

doi: 10.3969/j.issn.1007-7375.250052

基于改进 Jaya-RUSBoost 模型的焊枪故障预测

李响¹, 徐照光¹, 吴建国²

(1. 大连理工大学 经济管理学院, 辽宁 大连 116024; 2. 北京大学 工学院, 北京 100871)

摘要: 焊枪是工程制造中的关键设备, 其稳定性和可靠性直接影响生产线的连续运行与产品质量。针对焊枪故障预测中产生的数据不平衡问题, 提出了一种基于 Jaya-RUSBoost 改进模型的焊枪故障预测方法, 通过结合欠采样、集成学习和参数设置优化, 实现数据的平衡和故障预测精度的提升。首先, 构建 RUSBoost 故障预测模型, 设计实验评估超参数值对模型性能的影响, 确定模型参数的较优取值范围; 其次, 设计 Jaya 元启发式算法对 RUSBoost 模型参数进行迭代, 从而寻求最优故障预测参数模型。案例研究表明, 相较于传统的 RUSBoost 算法, Jaya-RUSBoost 算法在 5 个焊枪上的故障预测准确率和 F1 值分别提升了 9.43% 和 8.41%, 且与多种机器学习模型相比, 准确性等指标也得到了显著的提升。本文提出的焊枪故障预测方法, 具有较高的实际应用价值和推广前景, 能够为焊接设备的智能维护提供有力支持。

关键词: 故障预测; 焊枪; 数据不平衡; Jaya-RUSBoost; 智能制造

中图分类号: TP277; TP18; F403.6

文献标志码: A

文章编号: 1007-7375(xxxx)x-0001-12

Fault Prediction of Welding Guns Based on the Improved Jaya-RUSBoost Model

LI Xiang¹, XU Zhaoguang¹, WU Jianguo²

(1. School of Economics and Management, Dalian University of Technology, Dalian 116024, China;

2. College of Engineering, Peking University, Beijing 100871, China)

Abstract: The welding gun is a key device in engineering manufacturing, and its stability and reliability are crucial for the continuity of the production line and the quality of products. Faced with the challenge of data imbalance in welding gun fault prediction, a welding gun fault prediction method based on the Jaya-RUSBoost improved model is proposed. By combining undersampling, ensemble learning, and parameter setting optimization, this method achieves data balance and improves the accuracy of fault prediction. First, a RUSBoost fault prediction model is constructed, and experiments are designed to evaluate the impact of hyperparameter values on model performance, thereby determining the optimal range of model parameters. Subsequently, the Jaya metaheuristic algorithm is designed to iteratively optimize the parameters of the RUSBoost model, in order to seek the optimal fault prediction parameter model. The results of the case study show that compared with the traditional RUSBoost algorithm, the proposed algorithm has increased the average fault prediction accuracy and F1 value by 9.43% and 8.41% respectively on five welding guns. Moreover, compared with various machine learning models, the accuracy and other indicators have also been significantly improved. The welding gun fault prediction method proposed in this paper has high practical application value and broad prospects for promotion, and can provide strong support for the intelligent maintenance of welding equipment.

Key words: fault prediction; welding torch; data imbalance; Jaya-RUSBoost; intelligent manufacturing

收稿日期: 2025-04-17

基金项目: 国家自然科学基金资助项目 (72001034); 辽宁省自然科学基金博士科研启动基金资助项目 (2022-BS-088); 中央高校基本科研业务费资助项目 (DUT23RC(3)037); 大连理工大学经济管理学院研究生科研基金重点项目 (DUTSEMPRFK02)

作者简介: 李响 (2002—), 女, 辽宁省人, 硕士研究生, 主要研究方向为故障预测与健康管理。Email: lx410@mail.dlut.edu.cn

通讯作者: 徐照光 (1989—), 男, 江西省人, 副教授, 博士, 主要研究方向为智能质量管理、工业大数据分析等。

Email: zhgxu@dlut.edu.cn

随着技术创新与发展,工业制造设备变得愈加高效与智能,而设备维护却仍面临巨大挑战。《“十四五”信息化和工业化深度融合发展规划》指出,目前我国制造企业设备管理存在设备维护效率低、管理调整能力差、故障预测能力弱等痛点,设备服役工况复杂、故障情况多发、施工效率低下。设备运维能力直接影响企业的维修成本、生产效率以及客户服务水平。通常情况下,设备维护主要包括预防维护和事后维修两类。然而,传统维护方法往往难以应对日益复杂的设备管理需求,无法有效满足快速变化的工业环境和技术进步所带来的挑战。与上述方法相比,预测性维护通过故障预测实现了维护工作的精准化和智能化^[1]。设备故障预测作为预测性维护的重要组成部分,是指在设备运行过程中,通过分析从设备上采集的监测数据,对设备的潜在故障和性能衰退状态进行预测。这种维护策略能够降低计划外停机的风险、减少维护频率、降低维护成本,并且延长设备服务寿命。

螺柱焊枪作为汽车等装备制造中不可或缺的关键设备,广泛应用于车身部件和底盘系统等关键部件的连接,其稳定性和可靠性对生产效率和产品质量具有重要影响。目前,已有文献对螺柱焊枪的常见故障进行分析和研究^[2],但对于螺柱焊枪这一特定设备的故障预测模型的研究仍相对不足。Wang等^[3]利用多变量时间序列数据对电阻点焊枪的故障预测进行了评估,发现随机森林和时间融合变换器在多数情况下预测性能较优。但直接应用机器学习模型的准确性仍需提升,其预测准确性尚未达到工业应用的期望水平。此外,螺柱焊枪传感器收集的数据主要是焊接过程中的信号数据,而非直接针对焊枪本身的监测数据,而且焊枪故障数据的分布往往极不平衡,这些因素共同增加了准确预测焊枪故障的难度。针对螺柱焊枪故障预测中显著的数据不平衡挑战,本研究深入剖析了焊枪传感器收集的数据及以往故障记录,提出了一种 Jaya-RUSBoost 混合模型。该模型融合了 Jaya 优化算法与 RUSBoost 集成学习技术,专为应对数据不均衡情境下的精确故障预测而设计。此改进方案为制造企业的设备运维决策提供了一种有效的工具,能够前瞻性地识别焊枪潜在的故障风险,进而降低生产设备故障所带来的经济损失。

1 文献综述

当前,设备故障预测方法主要有 3 类:基于模型驱动、基于信息融合和基于数据驱动。

基于模型驱动的设备故障预测方法是将设备状态监测数据与设备的机械动力学特征进行结合,通过数学模型来刻画设备的衰退行为,进而预测设备健康状态和剩余使用寿命。Zhou 等^[4]基于 Paris 模型,采用有限元方法模拟了受电弓上臂的疲劳裂纹扩展,以预测受电弓在正常和腐蚀条件下的疲劳裂纹扩展寿命。蒋文博等^[5]提出了一种结合比例风险模型和机器学习的混合方法,通过比例风险模型探讨寿命与协变量的关联推导出累计风险函数,并计算寿命的预测值。使用模型驱动方法预测设备健康状态需要建立精确的数学模型。但随着工业过程自动化的提升,设备监测特征的复杂性使得企业难以建立精确的数学模型^[6]。因此,该方法的运用受到了一定的限制。

