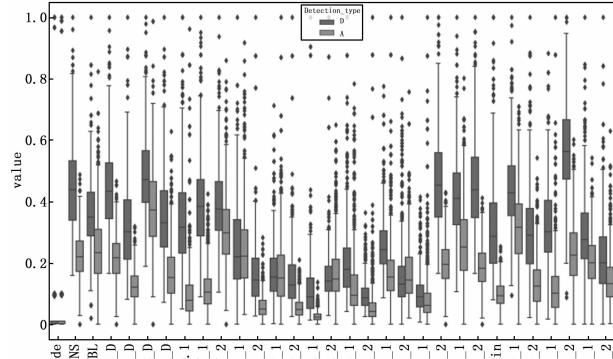
(b) 小提琴图分析



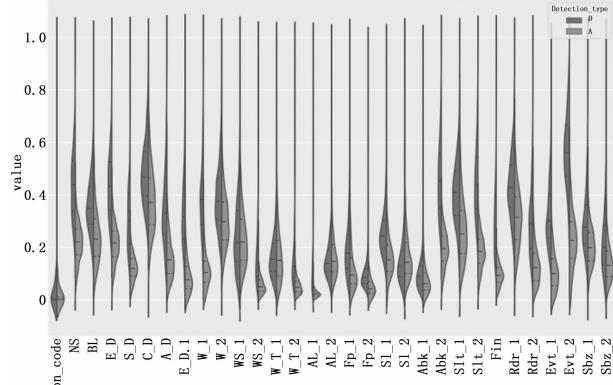
(c) 相关系数矩阵热力图分析

图 6 删除标准差小于 1 时的数据统计分析图

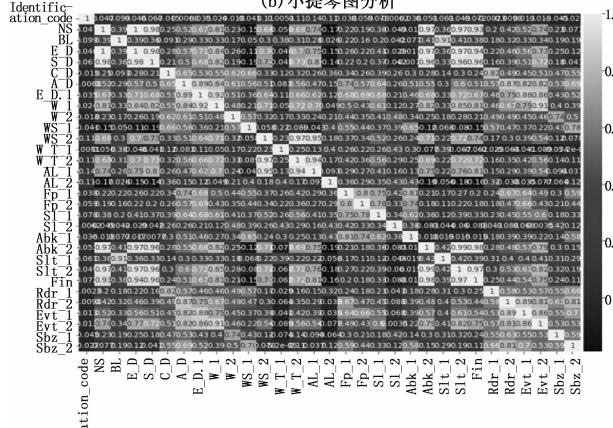
从图 9 所呈现的决策树数量与最大叶子节点数对 RF 模型训练数据准确率影响的三维曲面图中可以清晰地观察到模型性能随这两个关键超参数变化的动态过程。曲面的高度代表了模型在训练集上的准确率。当决策树数量和最大叶子节点数从较小的初始值开始逐渐增加时, 模型在训练数据上的准确率呈现出显著且快速的提升, 反映了模型从欠拟合状态向拟合状态的快速转变。在参数值很小的时候, 由少量简单决策树组成的 RF 模型学习能力不足以捕捉数据中的复杂模式和规



