

引用格式: 李卓汉, 有移亮, 赵子华, 等. 人工智能技术在失效分析领域的应用[J]. 航空材料学报, 2024, 44(5): 1-16.

LI Zhuohan, YOU Yiliang, ZHAO Zihua, et al. Application of artificial intelligence technology in failure analysis[J]. Journal of Aeronautical Materials, 2024, 44(5): 1-16.

人工智能技术在失效分析领域的应用

李卓汉, 有移亮*, 赵子华, 骆红云, 吴素君, 张 峥, 钟群鹏

(北京航空航天大学 材料科学与工程学院, 北京 100191)

摘要: 本文探讨了人工智能技术, 尤其是机器学习和自然语言处理技术在失效分析领域的应用与发展趋势。失效分析是确保设备可靠性和安全性的重要手段, 广泛应用于航空航天、汽车制造、电子设备等领域。传统的失效分析方法通常依赖专家经验, 而人工智能技术凭借其强大的数据处理能力, 与传统方法相结合, 极大地提升了分析的精度和效率。在失效模式诊断方面, 人工智能技术能够快速准确地识别各种故障模式, 并提供精确的诊断结果; 在失效原因诊断中, 人工智能通过整合多种数据来源, 揭示复杂的失效因素和潜在的因果关系, 提升了诊断的可靠性; 在失效预测方面, 机器学习技术能够精确预测材料的寿命和强度, 减少实验时间和成本; 在失效预防方面, 人工智能技术提供了新的思路, 能够有效降低失效发生的风险, 减少产品维护成本。本文还展望了人工智能技术在失效分析领域的发展前景, 提出了在数据质量提升、模型优化、跨学科合作以及伦理与安全等方面的挑战与建议。

关键词: 人工智能; 机器学习; 自然语言处理; 失效分析; 失效诊断; 寿命预测; 失效预防

doi: 10.11868/j.issn.1005-5053.2024.000133

中图分类号: V250.3; TG115

文献标识码: A

文章编号: 1005-5053(2024)05-0001-16

Application of artificial intelligence technology in failure analysis

LI Zhuohan, YOU Yiliang*, ZHAO Zihua, LUO Hongyun, WU Sujun,
ZHANG Zheng, ZHONG Qunpeng

(School of Materials Science and Engineering, Beihang University, Beijing 100191, China)

Abstract: This paper explores the application and development trends of artificial intelligence (AI) technology, particularly machine learning and natural language processing in the field of failure analysis. Failure analysis is a crucial method for ensuring the reliability and safety of equipment, and is widely used in aerospace, automotive manufacturing, electronic devices, and other fields. Traditional failure analysis methods often rely on expert experience, which is time-consuming and laborious. By integrating AI's powerful data processing capabilities with traditional methods, the accuracy and efficiency of analysis have been significantly enhanced. In terms of failure mode diagnosis, AI can rapidly and accurately identify various fault modes and provide precise diagnostic results. In failure cause diagnosis, AI integrates data from multiple sources to uncover complex failure factors and potential causal relationships, improving diagnostic reliability. In failure prediction, machine learning can accurately forecast material lifespan and strength, reducing experimental time and costs. In failure prevention, AI offers new approaches to effectively reduce the risk of failure and lower product maintenance costs. The paper also looks forward the future development prospects of AI in failure analysis and highlights challenges and recommendations in the areas, such as data quality improvement, model optimization, interdisciplinary collaboration, and ethical and safety issues.

Key words: artificial intelligence; machine learning; natural language processing; failure analysis; failure diagnosis; life prediction; failure prevention

失效分析是一种系统化的方法,用于确定产品发生故障的原因。失效分析的目的是解决现有问题并深入探究故障的根本原因以避免类似问题再次发生。失效分析对于提高产品的可靠性和安全性具有重要意义,广泛应用于航空航天、汽车制造、电子设备和医疗器械等多个领域。在航空航天领域,失效分析可以帮助确定飞机零部件在极端环境下的表现,从而提高飞行安全性。在汽车制造

中,失效分析可以识别和解决影响车辆性能和安全的潜在问题。在电子设备中,失效分析有助于发现和修复影响产品寿命和功能的缺陷。在医疗器械中,失效分析能够确保设备在临床应用中的可靠性和安全性,保障患者的健康。然而,传统的失效分析方法往往耗时费力,且对专家经验的依赖性较大^[1-7]。图1为失效分析的程序,由图1可知,失效分析具有一套庞大的工作体系,涉及多个工作领




图1 失效分析程序

Fig. 1 Failure analysis procedure

域,在工业生产、社会发展都具有较大影响,鉴于其复杂性,将人工智能方法引入失效分析具有较强的现实意义。

随着信息技术的迅猛发展,人工智能技术在各个学科领域展现出了巨大的潜力^[8-9]。机器学习作为一种数据驱动的方法,通过从大量数据中学习和提取特征,可以实现预测、分类和识别等任务^[10-11]。它不仅能处理结构化数据,如数值和文本,还能处理非结构化数据,如图像、音频和视频。机器学习算法种类繁多,包括监督学习、无监督学习和强化学习等^[12]。监督学习通过已有标签的数据训练模型,用于分类和回归任务^[13],如故障分类和寿命预测;无监督学习则用于发现数据中的隐藏模式和结构,如聚类分析和异常检测^[14];强化学习通过与环境的交互不断优化决策策略,可以应用于实时监控和动态调整的场景^[15]。此外,还有半监督学习和迁移学习等方法,半监督学习利用少量标注数据和大量未标注数据进行训练,适用于标注数据稀缺的场景^[16];迁移学习通过将在一个领域中学到的知识应用到另一个相关领域中,减少对大量标注数据的需

求,提高模型的适用性和泛化能力^[17]。另外,深度学习作为机器学习的一个分支,通过神经网络模型能够处理更为复杂的数据结构和特征提取任务,已经在图像识别和自然语言处理等领域取得了显著成效^[18]。例如,卷积神经网络(CNN)在图像分类和物体检测中的表现优异,能够准确识别失效模式^[19-20]。递归神经网络(RNN)及其变种如长短期记忆网络(LSTM)在时间序列分析中的应用广泛,可用于预测设备的故障发生时间和趋势^[21-22]。生成对抗网络(GAN)则可以用于生成模拟失效数据,帮助提升模型的鲁棒性^[23-24]。本文综述人工智能技术,特别是机器学习和自然语言处理技术在失效分析领域的应用与发展趋势。