基于信息融合的设备故障预测方法是将多监测数据和多传感器信息有效结合,通过直接输入、数据融合和预测融合等技术,预测设备健康状态和剩余寿命。基于信息融合的设备健康预测方法主要有 3 种。1) 将获取的多源监测数据直接输入到状态空间模型中进行分析。例如 Liu 等^[7]建立一个 Box-Cox 变换和状态空间模型的统一预测框架,以有效地线性化传感器数据,从而简化退化建模并提高剩余使用寿命 (remaining useful life, RUL) 预测精度。2) 对多传感器的数据进行层次化融合,以综合不同来源的信息,提高健康预测的准确性。例如 Ta 等^[8]提出一种基于多传感器多特征融合的自适应分阶段 RUL 预测方法,分别利用信息贡献率和衰减指标适宜性对振动信号和特征进行初始融合。3) 对多传感器进行预测层次的融合。例如李天梅等^[9]针对多源传感监测的线性随机退化设备,提出了一种结合随机失效阈值的数模联动方法来预测设备剩余寿命。

随着物联网的广泛应用,设备监测所产生的数据量以爆发式的速度增长。传统的信息处理方法在处理大规模数据时面临诸多实际问题,例如处理速度无法满足实时分析需求,来自不同设备的数据类型的多样性增加了数据处理的复杂性。相比之下,数据驱动方法凭借其强大的数据处理能力和预测准

确性, 逐渐受到广泛关注并应用于设备故障预测领域。基于数据驱动的设备故障预测方法利用设备运行状态的大量监测数据, 分析设备的失效阈值和未来状态, 从而预测设备的故障时间, 并评估其健康状态。这类方法包括传统的数值时间序列技术、人工智能和数据挖掘算法。例如, 谢本凯等^[10]针对轨道电路故障诊断准确率低且高质量故障数据难以收集等问题, 提出一种基于单分类支持向量机 (one-class support vector machines, OC-SVM) 与深度神经网络 (deep neural networks, DNN) 相结合的故障诊断方法。Bai 等^[11]提出了一种基于时际回归图 (inter-temporal return plot, IRP) 和数据增强的故障预测方法, 通过 IRP 将一维时间序列转为二维图像, 并利用 Wasserstein 生成对抗网络生成合成图像, 以减少数据不平衡, 提升故障诊断的准确性与收敛速度。刘华开等^[12]提出了一种联合故障机理和卷积神经网络的齿轮剩余使用寿命预测方法, 依据故障信号特征参数生成融合故障先验的时域、角域卷积核, 利用神经网络的特征提取能力挖掘振动信号中的平稳型、冲击型故障成分, 具备较好的物理解释性。

数据驱动的设备故障预测方法面临的主要问题是数据不平衡, 即设备故障数据在实际应用中通常较为稀少, 而正常运行的数据占据绝大多数^[13]。这种不平衡会导致模型在训练过程中更倾向于预测正常状态, 从而降低故障预测的准确性。不平衡数据集的处理策略通常从两个维度展开: 数据层面和算法层面^[14]。在数据层面, 采样技术被广泛应用于调整数据分布, 其中过采样通过增加少数类样本的数量来平衡数据集。SMOTE (synthetic minority over-sampling technique) 算法作为过采样的常用方法, 结合了 K 近邻算法与线性插值法的优势, 为少数类别生成新的样本。李敏波等^[15]针对汽车零部件质检数据中合格品与不合格品数量不平衡的问题, 提出了一种基于密度聚类和多工序制造特征的 MCDC-MF-SMOTE 质检数据过采样方法。欠采样方法则通过减少多数类样本的数量来实现类别平衡。李新鹏等^[16]提出了一种基于自适应加权 Bagging-GBDT 算法的磁盘故障预测模型, 采用聚类分层欠采样方法对健康磁盘样本进行多次抽样, 避免了随机欠采样过程中可能丢弃有用样本的问题。在算法层面, 集成学习技术展现出了强大的潜力。学者们也对算法本身进行了改进。范敏等^[17]利用有放回随机抽样的

思路, 设计了一种损失函数的随机选择策略, 构建了基于随机代价敏感卷积神经网络 (random cost-sensitive convolutional neural network, RandomCost-CNN) 的停电故障预测模型, 以应对传统代价敏感方法对少数类 (停电故障类) 过拟合的问题。

2 问题描述

螺柱焊接是汽车车身车间生产过程中一项关键工艺, 主要用于连接车身与车内各部件、仪表和装饰件。本文所采集数据来自拉弧螺柱焊接过程。在拉弧螺柱焊接中, 焊接工具或焊枪将螺柱靠在母材上。触发时, 喷枪中的电磁阀将螺柱从母材上提升到预设高度。拉出的电弧熔化了螺柱的底部和母材, 形成了一个熔池。然后, 喷枪将螺柱向下压入熔池中, 并用陶瓷套圈将熔融材料固定到位, 直到形成焊缝。拉弧式螺柱焊接示意图如图 1 所示。图中 A 为螺柱装入焊接工具并与母材正确对齐; B 为按下扳机, 螺柱升起, 产生电弧; C 为电弧期结束, 螺柱进入熔池; D 为焊接完成, 撤回焊接工具, 取下卡套进行检查。

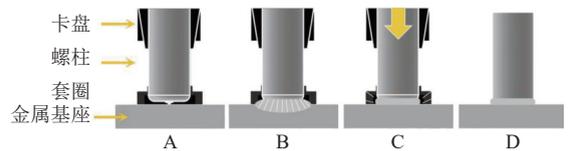


图 1 拉弧式螺柱焊接示意图

Figure 1 Schematic diagram of drawn-arc stud welding

焊接系统的高效运作依赖于控制器、馈线和焊头这 3 大核心部件的协同工作。控制器负责实时调控焊接能量和螺柱运动, 馈线确保高效安全的送料过程, 不同焊头适用于多种螺柱加工, 能够应对不同材料的焊接需求。这些部件的协同工作保证了焊接的质量和效率。

在焊接操作过程中, 焊枪可能会遇到诸如位置不正确、螺柱工作信号未能及时重置、螺柱长度错误等故障。发生故障后, 工作人员需要根据故障类型准备相应工具和零件来对焊枪进行维修, 这会消耗大量时间且造成一定经济损失。因此企业需要充分利用历史焊接数据及故障信息, 利用数据驱动的方法, 提前预测故障的发生时间以及故障类型, 使业务部门有足够的时间提前采取应对措施, 以便进一步控制停机时间减少损失。由于机器设备通常会

在出现故障后立即维修，这就导致历史故障样本的匮乏，数据分布存在严重的不平衡。焊枪数据存在的上述特点，使得精准预测焊枪故障成为企业的一项重要挑战。

3 方法与模型

3.1 RUSBoost 算法

如何高效处理不平衡数据是机器学习领域的一

个关键问题，RUSBoost 作为一种创新的混合采样和提升的算法，通过结合随机多数类欠采样 (random undersampling, RUS) 和 AdaBoost 集成学习技术，有效地提高了对少数类的识别能力。RUSBoost 算法^[18]通过欠采样平衡训练数据的类别分布，缩短训练时间，并通过独立采样每个基础学习器的训练集，有效克服欠采样带来的信息丢失问题。RUSBoost 算法结合了欠采样和提升法，其中提升法基于 AdaBoost 算法，其示意图如图 2 所示。