(a) 箱型图分析



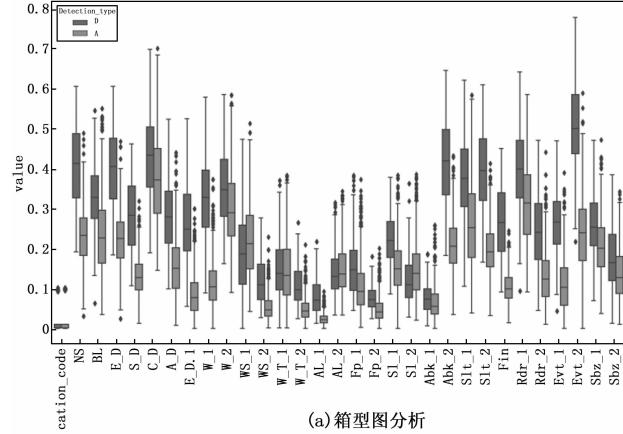
(b) 小提琴图分析



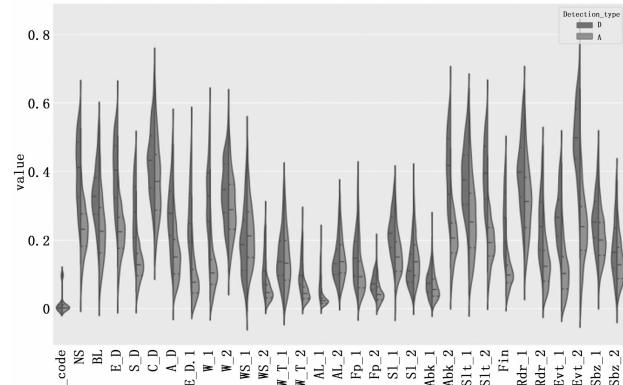
(c) 相关系数矩阵热力图分析

图 7 特征提取及处理前的数据统计图与相关系数矩阵热力图

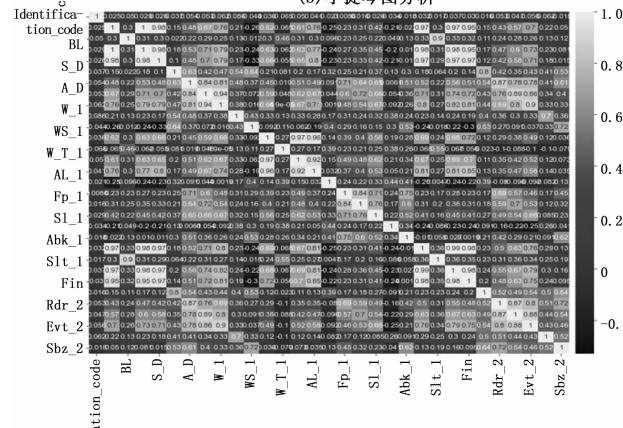
律，导致训练误差较高，即处于欠拟合状态。随着树的数量增加和每棵树允许的复杂度提高，模型的表达能力和对训练数据细节的捕捉能力增强，因此训练准确率迅速攀升。随后，当决策树数量和最大叶子节点数继续增加时，曲面的坡度趋于平缓，准确率的增长速度明显放缓，呈现缓慢增加或趋于平台期。在这个阶段，模型已经基本捕捉到了训练数据中的主要信息，进一步增加模型的复杂度所带来的准确率提升效应变得越来越微弱，甚至可以忽略不计。同时，参数的增加通常意味着计算资源的相应大量增加。图示的平缓区域表明，在这个范围内投入更多的计算资源来增加模型复杂度对于提高训



(a) 箱型图分析



(b) 小提琴图分析



(c) 相关系数矩阵热力图分析

图 8 特征提取及处理后的数据统计图与相关系数矩阵热力图

练数据的准确率而言其边际效益极低，投入与产出不成比例。当参数值进一步增大时，曲面高度开始趋于平缓甚至呈现轻微的下降趋势，模型开始学习训练数据中的随机噪声而非真实模式，从而牺牲泛化能力并引发过拟合。

对训练后的模型进行测试数据的评估验证，不同的树节点与叶节点评估准确率如表 4 所示。

根据表 4 数据散点绘制三维曲面图，如图 10 所示。

从图 10 中可以看出，在测试数据评估的开始阶段有部分准确率高于测试数据，表明模型在树节点与叶节点数量低的区域波动性大，即拟合性不高，后续与模型

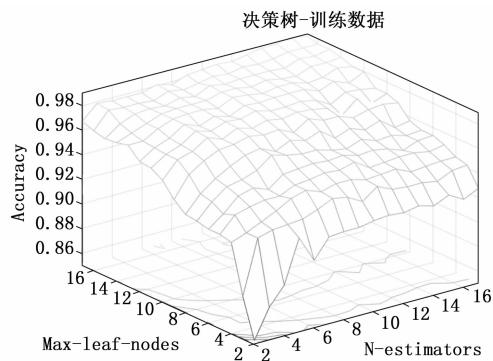


图 9 不同树节点与叶节点训练数据准确率  
三维曲面图

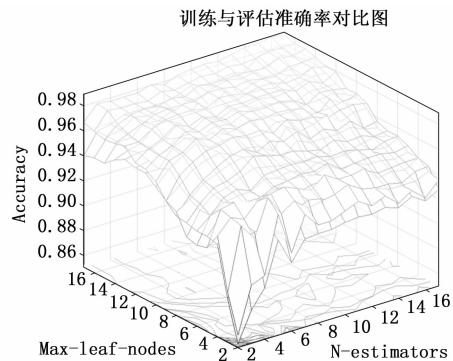


图 11 不同树节点与叶节点训练数据与测试  
数据散点拟合三维曲面图

表 4 不同树节点与叶节点验证数据准确率

Estimators & Leaf nodes	2	3	...	16	17
2	0.859 77	0.896 552	...	0.924 138	0.935 632
3	0.889 655	0.940 23	...	0.933 333	0.937 931
...	...	...	...	...	...
17	0.940 23	0.956 322	...	0.979 31	0.977 011