1 常用机器学习算法介绍

在材料设计领域中的机器学习算法各具特点,适用于不同的应用场景。图2列出了失效分析学科中常用的深度学习方法。下面介绍几种常用的算法及其优势、缺点和具体应用范围。




图2 失效分析中常用的机器学习方法

Fig. 2 Commonly used machine learning methods in failure analysis

1.1 监督学习算法

线性回归(linear regression)算法简单易用,能

够快速建立输入和输出之间的线性关系。其优势在于模型解释性强,适用于线性关系明显的材料性

能预测,如弹性模量和硬度,但是线性回归在处理复杂非线性问题时效果不佳^[25]。

支持向量机(support vector machine, SVM)在处理高维数据和小样本数据时表现优异,适用于分类问题,如材料的相结构分类或者相变温度预测。SVM的优势在于其强大的分类能力和良好的泛化性能,但计算复杂度高,参数调优较为困难^[26]。

决策树(decision tree)算法通过树形结构直观展示决策过程,易于理解和解释,适用于识别关键工艺参数和优化材料合成路线。其优势在于处理非线性数据的能力强,但容易过拟合,且对数据噪声敏感^[27]。

随机森林(random forest)通过集成多棵决策树,减少了单棵树过拟合的风险,提高了预测准确性。其优势在于处理复杂问题的能力,适用于预测材料性能和优化成分组合;缺点是训练和预测时间较长,模型难以解释^[28]。

神经网络(neural networks)具有强大的建模能力,能够处理复杂的非线性关系,适用于多变量性能预测,如材料的多种力学性能。其优势在于强大的学习能力,但需要大量数据进行训练,训练时间长且模型难以解释^[29]。

1.2 无监督学习算法

聚类分析(clustering)无需标签数据,通过发现数据中的潜在分组来识别相似的材料组合。其优势在于能够处理大量数据并发现隐藏的模式,适用于发现材料数据中的相似组,如合金成分组合。缺点是结果依赖于聚类算法的选择和参数设定^[30]。

主成分分析(principal component analysis, PCA)通过降维处理,减少数据维度,同时保留主要信息。其优势在于能够简化数据结构,便于后续分析,适用于提取材料数据的主要特征。缺点是PCA假设数据是线性的,限制了其应用范围,且主成分的解释性较差^[31]。

1.3 深度学习算法

卷积神经网络(convolutional neural networks, CNNs)擅长处理图像数据,能够捕捉空间特征,适用于分析显微结构图像和识别材料的微观特性。其优势在于处理图像数据效果显著,但需要大量标注数据,计算资源消耗大^[32-33]。

长短期记忆网络(long short-term memory, LSTM)适合处理时间序列数据,能够捕捉长期依赖关系,适用于预测材料在不同工艺条件下的性能变化。其优势在于能够处理长时间跨度的数据,但结构复杂,训练时间较长^[34-35]。

生成对抗网络(generative adversarial networks, GANs)通过生成高质量的虚拟数据来增强数据集,适用于生成虚拟材料数据,提升模型鲁棒性。其优势在于能够生成逼真的数据,但训练不稳定,难以收敛^[36-37]。

1.4 优化算法

遗传算法(genetic algorithm)遗传算法具有强大的全局搜索能力,适合复杂优化问题,适用于优化材料成分和工艺参数,寻找最优组合。其优势在于能够搜索广泛的解空间,但计算量大,收敛速度较慢^[38]。

贝叶斯优化(Bayesian optimization)通过高效搜索,处理高维优化问题,适用于优化实验设计,提高材料性能。其优势在于能够高效处理复杂的优化问题,但适用于较小的搜索空间,计算复杂度较高^[39]。

将机器学习引入失效分析,不仅可以提高分析的效率和准确性,还能在海量数据中发现传统方法难以察觉的失效模式和规律,为产品设计、制造和维护提供更科学的依据^[40-41]。机器学习强大的数据处理和分析能力能够解决传统失效分析中面临的挑战和瓶颈,包括失效预测、故障诊断、图像分析和数据挖掘等方面^[42]。通过机器学习技术,可以提高故障检测的准确性,减少对专家经验的依赖,提升故障预警能力^[43]。本文通过系统总结现有研究和实际应用案例,介绍了机器学习在失效分析领域四个主题框架的应用现状。图3为该机器学习在失效分析领域的应用概述图。随着数据采集技术和计算能力的不断提升,机器学习在失效分析中的应用前景将更加广阔。

2 失效模式诊断

在高度工业化的现代社会中,各种设备和产品的可靠性与安全性至关重要^[44]。失效模式诊断作为确保设备和产品正常运行的关键环节,对于提高生产效率以及保障人员安全具有重要意义^[45]。随着科技的不断发展和工业生产的日益复杂化,传统的失效模式诊断方法已经难以满足现代大工业时代的需求^[46]。机器学习方法的引进成为提高失效模式诊断准确性和效率的选择之一^[47]。材料失效模式主要包括断裂失效和非断裂失效(图4),这些失效方式对设备的可靠性和安全性构成了重大威胁。断裂失效可以进一步细分为塑性断裂、脆性断裂和塑性-脆性混合型断裂,断裂的路径也可以根




图 3 机器学习在失效分析领域的应用

Fig. 3 Application of machine learning in failure analysis

据其特点被分为穿晶断裂和沿晶断裂,根据断裂的机制,还可以将其分为解理、准解理、韧窝、滑移分离、沿晶及疲劳等类型^[48-49];非断裂失效又可以分为腐蚀失效、磨损失效和变形失效。在航空航天、汽车制造、能源等领域,失效模式诊断都具有至关重要的地位。在航空航天领域,飞机零部件的失效可能会引发严重的安全事故;在汽车制造领域,关键零部件的失效会影响车辆的性能和安全性。因此,准确诊断失效模式并采取相应的预防和修复措施,对于保障生产运行和人员安全至关重要^[50-51]。失效模式的诊断需要综合分析材料的失效类型和特征,以确定根本原因并制定有效的修复方案。因此失效模式诊断需要使用先进的检测技术,如 X 射线衍射(XRD)、扫描电子显微镜(SEM)