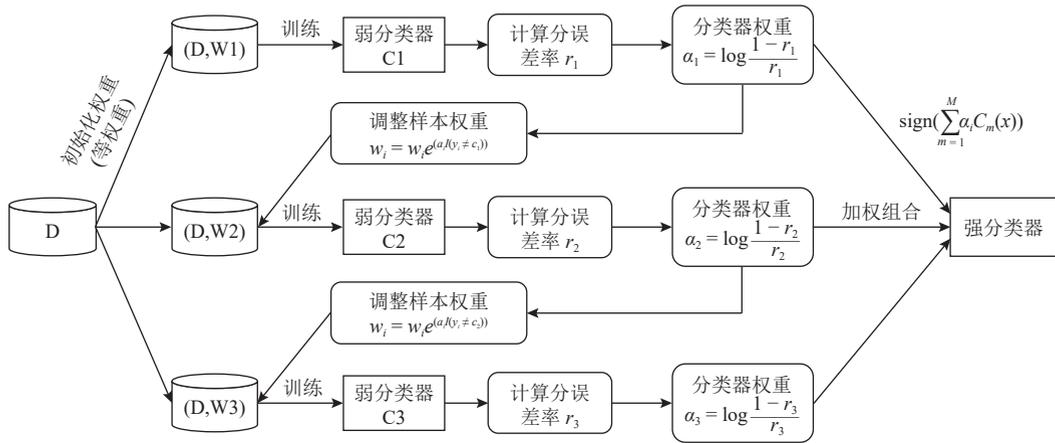


图 2 AdaBoost 算法示意图

Figure 2 Schematic diagram of the AdaBoost algorithm

Adaboost 分类器在数据集平衡的情况下分类效果更好，而在数据集不平衡的情况下，就会出现拟合不足的问题，从而降低分类性能。为了尽量减少不平衡数据的负面影响，RUSBoost 分类器采用了欠采样技术。在 RUSBoost 中，在进行欠采样后，权重会通过上述 Adaboost 方法进行更新。RUSBoost 使用公式 (1) 对新的测试实例进行分类。

$$y_i = H(x_i) = \text{sign} \left(\sum_{n=1}^N \alpha_n h_n(x_i) \right). \quad (1)$$

其中，分配给测试示例 x_i 的标签用 y_i 表示，RUSBoost 分类器用 $H(x_i)$ 表示， n 表示训练迭代次数或循环次数，弱学习器 (DTs) 用 h_n 表示， $\text{sign}()$ 函数返回 -1 (负类) 或 1 (正类)。

3.2 基于 Jaya-RUSBoost 改进算法的焊枪故障预测方法

尽管 RUSBoost 算法在处理不平衡数据方面表现出色，但在实际应用中仍存在一些不足之处，尤其是在参数设置方面。RUSBoost 中的一些关键参数 (如迭代次数、基分类器数、学习率等) 通常为经

验设定，未针对具体数据进行优化，可能会影响模型性能。此外，RUSBoost 在面对样本分布复杂或数据维度较高的场景时，分类边界较易受限。因此，有必要引入优化算法提升模型鲁棒性与预测精度。本文引入 Jaya 优化算法对 RUSBoost 分类器的超参数 (如弱学习器数量、学习率、最大深度等) 进行优化。Jaya 优化算法^[19]是一种通过迭代优化使候选方案更接近最佳方案的技术，其流程图如图 3 所示。

Jaya 优化算法具体步骤如下。

步骤 1 随机初始化一个候选解种群，该种群包含多个候选解。每个候选解都代表 RUSBoost 分类器的一组潜在超参数设置。

步骤 2 对种群中的每个候选解，使用训练数据集计算其对应的目标函数值。目标函数旨在最大化 F1 分数，以评估候选解的性能，如公式 (2)~(4) 所示。在整个候选解种群中，找出目标函数值最好的即 F1 分数最高的解 (X_i^*) 和最差的即 F1 分数最低的解 (X_i^{\dagger}) 的候选解。

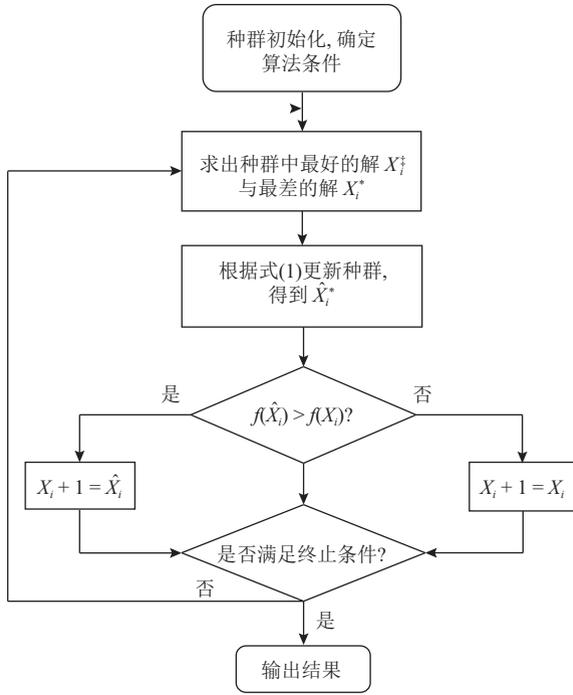


图 3 Jaya 优化算法流程图

Figure 3 Flowchart of Jaya optimization algorithm

$$P = \frac{P_T}{P_T + P_F}; \quad (2)$$

$$R = \frac{P_T}{P_T + N_F}; \quad (3)$$

$$f(X_i^*) = \max \left[\frac{2P \times R}{P + R} \right]. \quad (4)$$

其中, P_T 为正确分类的阳性检测样本数, P_F 为错误分类的阳性样本数, N_T 为正确分类的阴性样本数, N_F 为错误分类的阴性样本数。 P 为精确率, 它衡量的是被预测为正例的样本中实际为正例的比例, R 为召回率, 也称查全率, 它衡量的是实际为正例的样本中被预测为正例的比例。 F1 分数是召回率和精确度的调和平均数, 用于综合评估模型的性能。它旨在平衡召回率和精确度, 因为有时单独优化其中一个指标可能会导致另一个指标的性能下降, 因此目标函数使 F1 最大化。

步骤 3 使用 Jaya 优化算法中的更新公式 (如式 (5) 所示) 来更新种群中的每个候选解。对于种群中的每个候选解, 通过在其原始值上添加或减去与最佳解和最差解相关的项来生成新的候选解。这个过程旨在使新的候选解趋近于最佳解, 并远离最差解。

$$\hat{X}_i = X_i + r_1(X_i^* - X_i) - r_2(X_i - X_i^*), \quad r_1, r_2 \in [0, 1]. \quad (5)$$