过程一致，模型评估快速进入到高准确率阶段，对测试数据有极高的准确率反馈，同时在树节点与叶节点高于(16, 16)后，测试数据的模型评估准确率也开始呈现降低趋势，进入到过拟合阶段。

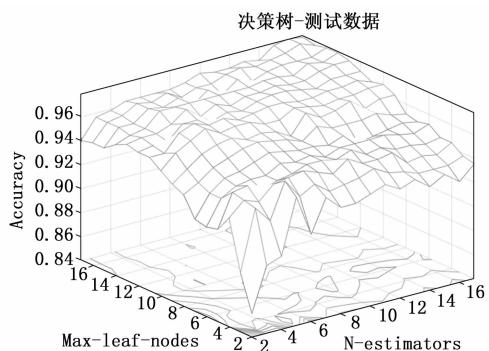


图 10 不同树节点与叶节点训练数据准确率  
三维曲面图

根据模型训练图 9 与测试数据图 10 绘制散点拟合三维曲面图，分析在随着树节点与叶节点变化过程中训练数据与测试数据的准确率拟合情况，如图 11。

图 11 是模型调优和验证过程中关键的可视化结果，通过三维曲面的形式直观地比较了 ES-RF 模型在不同参数组合下训练集和测试集上的准确率表现，描述了两者间的拟合情况。图中代表训练数据准确率的曲面与代表评估数据准确率的曲面之间的拟合性极强，意味着训练准确率与评估准确率的数值非常接近，变化趋势高度同步。这种“拟合性强”的现象表明了训练后的 ES-RF

模型具有优秀的泛化能力。模型并没有仅仅记忆训练数据中的噪声和特定模式，而是成功学习到了数据中更具普遍性和泛化性的规律，有效避免了过拟合。同时高且接近的训练与评估准确率意味着模型在应用于实际的、未用于训练和评估的新的数据时，依然能够保持较高的预测准确率。

### 3 结束语

本研究提出 ES-RF 模型对飞机材料裂纹故障进行了深入的智能识别分析，通过专家系统与随机森林算法的有机融合，有效解决了传统目击检查效率低、准确率差的技术难题。研究采用专家系统进行数据预处理和特征工程，通过归一化处理、异常值剔除和相关性分析等手段优化了数据质量，并运用随机森林算法构建了高精度的裂纹故障识别模型。实验结果表明，ES-RF 模型在材料裂纹故障评估中展现出卓越的性能，训练准确率达到 98.98%，测试准确率达到 97.93%，训练集与测试集准确率的高度拟合表明模型具有良好的泛化能力和稳定性，为飞机维修检查中 A 类型和 D 类型材料裂纹故障的自动化识别提供了可靠的技术方案。

### 参考文献：

- [1] 王锐光, 吴际, 刘超, 等. 基于维修日志的飞机设备故障原因判别方法 [J]. 软件学报, 2019, 30 (5): 1375–1385.
- [2] LITT J S, SIMON D L, GARG S, et al. A survey of intelligent control and health management technologies for aircraft propulsion systems [J]. Journal of Aerospace Computing, Information, and Communication, 2004, 1 (12): 543–563.
- [3] GÜEMES A, FERNANDEZ-LOPEZ A, POZO A R, et al. Structural health monitoring for advanced composite structures: a review [J]. Journal of Composites Science, 2020, 4 (1): 13.
- [4] TOWSYFYAN H, BIGURI A, BOARDMAN R, et al. Successes and challenges in non-destructive testing of air-