和能谱分析(EDS)等,对失效模式的微观机制进行深入分析。现代检测技术的应用,可以帮助工程师更全面地理解失效模式的成因和发展过程。例如,腐蚀失效可以通过电化学测试和腐蚀产物分析进行诊断,而疲劳失效则可以通过分析疲劳裂纹的扩展速率和方向来识别。结合这些检测手段,机器学习技术能够有效地处理和分析大量检测数据,进一步提高失效模式诊断的准确性和效率,为材料和设备的维护提供科学依据^[52-53]。随着人工智能技术的发展,机器学习已经成为材料失效模式诊断中的重要工具之一。将 X 射线衍射(XRD)、扫描电子显微镜(SEM)等现代检测技术获取材料的微观结构数据输入到机器学习模型中,可以准确预测材料在不同工作条件下的表现和失效风险。




图 4 失效模式汇总

Fig. 4 Failure mode summary

曹枝军等^[54]研究了热障涂层在三点弯曲载荷下的失效模式,并使用声发射技术进行实时监测,他们通过 K-means 聚类分析结合声发射参数和微观形貌特征,识别了四种主要失效模式,然后通过 Fourier 变换和小波包变换分析了这些模式的波形

特征。他们的研究采用机器学习方法,以小波能量系数为特征向量,通过反向传播神经网络对失效模式进行了分类。Bastidas 等^[55]在其研究中开发了一种通过深度学习对金属材料的断口进行分类的系统,可识别不同的失效模式。他们使用了两个数

数据集,一个是实际的断裂数据集,另一个是通过扫描电子显微镜(SEM)获得的图像,评估了传统卷积神经网络在这些数据集上的分类性能,并进一步优化了基于自适应小波变换的深度学习架构,这种方法成功提取了断口的纹理特征,为失效模式的识别提供了新的思路 and 手段。Polania 等^[56]也对断口分类进行了研究,他们利用 Haralick 特征、纹理能量法则和分形维度作为描述符,通过人工神经网络和支持向量机对三种断裂类型(脆性断裂、韧性断裂、疲劳断裂)进行分类,研究结果显示,人工神经网络的分类效果优于支持向量机,与专家的判断准确程度相当,他们验证了这些机器学习方法在失效模式识别中的有效性。Yue 等^[57]则在钢纤维增强混凝土的研究中,利用声发射技术和机器学习框架对断裂模式进行分类,以识别混凝土在单轴拉伸下的失效模式,他们通过声发射信号的时频分析,准确预测了裂缝的演化路径,为结构健康监测提供了方法。Das 等^[58]使用无标签的声发射波形特征,设计了一个基于机器学习的框架,通过高斯混合模型和支持向量机对混凝土断裂模式进行分类,验证了机器学习在水泥基复合材料断裂模式识别中的应用。Kabir 等^[59]利用机器学习方法对钢结构中柱底板连接的失效模式进行了鉴定,他们收集了大量实验数据,比较了多种机器学习算法的效果,发现决策树模型在识别失效模式上的准确率达到 91%,在此基础上他们开发了一个开源的机器学习模型,配合易用的图形用户界面,有效地预测连接的失效模式。Saroithi 等^[60]探索了用于预测结构钢中双剪螺栓连接失效模式的机器学习模型,他们通过分析 455 个实验结果,确定了影响失效类型的关键参数,研究表明,RF、CatBoost、XGBoost 和 GB 模型在分类失效模式方面表现出 90%~92% 的准确率,为结构设计提供了新的参考依据。Taffese 等^[61]的研究实现了对超高性能混凝土(UHPC)、加固钢筋混凝土(RC)构件中韧性和脆性失效模式的快速精准分类。他们采用了 Bagging、随机森林、AdaBoost、梯度提升、XGBoost 和 LightGBM 六种集成学习技术,利用包含 14 个特征的综合数据集进行模型训练,最终发现 XGBoost 表现最佳,分类准确率达到 84%。此外他们的研究还采用了 SHAP(shapley additive explanation)技术,分析了不同特征对失效模式的影响,指出抗弯矩和 UHPC 抗拉强度是预测失效模式的关键因素。

以上案例展示了机器学习在材料失效模式识别中的广泛应用,以及如何利用先进的算法提升失

效模式诊断的精度和效率。机器学习技术的引入有效地应对了复杂的失效模式识别挑战,还减少了对专家知识的依赖。机器学习模型通过对复杂数据模式的深度学习和特征提取,增强了对断裂、磨损、腐蚀等失效现象的识别能力,这些技术的发展和运用必将为材料的服役可靠性提供新的保障,进一步推动现代工业可靠性的发展。

3 失效原因诊断

随着现代装备的先进性和复杂性的不断提升,失效原因诊断的困难性和重要性日益凸显。失效原因诊断不仅是为了识别失效现象,更重要的是通过系统的分析和推断,找出导致失效的根本原因,并制定有效的预防和纠正措施。为了应对现代工业中不断增加的复杂性,人工智能技术,例如机器学习和自然语言处理(NLP),为失效原因诊断提供了有效手段^[62-63]。通过收集和分析设备运行数据、环境数据和材料数据,机器学习技术能够识别出异常模式和潜在的失效风险,并结合传统的失效分析方法,提升诊断的全面性和可靠性。此外,NLP 技术通过对大量事故报告和失效分析文档的文本挖掘,能够提取出隐藏的因果关系和模式。可以认为,人工智能技术的引入大幅提高了失效原因诊断效率和准确性。

Zheng 等^[64]提出了一种基于物理信息的机器学习模型,用于在复杂加载条件下模拟脆性材料的裂纹扩展,以便更准确地诊断材料失效的根本原因,他们的模型通过物理信息神经网络(PINN)重构损伤后的位移场,预测裂纹的扩展,为分析失效原因提供依据。Velásquez 等^[65]则利用机器学习改进了电力变压器的失效原因分析,他们通过智能遗传算法调优人工神经网络(ANN)分类器,结合溶解气体分析(DGA)样本,实现了高精度的失效原因分类。Zheng 等^[66]运用机器学习对双相钢在不同应力状态下的延性断裂表面进行了分类,通过预训练的卷积神经网络提取图像特征,并使用主成分分析(PCA)进行降维,再通过 K-Means 和 K-最近邻算法进行图像聚类 and 分类,帮助准确识别材料断裂表面的特征,从而通过断裂表面分析失效原因。Schmies 等^[67]结合深度学习和拓扑数据分析,提出了一种对断裂特征和机制进行分类的方法,通过光学图像和二维图像的综合分析,利用深度学习算法对断裂特征进行评估,并与断裂图谱数据库信息关联,从而提高了断裂特征识别的精度