其中, 变量 X_i 更新为 \hat{X}_i 。第 i 次迭代中的最佳解和最差解分别用 X_i^* 和 X_i^{\dagger} 表示。 r_1 和 r_2 是随机变量。在原始解决方案中添加项 $r_1(X_i^* - X_i)$ 会使更新后的解决方案趋近于最佳解决方案, 而从原始解决方案中减去项 $r_2(X_i - X_i^{\dagger})$ 会使更新后的解决方案远离最差的解决方案。

步骤 4 对于每个候选解, 比较其更新后的目标函数值和原始的目标函数值。如果更新后的目标函数值更优 (即 F1 分数更高), 则保留更新后的候选解作为下一次迭代的输入; 否则, 保留原始候选解, 如式 (6) 所示

$$X_{i+1} = \begin{cases} \hat{X}_i, & \text{if } f(\hat{X}_i) > f(X_i); \\ X_i, & \text{otherwise.} \end{cases} \quad (6)$$

步骤 5 重复步骤 2~4, 进行多次迭代, 直到达到预设的最大迭代次数。在迭代结束后, 选择目标函数值最好的候选解作为最终的 RUSBoost 分类器超参数设置。

Jaya 优化算法在执行上展现出其简洁与高效的特点, 特别是在与其他如差分进化等优化技术相比时, 其优势尤为明显。Jaya 算法使用的参数较少, 这意味着在应用该算法时无需进行复杂的参数调整, 从而简化了整个优化过程。同时, 较少的参数也降低了过拟合的风险, 提高了算法的泛化能力。其次, Jaya 算法的更新机制是其高效性的关键。在算法的每一次迭代中, 候选解并不是简单地根据随机扰动或差分信息来更新, 而是根据当前种群中的最佳解来指导其进化方向。具体来说, 每个候选解都会向最佳解靠拢, 同时避免陷入最差解的区域。这种机制确保了整个种群在迭代过程中不断向更优的解空间逼近, 从而提高了找到全局最优解的可能性。Jaya 算法还具备较好的鲁棒性和适应性。由于其更新机制不依赖于具体的优化问题或领域知识, 因此可以较为灵活地应用于各种优化问题中。

4 实例分析

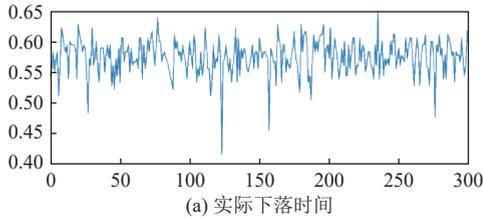
4.1 数据来源与描述

本文的实验数据来源于某轿车厂车身车间 2023 年前 3 个月的螺柱焊枪监测数据。所使用的焊枪包括“++ST330+IR001.CP001”“++ST330+IR002.CP001”“++ST350+IR001.CP001”“++ST420+IR003.CP001”“++ST520+IR002.CP001”共 5 个型号, 广泛应用于

车身焊接环节。数据主要包括“焊枪传感器数据”和“焊枪故障信息数据”。其中，“焊枪传感器数据”记录了焊接时刻焊枪传感器的状态信息，包括下落时间、焊接电压、焊接电流等数值特征的实际值、最大值和最小值，以及焊接模式等类别特征，共计 600 万条记录。而“焊枪故障信息数据”则记录了焊枪故障的相关信息，包括故障发生时间、故障持续时间和故障类型等，共计 8 万余条记录。焊枪传感器数据特征如表 1 所示。

为观察特征的变化规律，本文绘制了特征折线图。以“++ST330+IR001.CP001”号焊枪传感器数据为例，绘制其部分代表性特征前 300 条数据的特征折线图如图 4 所示。

从图 4 中可以看出，实际提升高度展示了明显的周期性变化，下落时间上限在最大值和最小值之间波动。此外，参数还包括一些恒定不变的最大值、最小值以及参考值，这些都是工艺设定的固定



数据字段	描述
dropTimeActual	实际下落时间
dropVoltage	下落电压
liftHeightActual	实际提升高度
mainWeldcurrentVoltageActual	实际焊接电压
penetrationActual	实际熔深
stickOutActual	实际伸出值
weldEnergyActual	实际焊接能量
weldcurrentActual	实际焊接电流
toolWeldcounter	焊接计数 (焊枪)
...	...
weldtimeActual	实际焊接时间

参数。一些计数特征如出口焊接次数、系统焊接次数和工具焊接次数，表现出递增的趋势，反映了焊接活动的累积情况。

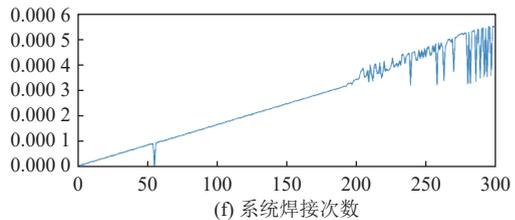
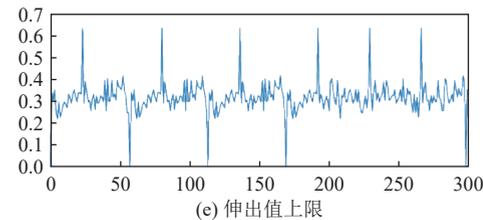
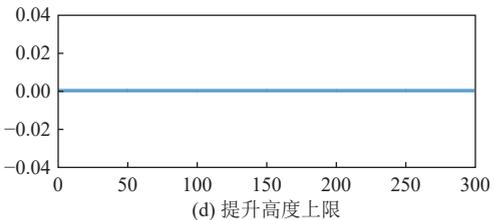
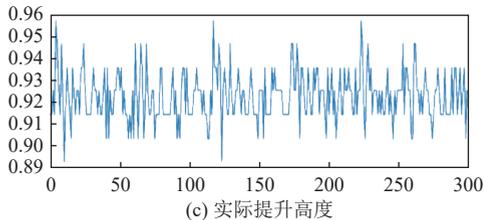
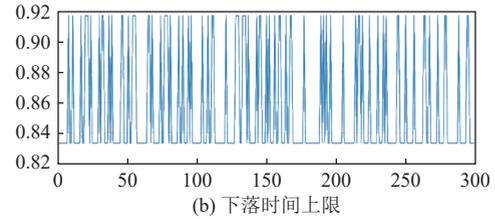


图 4 焊枪传感器数据特征折线图

Figure 4 Line chart of sensor data features for the welding gun

此外，焊枪故障类型主要包括 5 种类型，如表 2 所示。在此基础上，进一步统计了不同焊枪的故障数量，并分析了数据的不平衡性，如表 3 所示。

由表 3 中可知，不同焊枪的故障数量分布存在显著差异。例如，焊枪“++ST330+IR002.CP001”的

故障数量高达 190 次，而“++ST520+IR002.CP001”的故障数量为 45 次。这种不平衡性可能会对故障诊断模型的训练和性能产生影响，可能对高频故障过度拟合，而对低频故障识别不足。因此，在后续的故障诊断研究中，需要特别关注数据不平衡问题

表 2 焊枪故障类型

Table 2 Welding Gun Fault Type

故障数量	故障类型
17 009	Weld Tool: Weld tool not in R position
20 004	SOW not reset
21 051	DCPU-PM: Wrong stud length (stickout)
16 346	Weld tool: Wrong stud length (variable stud block)
16 352	TR: Pickup station 1: rotation segment not in loading position