- craft composite structures [J]. Chinese Journal of Aeronautics, 2020, 33 (3): 771–791.
- [5] QING X, LI W, WANG Y, et al. Piezoelectric transducer-based structural health monitoring for aircraft applications [J]. Sensors, 2019, 19 (3): 545.
- [6] CHADY T, OKARMA K, MIKOŁAJCZYK R, et al. Extended damage detection and identification in aircraft structure based on multifrequency eddy current method and mutual image similarity assessment [J]. Materials, 2021, 14 (16): 4452.
- [7] SUN Y, OUYANG T, XU J, et al. Crack detection in aircraft fastener holes using flat geometry remote field eddy current technique and super sensitive eddy current system [J]. Inovative Materials Testing Technologies Inc.
- [8] SHEN X, LU X, GUO J, et al. Nondestructive testing of metal cracks: contemporary methods and emerging challenges [J]. Crystals, 2023, 14 (1): 54.
- [9] KUBRUSLY A C, FREITAS M A, VON DER WEID J P, et al. Interaction of SH guided waves with wall thinning [J]. NDT & E International, 2019, 101: 94–103.
- [10] TITTMANN B R. Approaches for ultrasonic damage detection in aircraft components for structural health monitoring [J]. The Journal of the Acoustical Society of America, 2010, 127 (3 \_ Supplement): 1900–1900.
- [11] STOLZE F H G, WORDEN K, MANSON G, et al. Fatigue-Crack detection in a Multi-Riveted Strap-Joint aluminium aircraft panel using amplitude characteristics of diffuse lamb wave field [J]. Materials, 2023, 16 (4): 1619.
- [12] ZHU Z, MA X, WANG C, et al. The metallurgical behaviors and crystallographic characteristic on macro deformation mechanism of 316 L laser-MIG hybrid welded joint [J]. Materials & Design, 2020, 194: 108893.
- [13] WANG X, WONG B S, TAN C S, et al. Automated crack detection for digital radiography aircraft wing inspection [J]. Research in Nondestructive Evaluation, 2011, 22 (2): 105–127.
- [14] TRAN T, SAMANT P, XIANG L, et al. X-ray induced acoustic computed tomography for non-destructive testing of aircraft structure [C] // ASME International Mechanical Engineering Congress and Exposition. American Society of Mechanical Engineers, 2019, 59360: V001T03A005.
- [15] ALDRIN J C, MANDEVILLE J R, JUDD D R, et al. Crack detection for aircraft holes with limited accessibility containing fasteners and sealant [C] // AIP Conference Proceedings. 2003, 657 (22): 173–180.
- [16] TOWSYFYAN H, BIGURI A, BOARDMAN R, et al. Successes and challenges in non-destructive testing of aircraft composite structures [J]. Chinese Journal of Aeronautics, 2020, 33 (3): 771–791.
- [17] ZHU Z, MA X, WANG C, et al. The metallurgical behaviors and crystallographic characteristic on macro deformation mechanism of 316 L laser-MIG hybrid welded joint [J]. Materials & Design, 2020, 194: 108893.
- [18] PAN X, XIANG T, HE Y, et al. A crack detection method for aero-engine blade based on air-flow thermography [J]. Journal of Nondestructive Evaluation, 2023, 42 (1): 22.
- [19] 陈勇刚, 罗晓利, 杨晓强. 航空公司司机队可靠性状态识别方法 [J]. 航空学报, 2014, 35 (8): 2217–2224.
- [20] QING X, LI W, WANG Y, et al. Piezoelectric transducer-based structural health monitoring for aircraft applications [J]. Sensors, 2019, 19 (3): 545.
- [21] BAO Y, CHEN Z, WEI S, et al. The state of the art of data science and engineering in structural health monitoring [J]. Engineering, 2019, 5 (2): 234–242.
- [22] HASSANI S, DACKERMANN U. A systematic review of advanced sensor technologies for non-destructive testing and structural health monitoring [J]. Sensors, 2023, 23 (4): 2204.
- [23] LI W, YAN E. Fault diagnosis of bearings based on the fusion of 1D-CNN and random forest algorithm [C] // 2024 6th International Conference on Communications, Information System and Computer Engineering (CISCE). IEEE, 2024: 1068–1071.
- [24] MING Y, SHAO H, CAI B, et al. Rgfc-Forest: an enhanced deep forest method towards small-sample fault diagnosis of electromechanical system [J]. Expert Systems with Applications, 2024, 238: 122178.
- [25] ZOLGHADRI A, LEBERRE H, GOUPIL P, et al. Parametric approach to fault detection in aircraft control surfaces [J]. Journal of Aircraft, 2016, 53 (3): 846–855.
- [26] LI L, DAS S, JOHN HANSMAN R, et al. Analysis of flight data using clustering techniques for detecting abnormal operations [J]. Journal of Aerospace Information Systems, 2015, 12 (9): 587–598.
- [27] JOHNSON S C. Hierarchical clustering schemes [J]. Psychometrika, 1967, 32 (3): 241–254.
- [28] LIN L, WANG B, QI J, et al. Bearing fault diagnosis considering the effect of imbalance training sample [J]. Entropy, 2019, 21 (4): 386.
- [29] DAHLENI KRAEMER A, VILLANI E. Framework for offline Data-Driven aircraft fault diagnosis [J]. Journal of Aerospace Information Systems, 2024, 21 (4): 348–361.
- [30] LI G, BA Z G, ZHANG H Z. Expert system of fault diagnosis for flight simulator based on fault tree analysis [J]. Advanced Materials Research, 2014, 1055: 371–374.