和自动化程度,强化了失效机制的诊断。Zhang等^[68]提出了一种基于机器学习的金属延性断裂表面定量分析方法,利用卷积神经网络对断裂表面图像进行分类,并通过图像分割提取断裂表面的特征,训练回归模型以预测材料的力学性能,为失效原因分析提供了量化支持。Li等^[69]则提出了一种融合图像数据和物理数据的单晶疲劳寿命预测方法,通过从断裂图像中推断服役条件和材料固有特性,利用机器学习技术对单晶疲劳寿命进行预测,从而为复杂条件下的合金失效原因诊断提供了可靠依据。

Liu等^[70]的研究展示了如何利用自然语言处理(NLP)和文本挖掘技术来识别管道事故的因果关系和影响因素,他们在处理大量非结构化的事故叙述文本数据时,成功应用了K-means聚类和共现网络分析等技术,揭示了事故背后的复杂因果关系与模式,这一研究为事故分析提供了新视角,说明NLP技术在处理大规模文本数据以提取有价值信息方面具有强大潜力。Chokor等^[71]进一步探索了无监督机器学习与NLP在建筑事故报告中的应用,他们通过对OSHA历史事件的文本数据进行聚类分析,成功地将事故分类为不同的类型,这种数据驱动的方法不仅提升了事故报告的处理效率,还帮助地方机构根据当地法规和环境条件定制更适用的安全标准。Goh等^[72]则评估了多种机器学习算法在分类建筑事故叙述中的表现,他们发现支持向量机(SVM)在处理和分类大量事故报告时表现最佳,有效提升了事故预防和安全管理的效果,这一研究展现了NLP和机器学习技术在自动化处理和分析大量事故报告中的重要作用。Halim等^[73]通过对多个管道事故数据库的综合分析,开发了一种基于因果模型的分析方法,利用大数据和人工智能技术揭示了不同因素之间的复杂关系。他们的研究表明,通过对背景因素、潜在因素和因果因素的深入分析,能够更准确地预测未来的失效风险,为管道系统的维护和安全管理提供了科学依据。此外,Nakata^[74]通过文本挖掘技术,从大量工业事故报告中提取出典型的事件发展流程,他们开发的系统能够识别出事件的前后关系,揭示事故发生的典型路径,这为理解事故的根本原因和发展过程提供了新的方法。NLP技术在失效原因诊断方面的应用,不仅提高了事故报告分析的深度,还为未来的事故预防策略制定提供了重要参考。这些研究共同表明,人工智能技术,特别是自然语言处理和机器学习,在失效原因分析中展现出巨大的应用

潜力。

人工智能技术通过先进的图像识别、模式分类以及文本挖掘技术,提高了失效原因诊断的准确性和效率。通过结合X射线衍射(XRD)和扫描电子显微镜(SEM)等成像技术与机器学习模型,研究材料在微观结构级别上的变化,并成功预测其在不同载荷和环境条件下的行为。同时,利用NLP技术分析大量事故报告,揭示了潜在的因果关系和模式。这些案例研究表明,人工智能技术不仅能够帮助材料科学家和工程师更有效地识别和分析材料的潜在失效原因,还能自动化分析、优化材料的设计、加工工艺和服役条件。

4 失效预测

在工业生产制造过程中,设备和材料在长期使用过程中会受到机械应力、高温、化学腐蚀等多种因素的影响,导致其性能逐渐退化甚至失效。失效预测是避免突发故障和重大事故的重要手段之一,其内容广泛,包括失效模式、寿命和强度的预测。失效模式预测主要是通过分析材料和结构在不同应力条件下的失效方式,识别潜在的失效类型,并制定相应的预防措施^[75]。寿命预测主要包括疲劳寿命、蠕变寿命和腐蚀寿命三大方面^[76]。疲劳寿命预测可以估算材料在循环应力作用下的耐久性,是航空航天、汽车制造和风力发电等领域的关键^[77];蠕变寿命预测则评估材料在高温和恒定应力下的变形和寿命,广泛应用于电力、化工和航空发动机等高温环境^[78];腐蚀寿命预测则针对材料在化学或电化学环境中的耐久性,确保海洋工程、石油化工和核能领域设备的安全性^[79]。此外,强度预测作为评估材料和结构在实际工况下承载能力的重要方法,对于土木工程、桥梁建设和高层建筑等领域至关重要^[80]。

Liu等^[81]提出了一种基于注意力机制的深度神经网络,用于预测嵌入皱纹纤维增强复合材料的力学性能和失效模式。他们通过注意力机制增强模型对关键特征的捕捉能力,并成功预测了复合材料在复杂载荷下的失效模式,特别是在预测裂纹扩展路径和局部失效区域方面表现出色,最终的预测结果与实验数据高度一致。颜秀文等^[82]提出了一种基于多层感知机(MLP)的失效模式预测方法,采集了生产线传感器数据并通过MLP模型进行训练,有效预测了生产线设备的失效模式,提升了设备的可靠性和稳定性。马高等^[83]基于机器学习方

法对钢管混凝土剪力墙的破坏模式进行了预测,使用 SMOTE 算法平衡不均衡数据,并结合随机森林和 XGBoost 等模型,成功预测了剪切破坏、弯曲破坏和弯剪破坏的模式,随后还通过 SHAP 法对特征参数的影响进行了分析。Taher 等^[84]研究了淬火分区不锈钢电阻点焊接头的失效模式,利用有限元模型结合数字图像相关技术(DIC)准确预测了不同电流条件下的界面破坏和部分界面破坏模式,研究为汽车结构安全性提供了重要参考。Mangalathu 等^[85]使用多种机器学习算法对钢筋混凝土梁柱节点的失效模式进行了分类和预测,模型成功预测了剪切失效和弯剪失效模式,随机森林算法在剪切失效预测中表现最佳,预测结果与实验数据高度一致。