表 3 焊枪故障统计

Table 3 Welding Gun Fault Statistics

焊枪编号	型号 (toolType)	传感器 数据条数	故障信息 数据条数	故障数量
++ST520+IR002.CP001	TR 610	92 521	299	45
++ST420+IR003.CP001	TH 519	291 357	793	95
++ST330+IR001.CP001	TH 510	325 023	437	159
++ST330+IR002.CP001	TH 510	215 408	333	190
++ST350+IR001.CP001	TH 510	370 914	583	124

以提高模型对不同故障的识别能力和泛化性能。

4.2 实验设计

实验旨在通过 Jaya 优化算法对 RUSBoost 模型进行参数调优, 以提高故障预测的效果。研究主要关注两个核心参数: 弱学习器的数量 (即迭代次数) 和弱学习器决策树的最大深度。

实验的第一阶段, 设计实验评估模型性能随参数变化的情况, 确定了这些参数的较优取值范围。实验的第二阶段, 在模型训练过程中, 利用验证集来调整 Jaya-RUSBoost 模型的超参数 (如弱学习器数量、学习率等)。考虑到故障预测问题本质上属于不平衡分类问题, 单独使用准确率容易被多数类主导, 忽略了少数类 (故障类) 的识别效果。而 F1 值兼顾了精确率与召回率, 能更全面反映模型对少数类的识别能力, 因此选择 F1 值作为目标函数。具体来说, 将验证集的 F1 值作为优化目标, 通过 Jaya 优化算法来搜索最优的超参数组合, 使得模型能够找到在验证集上表现最佳的参数设置, 从而提高模型的泛化能力。

最后, 在模型评估阶段使用独立的测试集来评估模型的泛化能力。测试集在模型的整个训练和优化过程中保持不可见, 从而能够客观地反映模型在新数据上的表现。通过对比测试集上的性能指标, 可以全面评估模型的性能, 并为模型的部署和应用提供可靠的依据。

4.3 数据预处理

为了准确预测焊枪故障, 关键的一步是选择和构建能够真实反映焊枪运行状态的传感器特征。首先, 结合焊枪的工作原理与企业工程师的实际经验, 选取下落时间、焊接电压、焊接电流等多个关键数值特征作为初步特征集, 这些指标能够较为全面地反映焊枪在焊接过程中的动态变化。

在此基础上, 本文特别关注能够体现焊枪工作是否异常的衍生特征。根据案例企业的反馈, 选取了实际采集值与焊枪实时参考上下限之间的差值作为衡量指标, 以揭示参数是否超出合理范围。例如, 实际焊接能量与参考最大值之间的差值可反映其是否接近过载状态, 而与最小值的差值则有助于判断是否处于异常的低能量状态。

在数据匹配方面, 由于传感器数据的采集频率远高于故障信息, 二者难以直接对齐。为此, 本文将每小时内的传感器数据进行汇总, 并从中提取峰值、均值、方差等时域统计特征, 该策略已在多个机械故障检测研究中得到应用与验证^[20], 在处理高频传感器数据与低频故障事件时, 具有良好的信息压缩与状态刻画能力。该方式也便于与后续故障标签进行匹配。此外, 为消除不同特征间的量纲不一致与数值幅度差异, 对所有特征进行了归一化与标准化处理, 以提升后续建模的稳定性与训练效果。

在构建预测标签时, 设定以整点时间为基准的未来时间窗口 (分别为 12~24 h 与 24~36 h), 并在每个窗口内查找是否存在对应的故障事件。若匹配成功, 则提取对应的故障编号, 并通过设定的映射函数生成标签, 最终将提取的特征与标签进行连接, 构建出适用于模型训练的数据集。

4.4 结果分析

4.4.1 弱学习器数量对模型性能影响

为了探讨弱学习器数量 (迭代次数) 对模型性能的影响, 实验训练并验证了迭代次数在 25~425 范围内的模型, 并通过折线图展示了不同迭代次数对 5 种焊枪模型平均 F1 分数的影响。图 5 中的 x 轴表示弱学习器数量 (迭代次数) 的数量, y 轴表示平均 F1 分数。

当弱学习器数量达到一定阈值后, 大多数焊枪型号的平均 F1 分数开始下降, 表明过多的弱学习器可能导致模型过拟合。不同焊枪型号在达到峰值时的弱学习器数量和 F1 分数有所不同, 说明针对

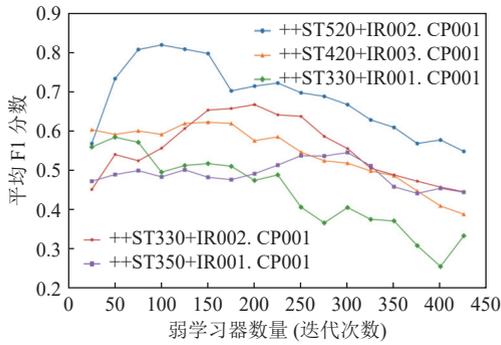


图5 弱学习器数量与 F1 值折线图

Figure 5 Line chart of number of weak learners versus F1 value

不同焊枪型号，可能需要不同的弱学习器数量设置以达到最佳性能。因此，将弱学习器迭代次数的优化范围设置为 0~400，以覆盖所有焊枪预测性能的最大值和可能的最优范围。

4.4.2 弱学习器最大深度对模型性能影响

为了探讨弱学习器最大深度对模型性能的影响，实验训练并验证了最大深度在 1~20 范围内的模型，并通过图 6 所示的折线图展示了不同最大深度值对 5 种焊枪模型平均 F1 分数的影响。图 6 中的 x 轴表示最大深度的数量，y 轴表示平均 F1 分数。

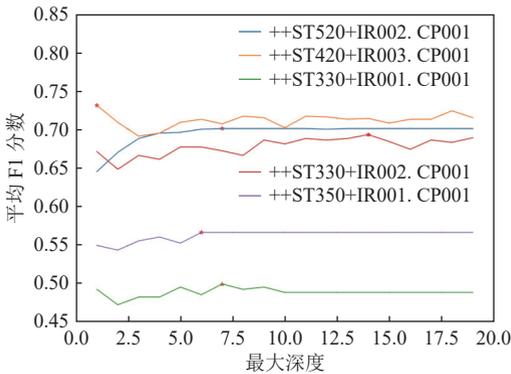


图6 弱学习器最大深度与 F1 值折线图

Figure 6 Line chart of maximum depth of weak learners and F1 score

从图 6 可以看出，随着弱学习器最大深度的增加，F1 值呈现 3 种变化情况：先上升后趋于平稳、先下降后波动趋于平稳、不规则波动后趋于平稳。不同焊枪的变化情况不同，且在最大深度达到 20 时，F1 值不再变化。因此，将弱学习器最大深度的优化范围设为 0~20。