Bao 等^[86]提出了一种基于机器学习来预测选择性激光熔融 Ti-6Al-4 V 合金疲劳寿命的方法,他们在研究中使用支持向量机(SVM)模型分析缺陷位置、大小和形态对高周疲劳寿命的影响,通过同步辐射 X 射线断层扫描技术获取关键缺陷的几何特征,并使用网格搜索法与交叉验证优化模型参数,预测寿命与实验寿命之间的决定系数高达 0.99。Zhou 等^[87]提出了一种基于机器学习的遗传特征识别和疲劳寿命预测方法,结合了人工神经网络(ANN)和偏最小二乘(PLS)算法来提高疲劳寿命预测准确度,他们使用 27 个 316 LN 不锈钢试样在单轴和多轴加载下的早期实验数据,验证了前期疲劳数据对疲劳寿命预测的重要性,并从中识别出了五个关键遗传特征,利用这些特征建立的预测模型的预测结果显示,所有样本的预测疲劳寿命均在 1.5 倍误差范围内,他们的框架可扩展到识别其他材料在不同加载条件下的遗传特征和预测疲劳寿命,大大减少了实验时间和成本。Zhang 等^[88]提出了一种基于深度学习的通用寿命预测方法,适用于蠕变、疲劳和蠕变-疲劳寿命预测,他们在研究中整合了 316 奥氏体不锈钢的疲劳、蠕变和蠕变-疲劳数据,并将深度神经网络(DNN)与传统机器学习模型(如支持向量机、随机森林、高斯过程回归、浅层神经网络)进行了对比,结果显示,深度学习模型在预测精度和泛化能力方面优于传统机器学习模型。Wang 等^[89]利用了机器学习方法预测 Cr-Mo 钢的蠕变性能,他们在该研究中使用 Larson-Miller 参数(LMP)、Manson-Haferd 参数(MHP)和 Manson-Succop 参数(MSP)作为目标特征,结合随机森林(RF)模型进行蠕变寿命预测,结果表明,使用 MSP 作为目标特征时,RF 模型在所有回归模型

中表现最佳,并通过特征重要性排序为研究人员提供了蠕变性能影响因素的重要性。Pei 等^[90]通过 Fe/Cu 型电偶腐蚀传感器监测碳钢的大气腐蚀情况,使用随机森林(RF)模型处理数据,识别相对湿度、温度和降雨对初始大气腐蚀的影响,研究表明,RF 模型在预测腐蚀行为方面的准确性优于人工神经网络(ANN)和支持向量回归(SVR)模型,他们在模型中增加锈蚀的影响从而进一步提高了模型的预测准确性。牛瞳等^[91]基于原位观测及机器学习方法,对 T7451 及铸态 7050 铝合金在 3.5%NaCl 溶液中的腐蚀行为进行了表征,通过扫描电镜(SEM)和电子背散射衍射(EBSD)技术分析了腐蚀形貌和晶粒取向,并结合 196 条历史文献数据,运用 Pearson 相关性筛选及 Backforward 算法,对腐蚀行为特征进行了重要性排序,研究中发现,腐蚀行为萌生于析出相周围,腐蚀深度及范围随时间增加,并伴有裂纹萌生,其中 Cu、Ti、Fe、Mg 等元素在析出相中影响最为显著。

李绪尧等^[92]通过融合机器学习和传统强度理论,提出了一种腐蚀油气管道剩余强度预测的新方法,研究展示了通过前馈神经网络优化策略(如粒子群算法和 Dropout 技术)提高预测精度的有效性,特别是使用动态参数法预测不同工况下的经验参数来增强模型的实用性和准确度。曹斐等^[93]提出一种改进的支持向量回归的混凝土强度预测方法,以支持向量回归(SVR)为基础,提出基于马氏距离的加权型 SVR(MWSVR)算法预测混凝土强度,根据训练集和测试集的自变量距离决定训练样本重要性。Bhandari 等^[94]使用机器学习方法预测了高熵合金的屈服强度,采用随机森林(RF)回归方法,预测了 MoNbTaTiW 和 HfMoNbTaTiZr 在 800、1200 ℃ 和 1500 ℃ 的屈服强度,结果显示,RF 回归模型的预测结果与现有的实验数据高度一致,表明该方法在预测高熵合金在所需温度下的屈服强度方面具有高准确性,此研究方法为其他具有特定屈服强度需求的高熵合金的发现提供了可能。Zhang 等^[95]提出利用机器学习和硬度数据预测钨合金屈服强度的新方法,在八种机器学习模型中,梯度提升决策树模型(GBDT)最有效,其预测与实验结果平均误差为 6.7%,还给出了 90WNiFe 合金系统的硬度与屈服强度关系,凸显了 GBDT 回归模型结合硬度测量预测屈服强度的潜力。Mamun 等^[96]利用梯度提升机对 9%~12%Cr 铁素体-马氏体合金(FMA)和奥氏体不锈钢的蠕变断裂强度进行参数化,通过交叉验证对测试数据进行预

测,取得了较为准确的预测结构,并用 Shapley 值分析计算特征重要性以理解不同特征的复杂相互作用。Deng 等^[97]研究用机器学习方法预测粉末冶金技术制造的 Cu-Al 合金的力学性能,用六种算法构建预测模型,结果表明支持向量回归的顺序最小优化算法(SMOreg/puk)模型的预测能力最佳,其预测的相关系数最高、误差最低,他们还将该模型用于预测 Cu-Al 合金的拉伸强度和硬度并指导成分设计,在模型的指导下开发出达到预期值的 Cu-12Al-6Ni 合金。

从航空航天到高温工业环境,机器学习不仅能够准确预测材料的疲劳、蠕变和腐蚀寿命,还能识别并预测材料和结构在不同应力条件下的失效模式,评估其在复杂工况下的结构强度。通过使用如支持向量机、深度神经网络和随机森林等高级模型,研究人员能够从大规模数据中提取关键特征,优化预测模型,并显著减少实验时间和成本。此外,这些技术的应用不仅限于传统的寿命测试,还扩展到了实时监测和预测。通过结合失效模式的模拟与实验验证,研究人员已成功提高了失效模式、寿命与强度预测的精度。

5 失效预防

随着工业系统的日益复杂和自动化程度的提高,失效预防已成为提高生产可靠性和安全性的核心策略,人工智能技术尤其是机器学习方法的引入为失效预防提供了新的思路^[98]。其范畴不仅限于预测潜在故障,还包括通过优化设计、材料选择和工艺改进来减少或延缓设备和材料的失效,旨在通过提前发现问题和优化方案,最大程度减少突发故障的发生并延长设备与材料的使用寿命。机器学习在失效预防中主要利用其强大的数据分析能力来预测和防止潜在的故障,从而减少故障发生的风险和维护成本^[99]。在复杂的制造系统中,机器学习算法可以分析来自传感器的实时数据,识别出可能导致故障的异常模式。这种预测性维护方法提高了设备的运行效率,降低了意外停机的概率。此外,机器学习还可以在产品设计阶段发挥作用,通过模拟和分析不同设计方案的可能表现,帮助设计师优化产品结构和材料选择,在产品制造之前预见并消除潜在的设计缺陷,增强产品的整体性能和耐用性。在材料科学领域,机器学习技术被用来开发新材料,通过分析大量的化学和物理数据,机器学习模型可以预测材料的行为和寿命,指导更加有效