4.4.3 Jaya-RUSBoost 改进算法优化过程

Jaya 算法初始种群数量设定为 100，以最大化 F1 值为优化目标，进行 50 次优化迭代。每次迭代生成一组新的参数配置并计算对应的 F1 分数。若

当前 F1 分数高于已知最佳值，则更新最佳分数和参数配置。以“++ST330+IR002.CP001”焊枪为例，优化过程中验证集 F1 值的变化如图 7 所示。

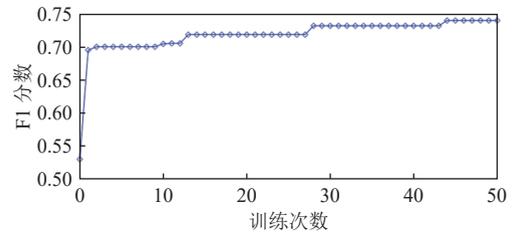


图7 优化过程训练次数与 F1 值的关系

Figure 7 Relationship between training iterations and F1 score during the optimization process

从图 7 中可以看出，F1 值在初次优化时急剧增加，随后呈阶梯式小幅增长，最终从 0.52 增加至 0.74，表明 Jaya-RUSBoost 逐渐收敛到最小损失并趋于稳定。优化后，得到在验证集上 F1 值较高的 RUSBoost 模型。将其应用于测试集并计算 F1 分数，以评估模型的泛化能力。

4.4.4 Jaya-RUSBoost 改进算法的焊枪故障预测结果

使用 Jaya 算法对 5 个焊枪在两个预测时段的模型进行优化调参。调参前后的准确率与 F1 值如表 4 所示。结果表明，所有模型评价指标均有提升，尤其是预测设备“++ST520+IR002.CP001”故障的能力显著提高，准确率和 F1 值的提升分别达到了 29.15% 和 24.97%。

为了进一步评估 Jaya-RUSBoost 模型的性能，本文将其与多种机器学习模型进行了对比，包括 EasyEnsemble、BalancedRandomForest 等集成学习模型，以及在原始数据集进行平衡处理后使用 SVM、XGBoost 和 AdaBoost 等算法的模型。出于实际意义的考虑，针对每个设备，分别计算其在 12~24 h 和 24~36 h 内的准确率、精确率、召回率和加权 F1 值。然后，将 12~24 h 的各项指标乘以 0.4，24~36 h 的各项指标乘以 0.6，再将两者相加，得到最终的设备评分。对于给定的 5 个设备，计算每个设备的评分，再求和并除以 5，得到综合评分。这个评分综合了两次预测 (12~24 h 和 24~36 h) 的各项指标，结果如表 5 所示。

从表 5 的结果可以看出，Jaya-RUSBoost 模型在所有评估指标中均表现出色，尤其是在准确率和 F1 值方面。具体来说，Jaya-RUSBoost 模型的准确率达到 0.652，高于其他模型，如 Smote-SVM 的 0.422 和 BalancedRandomForest 的 0.444。这表明

表 4 优化前后模型性能对比

Table 4 Comparison of model performance before and after optimisation

设备名称	原始 RUSBoost		Jaya-RUSBoost		提升效果	
	准确率	F1 值	准确率	F1 值	准确率提升	F1 值提升
++ST520+IR002.CP001-12_to_24	0.736	0.742	0.951	0.927	29.15%	24.97%
++ST520+IR002.CP001-24_to_36	0.796	0.915	0.990	0.995	24.37%	8.73%
++ST420+IR003.CP001-12_to_24	0.624	0.636	0.639	0.642	2.34%	1.05%
++ST420+IR003.CP001-24_to_36	0.699	0.667	0.673	0.674	-3.78%	1.08%
++ST330+IR001.CP001-12_to_24	0.539	0.525	0.550	0.560	1.95%	6.73%
++ST330+IR001.CP001-24_to_36	0.510	0.540	0.524	0.549	2.71%	1.76%
++ST330+IR002.CP001-12_to_24	0.563	0.597	0.605	0.628	7.55%	5.06%
++ST330+IR002.CP001-24_to_36	0.524	0.546	0.577	0.598	10.00%	9.47%
++ST350+IR001.CP001-12_to_24	0.459	0.551	0.602	0.594	31.10%	7.71%
++ST350+IR001.CP001-24_to_36	0.540	0.469	0.505	0.528	-6.43%	12.51%
平均	0.596	0.617	0.652	0.669	9.43%	8.41%

表 5 各模型预测结果对比

Table 5 Comparison of model predictions

模型	准确率	精确率	召回率	加权 F1 值
Smote-SVM	0.422	0.575	0.422	0.345
Adasyn-SVM	0.415	0.578	0.415	0.336
RandomUnderSampler-SVM	0.430	0.565	0.430	0.350
Smote-XGBoost	0.534	0.550	0.534	0.514
Adasyn-XGBoost	0.544	0.566	0.544	0.527
BorderlineSMOTE-XGBoost	0.521	0.542	0.521	0.503
RandomUnderSampler-XGBoost	0.501	0.651	0.501	0.489
Smote-AdaBoost	0.595	0.573	0.595	0.530
Adasyn-AdaBoost	0.591	0.610	0.591	0.519
BorderlineSMOTE-AdaBoost	0.582	0.590	0.582	0.510
RandomUnderSampler-AdaBoost	0.537	0.585	0.537	0.531
EasyEnsemble	0.493	0.660	0.493	0.513
BalancedRandomForest	0.444	0.658	0.444	0.480
RUSBoost	0.596	0.645	0.596	0.617
Jaya-RUSBoost	0.652	0.710	0.635	0.669

Jaya-RUSBoost 模型在处理不平衡数据集时具有更高的分类准确性。

此外, Jaya-RUSBoost 模型的加权 F1 值达到了 0.669, 同样高于其他模型, 如 Adasyn-SVM 的 0.336 和 RandomUnderSampler-XGBoost 的 0.489。这表明 Jaya-RUSBoost 模型在平衡精确率和召回率方面表现更为优异, 能够更好地捕捉到少数类样本。

综上所述, Jaya-RUSBoost 模型在各项评估指标上均表现优异, 优于其他对比模型, 展示了其在不平衡数据集分类任务中的强大性能。

5 基于 SHAP 可解释机器学习的故障原因分析

在焊枪故障预测的研究中, 为了深入理解模型的预测机制, 并揭示导致焊枪故障的关键原因, 本文采用了 SHAP(SHapley Additive exPlanations) 这一可解释机器学习工具。SHAP 是一种基于博弈论的方法, 它通过将特征的贡献值分解为加法形式, 为每一个特征分配一个 SHAP 值, 从而量化每个特征对模型预测结果的贡献。通过创建 shap.KernelExplainer 对象, 并传入模型预测函数和训练数据, 本文构建了一个 SHAP 解释器。

在获取了每个样本的 SHAP 值后, 可使用 shap.summary_plot(特征重要性汇总图) 来可视化这些结果。该图提供了一个全局视角, 展示了不同特征对模型预测结果的影响大小。特征按照它们对模型预测结果的总影响(即 SHAP 值的绝对值之和)进行排序。以“++ST330+IR002.CP001”焊枪为例, 其特征重要性汇总图如图 8 所示。

通过观察特征重要性汇总图, 可以迅速识别出对焊枪故障预测贡献最大的特征及其影响。从图 8 中可以看出, stickoutactual_mean 即实际伸出值均值对模型预测结果的总影响最大, 伸出值多项指标也均对模型预测结果有较大影响, 而实际下落时间均值、实际提升高度均值也对模型结果影响较为显著, 因 5 种故障均属机械故障, 以上结果较为符合认知。