的材料加工和处理工艺,从而生产出更加可靠和耐用的材料。机器学习的应用使得失效预防更加智能化和精准化,对于现代工业尤其是在航空、汽车、能源等高风险行业的重要性日益增加。通过不断优化算法和扩大数据集,未来机器学习在失效预防领域的作用将更加显著,有望优化传统的工业维护模式。

Bergès 等^[100]在其研究中探讨了在晶圆切割过程中应用集成先进分析和机器学习的新方法,通过大规模数据的训练,这些算法能够洞察生产过程,还能自动化地预测和预防失效模式,从而提高生产质量和效率,此外,该项目还强调了技术专家与数据科学家之间的合作,通过迭代优化模型来实现项目的维护与升级。Xu 等^[101]的研究提供了机器学习在可靠性工程和安全应用中的全面综述,他们指出,尽管机器学习在许多领域已经有了显著的影响,可靠性工程和安全领域的文献仍然是分散的,通过总结现有研究并提供未来的发展路线图,强调了深度学习在这些应用中的增长和优势,展示了机器学习在提供新见解和预测事故的能力。Liu 等^[102]通过物理信息的机器学习,展示了在设计记忆合金时的新方法,结合传统的物理模型和机器学习算法,特别是在热处理过程参数的转换中,使用非线性数学关系来预测合金的微观结构和变形特性,有效地预测了复杂微观结构的形状记忆合金的物理行为。Pan 等^[103]在其综述中讨论了机器学习和人工智能在钢铁材料设计中的应用,通过数据预处理和不同机器学习模型的介绍,回顾了钢铁研究领域的成功案例,特别强调了机器学习方法在材料组成、结构、加工和性能优化方面的应用,以及在钢铁缺陷检测和材料组成的逆向设计中的潜力。Hassan 等^[104]的研究开发了一种用于机加工过程中突发工具故障预测和预防的实时深度机器学习方法,使用离散小波变换提取声发射信号的时频表示,并通过长短时记忆自编码器进行特征压缩和重构,使用这些数据作为预故障指示,成功预测并防止突发故障,提高了加工质量和效率。Kumar 等^[105]开发了一种机器学习系统,评估并预防主管管破裂的风险,利用水管历史破裂数据和一些描述性数据,通过梯度提升决策树进行风险评估,实现了 0.62 的预测精度,优于随机基准和专家启发式的评估方法。Dey 等^[106]提出了一种基于深度学习的集成模型,用于半导体工艺中缺陷的精确分类、检测和定位,通过不同的 ResNet 和 VGGNet 架构训练 RetinaNet 模型,并应用无监督机器学习进行去噪,

提高了半导体制造过程中缺陷检测的准确性。Mohammadi 等^[107]在激光粉末床熔融(L-PBF)过程中,采用机器学习技术进行在线缺陷检测,在研究中使用声发射(AE)传感器接收弹性波,结合层次化 K-means 聚类、主成分分析(PCA)和高斯混合模型(GMM)等方法,实现了对 H13 工具钢样品中不同缺陷的分类和检测,并验证了无需模型训练的缺陷检测方法的有效性。Krummenacher 等^[108]提出了两种基于机器学习的方法,用于自动检测铁路货车车轮缺陷,通过永久安装的传感系统测量车轮垂直力,研究使用支持向量机(SVM)和卷积神经网络(CNN)对平坦点、剥落和非圆度等缺陷进行分类和检测,显著提升了检测精度。

6 技术发展

人工智能技术在失效分析中的应用为这一领域带来了变革,展现出了巨大的潜力和广泛的应用前景,且在领域内的影响力逐年增加。图5为机器学习相关主题在领域内期刊的发文量变化。从断口特征提取、分类,到力学性能预测和断裂演化模拟,机器学习不仅提高了分析的效率和精度,还在很大程度上减少对专家经验的依赖。同时,NLP 等方法可以批量阅读、总结各种失效分析报告,归纳失效分析原因。




图5 机器学习在常见期刊的发文量

Fig. 5 Number of machine learning papers published in common journals

6.1 数据获取与数据质量

在人工智能方法的实现过程中,数据的获取与质量是至关重要的一环。高质量的数据是训练出高性能模型的前提,而失效分析中所需的数据往往需要经过复杂的实验和精细的标注。为了提升数据质量,可以采用多种手段,如使用先进的表征手

段或者显微技术获取微观结构信息,以及利用大数据技术进行数据的预处理和清洗。此外,数据的多样性也非常重要,涵盖不同材料、不同工况下的失效数据,有助于提高模型的泛化能力和适用性。失效分析行业在大数据和人工智能时代面临着新的挑战 and 机遇,数据的标准化和规范化在这个过程中尤为关键,这不仅有助于确保数据的一致性和可比性,还为机器学习模型的有效训练提供了坚实的基础^[109]。

6.2 模型的选择与优化

不同的人工智能模型在失效分析中的表现各有千秋。卷积神经网络(CNNs)在图像特征提取方面表现优异,适用于断口图像、金相的分类或分割;支持向量机(SVM)和随机森林(RF)则在处理结构化数据和进行分类预测时具有较好的效果;生成对抗网络(GANs)在模拟和生成数据方面展现出独特的优势,能够生成实验数据,包括文本类或者图像类,但是该种算法仅用于锦上添花,机器学习还是需要大量的原始数据作为支撑。为了提高模型的性能,可以采用多种优化手段,如超参数调优、模型集成、迁移学习等方法。特别是迁移学习,能够将已有模型在相关领域中的知识迁移到断口力学分析中,从而减少对大规模标注数据的需求,提高模型的训练效率和性能。