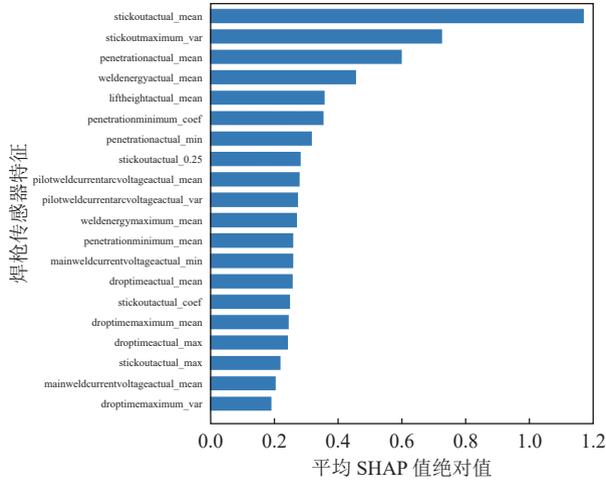


图 8 特征重要性汇总图

Figure 8 Summary of feature importance

为了进一步理解单个样本的预测过程，使用瀑布图 (也称为 SHAP Force Plot) 对模型的预测结果进行解释。瀑布图以垂直堆叠的方式展示了每个特征的 SHAP 值，从基线预测值开始，按照特征对预测结果的贡献大小，逐步向上或向下添加 (正值) 或减去 (负值) 相应的 SHAP 值，最终得到模型的预测结果。这种方式直观地展现了每个特征如何逐步推动预测结果的变化。图 9 以“++ST330+IR002.CP001”焊枪的第一个测试样本为例，展示了其各个特征的 SHAP 值及其对预测结果的贡献。

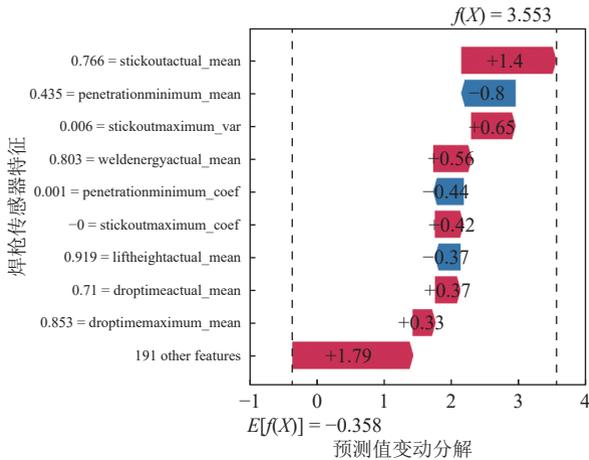


图 9 SHAP 瀑布图

Figure 9 SHAP force plot

在图 9 所示的瀑布图中，从底部开始，首先有一个基线值-0.358(即 $E[f(x)]$)，这是模型预测的平均值，其中可以看出 stickoutactual_mean 对模型的预测结果有 1.4 单位的正向影响，renetrationminimum_mean 对模型的预测结果有 0.80 单位的负向影响，

总体特征正向多于负向，模型预测值高于基线值，说明模型预测结果倾向于焊枪是故障的。

此外，本文还绘制了如图 10 所示的蜂群图 (beeswarm plot)，用于展示所有样本的 SHAP 值在不同特征上的分布情况。蜂群图以直观的方式呈现了数据点的分布密度和位置，能够提供不同特征对模型输出影响的整体趋势和个体差异。在焊枪故障预测的研究中，蜂群图有助于识别出可能导致故障的关键特征组合和条件。

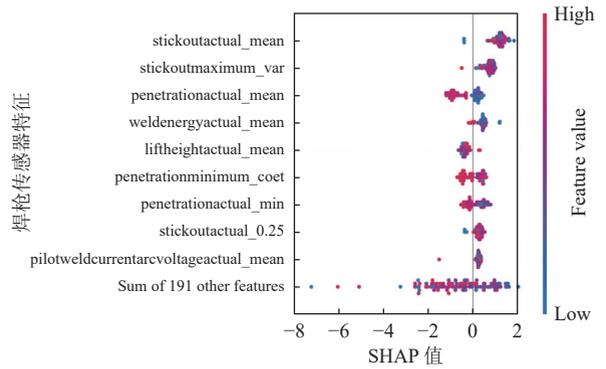


图 10 SHAP 蜂群图

Figure 10 SHAP beeswarm plot

如图 10 所示，粉色的点表示特征值较高，蓝色的点表示特征值较低。在 stickoutactual_mean 特征中，较高值大多集中在基线右侧，说明较高的 stickoutactual_mean 能够增加预测结果 (即故障发生的概率)。这种分布表明，当 stickoutactual_mean 值较高时，焊枪发生故障的可能性更大。

对于 penetrationactual_mean 特征，较高值和较低值的分布较为均匀，说明该特征对预测结果的影响较为中性，没有明显的趋势。这意味着 penetrationactual_mean 的变化对故障预测的贡献较小，可能不是主要的影响因素。在 weldenergyactual_mean 特征中，较高值大多集中在基线左侧，说明较高的 weldenergyactual_mean 会降低预测结果 (即故障发生的概率)。这表明，当 weldenergyactual_mean 值较高时，焊枪发生故障的可能性较低。

通过这种深入分析，可以更清晰地理解每个特征对预测结果的具体影响，从而指导生产过程中对这些关键特征进行优化和调整。蜂群图直观地展示了每个特征在高值和低值情况下对预测结果的影响，有助于识别出对故障预测最为重要的特征。该方法不仅可以帮助理解模型的决策过程，还可以为生产指标的调整提供有力的依据，确保生产过程更

加稳定和高效。

6 结论

针对焊枪故障预测过程中数据类别分布严重失衡的问题, 本文提出了一种基于 Jaya-RUSBoost 改进算法的故障预测方法。通过结合 RUSBoost 算法的欠采样和提升法, 有效地解决了数据不平衡的问题, 并通过独立采样每个基础学习器的训练集克服了信息丢失问题。与此同时, Jaya 优化算法通过其简洁高效的更新机制, 对 RUSBoost 分类器的超参数进行了优化, 简化了参数调整过程, 并提高了全局最优解的搜索能力。实验结果表明, 与传统的 RUSBoost 算法相比, Jaya-RUSBoost 模型在 5 个焊枪上的故障预测准确率和 F1 值分别平均提升了 9.43% 和 8.41%。在与多种机器学习模型的比较中, Jaya-RUSBoost 模型在准确率、精确率、召回率和 F1 值等关键指标上均表现最佳。此外, 利用 SHAP 值进行了可解释性分析, 直观展示了各特征对预测结果的贡献, 这些发现有助于深入理解焊枪故障的内在原因, 增强了模型的透明度和可信度。

综上所述, 本文提出的基于改进 Jaya-RUSBoost 的焊枪故障预测方法不仅有效应对了数据不平衡的挑战, 还通过优化超参数显著提高了预测模型的性能。此方法能够较为准确地预测焊接设备的故障, 从而减少因设备故障导致的停工损失, 同时有效延长设备的使用寿命, 提升生产线的稳定性和整体效率。因此, 本方法具有较高的实际应用价值和推广前景, 为智能制造领域的企业提供可靠的焊接设备智能维护解决方案, 为实现更高效、更稳定的生产运营提供有力支持。

参考文献:

[1] 袁焯, 张永, 丁汉. 工业人工智能的关键技术及其在预测性维护中的应用现状[J]. 自动化学报, 2020, 46(10): 2013-2030.
YUAN Ye, ZHANG Yong, DING Han. Research on key technology of industrial artificial intelligence and its application in predictive maintenance[J]. Acta Automatica Sinica, 2020, 46(10): 2013-2030.

[2] 滕飞. 螺柱焊系统的故障分析及预防措施研究[J]. 现代制造技术与装备, 2018, 54(4): 58-59.
TENG Fei. Studying the failure analysis and preventive measures of stud welding system[J]. Modern Manufacturing Technology and Equipment, 2018, 54(4): 58-59.

[3] WANG X Y, ZHANG C S, WANG T. Benchmark for welding

Gun fault prediction with multivariate time series data[J]. Scientific Data, 2024, 11: 83.

[4] ZHOU N, WEI H F, JIANG H Y, et al. Fatigue crack propagation model and life prediction for pantographs on High-Speed trains under different service environments[J]. Engineering Failure Analysis, 2023, 149: 107065.

[5] 蒋文博, 胡澜也, 宋斐, 等. 基于比例风险模型与机器学习混合方法的电梯故障预测[J]. 工业工程与管理, 2021, 26(4): 19-27.
JIANG Wenbo, HU Lanye, SONG Fei, et al. Hybrid method based on proportional hazards model and machine learning for failure prediction of elevators[J]. Industrial Engineering and Management, 2021, 26(4): 19-27.

[6] 杨述明, 吴建军, 谢昌霖, 等. 数据驱动智能故障诊断技术在液体火箭发动机中的应用与展望[J/OL]. 航空学报, 2025: 1-22. (2025-03-07). <http://kns.cnki.net/kcms/detail/11.1929.V.20250306.1410.006.html>.
YANG Shuming, WU Jianjun, XIE Changlin, et al. Application issues of data-driven intelligent fault diagnosis technologies for liquid rocket engines[J/OL]. Acta Aeronautica et Astronautica Sinica, 2025: 1-22. (2025-03-07). <http://kns.cnki.net/kcms/detail/11.1929.V.20250306.1410.006.html>

[7] LIU J, HOU B C, LU M, et al. Box-Cox transformation based state-space modeling as a unified prognostic framework for degradation linearization and RUL prediction enhancement[J]. Reliability Engineering & System Safety, 2024, 244: 109952.

[8] TA Y T, LI Y F, CAI W A, et al. Adaptive staged remaining useful life prediction method based on multi-sensor and multi-feature fusion[J]. Reliability Engineering & System Safety, 2023, 231: 109033.

[9] 李天梅, 司小胜, 张建勋. 多源传感监测线性退化设备数模联动的剩余寿命预测方法[J]. 航空学报, 2023, 44(8): 227190.
LI Tianmei, SI Xiaosheng, ZHANG Jianxun. Data-model interactive remaining useful life prediction method for multi-sensor monitored linear stochastic degrading devices[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(8): 227190.

[10] 谢本凯, 蔡水涌, 黄春雷, 等. 基于 OC-SVM 与 DNN 相结合的 ZPW-2000R 轨道电路故障诊断研究[J]. 工业工程, 2023, 26(4): 154-163.
XIE Benkai, CAI Shuiyong, HUANG Chunlei, et al. Fault diagnosis of ZPW-2000R track circuits based on OC-SVM and DNN[J]. Industrial Engineering Journal, 2023, 26(4): 154-163.

[11] BAI G L, SUN W, CAO C, et al. GAN-based bearing fault diagnosis method for short and imbalanced vibration signal[J]. IEEE Sensors Journal, 2024, 24(2): 1894-1904.

[12] 刘华开, 丁康, 何国林, 等. 联合故障机理和卷积神经网络的齿轮剩余使用寿命预测方法研究[J]. 机械工程学报, 2024, 60(12): 116-125.
LIU Huakai, DING Kang, HE Guolin, et al. Research on the prediction method of remaining useful life of gears by combining fault mechanism and convolutional neural network[J]. Journal of Mechanical Engineering, 2024, 60(12): 116-125.

- [13] GAO C, WANG Z K, GUO Y J, et al. MPINet: Multiscale physics-informed network for bearing fault diagnosis with small samples[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(12): 14371-14380.
- [14] WANG Y Z, LI Z F, CHEN H X, et al. Research on diagnostic strategy for faults in VRF air conditioning system using hybrid data mining methods[J]. *Energy and Buildings*, 2021, 247: 111144.
- [15] 李敏波, 董伟伟. 面向不平衡数据集的汽车零部件质量预测[J]. *中国机械工程*, 2022, 33(1): 88-96.
LI Minbo, DONG Weiwei. Quality prediction of automotive parts for imbalanced datasets[J]. *China Mechanical Engineering*, 2022, 33(1): 88-96.
- [16] 李新鹏, 高欣, 何杨, 等. 不平衡数据集下基于自适应加权 Bagging-GBDT 算法的磁盘故障预测模型[J]. *微电子学与计算机*, 2020, 37(3): 14-19.
LI Xinpeng, GAO Xin, HE Yang, et al. Prediction model of disk failure based on adaptive weighted bagging-GBDT algorithm under imbalanced dataset[J]. *Microelectronics & Computer*, 2020, 37(3): 14-19.
- [17] 范敏, 杨青, 郭祥富, 等. 面向不平衡数据的配电网故障停电预测方法[J]. *电力系统保护与控制*, 2023, 51(8): 96-106.
FAN Min, YANG Qing, GUO Xiangfu, et al. Prediction method of power outage in a distribution network for unbalanced data[J]. *Power System Protection and Control*, 2023, 51(8): 96-106.
- [18] SEIFFERT C, KHOSHGOFTAAR T M, VAN HULSE J, et al. RUSBoost: A hybrid approach to alleviating class imbalance[J]. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 2010, 40(1): 185-197.
- [19] VENKATA RAO R. Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems[J]. *International Journal of Industrial Engineering Computations*, 2016: 19-34.
- [20] 袁锐炜, 陈兆祥, 卫宇杰, 等. 基于改进 Stacking 与 D-S 证据理论的两阶段多源信息融合轴承故障诊断[J/OL]. *工业工程*, 2025: 1-12. (2025-01-14). <http://kns.cnki.net/kcms/detail/44.1429.TH.20250113.1902.002.html>.
YUAN Ruiwei, CHEN Zhaoxiang, WEI Yujie, et al. Bearing fault diagnosis with two-stage multi-source information fusion based on improved stacking algorithm and D-S evidence theory[J/OL]. *Industrial Engineering Journal*, 2025: 1-12. (2025-01-14). <http://kns.cnki.net/kcms/detail/44.1429.TH.20250113.1902.002.html>.

(责任编辑: 孟晓燕)