6.3 学科交叉

失效分析涉及材料科学、力学、物理学和计算机科学等多个学科的知识,跨学科合作对于推动这一领域的发展至关重要。通过与材料科学家、力学专家、计算机科学家等领域的专业人员合作,充分发挥不同领域专家各自的优势,共同解决复杂的失效分析问题,进一步推动人工智能在失效分析中的应用与发展。不同学科的专家在交流和合作中,往往会带来新的想法和观点,进而推动失效分析方法和技术的不断创新和发展。同时,跨学科合作也有助于培养具有综合素养的专业人才,学科交叉人才能够更好地适应复杂的失效分析问题,为行业的发展提供有力的支持。

6.4 伦理与安全

在失效分析中应用人工智能技术时,也需要关注伦理和安全问题。例如,如何确保数据的隐私和安全,避免敏感信息的泄露;如何公平公正地使用和分析数据,避免算法偏见和歧视;如何对模型的预测结果进行验证和解释,确保其可靠性和科学性。这些问题的解决不仅需要技术手段,还需要制度和规范的保障。通过建立健全的伦理和安全框

架,可以为机器学习技术在失效分析中的健康发展提供有力支持。

7 未来展望

展望未来,人工智能技术在失效分析中的应用前景广阔。在数据获取方面,随着传感技术和数据采集技术的不断进步,获取高质量、多样化的失效数据将变得更加容易。未来的失效数据将不仅包括传统的实验数据,还将涵盖现场监测数据、实时传感数据等,使得失效分析更加全面和精确。随着传感器技术的发展,工程师们将能够收集到更多维度的数据,为人工智能模型提供更加丰富的输入。从业人员要关注先进表征手段和光学仪器的发展,利用其获得高质量、高准度的数据。

在失效模式诊断方面,未来的发展将侧重于结合机器学习和先进表征手段,通过实时数据的监测和历史数据的积累,机器学习模型能够更好地捕捉和识别复杂失效模式。这将极大提升诊断的准确性和效率,为工程师提供更精确的分析工具,帮助他们在早期阶段发现潜在的故障模式。

在失效原因诊断方面,将人工智能与传统的力学模型相结合,发展出具有更高精度和更好可解释性的混合模型,是未来研究的重要方向。通过大规模数据分析,机器学习将帮助揭示复杂的失效原因,并进一步优化材料和工艺设计,以降低失效风险。这种结合物理模型与数据驱动的诊断方法,将为复杂工程结构和材料提供更深入的理解。

在失效预防方面,人工智能和机器学习将通过预测性维护的方式,提升设备运行的可靠性和安全性。未来,开发专用的机器学习算法和工具,将显著提高失效预防系统的自动化和智能化水平。通过实时监测系统,失效预防将变得更加精准和动态化,能够有效减少设备停机时间,确保设备和材料的长期稳定性。

在失效预测领域,随着计算能力的提升,训练和应用复杂的人工智能模型将更加高效。通过分布式计算、云计算和边缘计算等技术,未来的失效预测系统将能够处理更大规模的数据,提供更快速和准确的预测结果。失效预测不仅将实现对故障的实时监测,还将通过自适应学习不断更新模型,提升在不同场景下的预测能力,从而确保设备在复杂环境中的可靠性。

持续学习与自适应能力将使人工智能模型在不同应用场景中保持良好的性能。通过持续学习,

模型可以不断更新和优化,以适应新的数据和新的应用场景。例如,在失效分析中,通过不断引入新的失效数据,模型可以提高对不同材料、不同工况下失效特征的识别和预测能力。自适应学习则能够使模型在运行过程中自动调整参数和策略,以应对环境和条件的变化,提高分析的鲁棒性和可靠性。

总之,人工智能技术在失效分析中的应用已经展现出巨大的潜力和广阔的前景。通过不断提升数据质量、优化模型、加强跨学科合作、注重持续学习和自适应能力,并关注伦理和安全问题,人工智能技术将在失效分析中发挥越来越重要的作用,为材料科学和工程实践提供更加科学和高效的解决方案。希望本文的综述能够为研究人员和工程师提供有价值的参考,推动这一领域的进一步发展和创新。

参考文献:

- [1] 钟群鹏,张峥,有移亮.失效学的理念与材料的疲劳断裂失效[C]//2011年全国失效分析学术会议论文集.北京:中国机械工程学会,2011:1.
- [2] NISHIDA S. Failure analysis in engineering applications[M]. Amsterdam: Elsevier, 2014.
- [3] 钟群鹏,张峥,有移亮.失效学理念与安全生产[C]//中国职业安全健康协会.中国职业安全健康协会2010年学术年会论文集.北京:北京航空航天大学,2010:4.
- [4] NASRAZADANI S, HASSANI S. Modern analytical techniques in failure analysis of aerospace, chemical, and oil and gas industries[M]//Handbook of Materials Failure Analysis with Case Studies From the Oil and Gas Industry. Oxford: Butterworth-Heinemann, 2016: 39-54.
- [5] 钟群鹏,有移亮,张峥,等.深化失效学的哲学理念探索,强化材料失效交叉技术研究[J].航空学报,2014,35(10):2683-2689.
ZHONG Q P, YOU Y L, ZHANG Z, et al. Further exploration on philosophical concepts and analyzing overlapping technologies of failure study[J]. Acta Aeronautica et Astronautica Sinica, 2014, 35(10): 2683-2689.
- [6] 李鹤林.失效分析的任务、方法及其展望[J].理化检验(物理分册),2005(1):1-6.
- [7] 胡昌华,施权,司小胜,等.数据驱动的寿命预测和健康管理技术研究进展[J].信息与控制,2017,46(1):72-82.
HU C H, SHI Q, SI X S, et al. Data-driven life prediction and health management: state of the art[J]. Infor-

- mation and Control, 2017, 46(1): 72-82.
- [8] XU Y, LIU X, CAO X, et al. Artificial intelligence: a powerful paradigm for scientific research[J]. *The Innovation*, 2021, 2(4): 100179.
- [9] 米晓希, 汤爱涛, 朱雨晨, 等. 机器学习技术在材料科学领域中的应用进展 [J]. *材料导报*, 2021, 35(15): 15115-15124.
- MI X X, TANG A T, ZHU Y C, et al. Research progress of machine learning in material science[J]. *Materials Reports*, 2021, 35(15): 15115-15124.
- [10] 雷明. 机器学习: 原理、算法与应用 [M]. 北京: 清华大学出版社, 2019.
- [11] SARKER I H. Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions[J]. *SN Computer Science*, 2021, 2(6): 420.
- [12] MAHESH B. Machine learning algorithms — a review[J]. *International Journal of Science and Research*, 2020, 9(1): 381-386.
- [13] CUNNINGHAM P, CORD M, DELANY S J. Supervised learning[M]//Machine Learning Techniques for Multimedia: Case Studies on Organization and Retrieval. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008: 21-49.
- [14] BARLOW H B. Unsupervised learning[J]. *Neural Computation*, 1989, 1(3): 295-311.
- [15] 高阳, 陈世福, 陆鑫. 强化学习研究综述 [J]. *自动化学报*, 2004, 30(1): 86-100.
- GAO Y, CHEN S F, LU X. Research on reinforcement learning technology: a review[J]. *Acta Automatica Sinica*, 2004, 30(1): 86-100.
- [16] LEARNING S S. Semi-supervised learning[J]. *CSZ*, 2006, 5: 2.
- [17] 庄福振, 罗平, 何清, 等. 迁移学习研究进展 [J]. *软件学报*, 2015, 26(1): 26-39.
- ZHUANG F Z, LUO P, HE Q, et al. Survey on transfer learning research[J]. *Journal of Software*, 2015, 26(1): 26.
- [18] JAMWAL A, AGRAWAL R, SHARMA M. Deep learning for manufacturing sustainability: models, applications in industry 4.0 and implications[J]. *International Journal of Information Management Data Insights*, 2022, 2(2): 100107.
- [19] LI Z, LIU F, YANG W, et al. A survey of convolutional neural networks: analysis, applications, and prospects[J]. *IEEE transactions on neural networks and learning systems*, 2021, 33(12): 6999-7019.
- [20] 陈超, 齐峰. 卷积神经网络的发展及其在计算机视觉领域中的应用综述 [J]. *计算机科学*, 2019, 46(3): 63-73.
- CHEN C, QI F. Review on development of convolutional neural network and its application in computer vision[J]. *Computer Science*, 2019, 46(3): 63-73.
- [21] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. *Physica D*, 2020, 404: 132306.
- [22] ESKANDARI H, IMANI M, MOGHADDAM M P. Convolutional and recurrent neural network based model for short-term load forecasting[J]. *Electric Power Systems Research*, 2021, 195: 107173.
- [23] 王坤峰, 苟超, 段艳杰, 等. 生成式对抗网络 GAN 的研究进展与展望 [J]. *自动化学报*, 2017, 43(3): 321-332.
- WANG K F, GOU C, DUAN Y J, et al. Generative adversarial networks: the state of the art and beyond[J]. *Acta Automatica Sinica*, 2017, 43(3): 321-332.
- [24] 梁俊杰, 韦舰晶, 蒋正锋. 生成对抗网络 GAN 综述 [J]. *计算机科学与探索*, 2020, 14(1): 1-17.
- LIANG J J, WEI J J, JIANG Z F, et al. Generative adversarial networks(GAN) overview[J]. *Journal of Frontiers of Computer Science and Technology*, 2020, 14(1): 1-17.
- [25] SU X, YAN X, TSAI C L. Linear regression[J]. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2012, 4(3): 275-294.
- [26] HUANG S, CAI N, PACHECO P P, et al. Applications of support vector machine (SVM) learning in cancer genomics[J]. *Cancer Genomics & Proteomics*, 2018, 15(1): 41-51.
- [27] SONG Y Y, YING L U. Decision tree methods: applications for classification and prediction[J]. *Shanghai Archives of Psychiatry*, 2015, 27(2): 130.
- [28] BIAU G, SCORNET E. A random forest guided tour[J]. *Test*, 2016, 25: 197-227.
- [29] GURNEY K. An introduction to neural networks[M]. [S. l.]: CRC press, 2018.
- [30] 章永来, 周耀鉴. 聚类算法综述 [J]. *计算机应用*, 2019, 39(7): 1869-1882.
- ZHANG Y L, ZHOU Y J. Review of clustering algorithms[J]. *Journal of Computer Applications*, 2019, 39(7): 1869-1882.
- [31] ABDI H, WILLIAMS L J. Principal component analysis[J]. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2010, 2(4): 433-459.
- [32] SHARIF R A, AZIZPOUR H, SULLIVAN J, et al. CNN features off-the-shelf: an astounding baseline for recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition workshops. [S. l.]: [s. n.], 2014: 806-813.
- [33] WANG W, YANG Y, WANG X, et al. Development of convolutional neural network and its application in

- image classification: a survey[J]. *Optical Engineering*, 2019, 58(4): 040901-040901.
- [34] MANASWI N K, MANASWI N K. RNN and LSTM[M]//*Deep Learning with Applications Using Python: Chatbots and Face, Object, and Speech Recognition with TensorFlow and Keras*. [S. l.]: [s. n.], 2018: 115-126.
- [35] SHI H, XU M, LI R. Deep learning for household load forecasting—a novel pooling deep RNN[J]. *IEEE Transactions on Smart Grid*, 2017, 9(5): 5271-5280.
- [36] WANG K, GOU C, DUAN Y, et al. Generative adversarial networks: introduction and outlook[J]. *IEEE/CAA Journal of Automatica Sinica*, 2017, 4(4): 588-598.
- [37] LI Y, WANG Q, ZHANG J, et al. The theoretical research of generative adversarial networks: an overview[J]. *Neurocomputing*, 2021, 435: 26-41.
- [38] LAMBORA A, GUPTA K, CHOPRA K. Genetic algorithm—a literature review[C]//*2019 International Conference On Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*. [S. l.]: IEEE, 2019: 380-384.
- [39] FRAZIER P I. Bayesian optimization[M]//*Recent Advances in Optimization and Modeling of Contemporary Problems*. [S. l.]: Informa, 2018: 255-278.
- [40] FILZ M A, LANGNER J E B, HERRMANN C, et al. Data-driven failure mode and effect analysis (FMEA) to enhance maintenance planning[J]. *Computers in Industry*, 2021, 129: 103451.
- [41] SADER S, HUSTI I, DARÓCZI M. Enhancing failure mode and effects analysis using auto machine learning: a case study of the agricultural machinery industry[J]. *Processes*, 2020, 8(2): 224.
- [42] LEI Y, YANG B, JIANG X, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap[J]. *Mechanical Systems and Signal Processing*, 2020, 138: 106587.
- [43] SAUFI S R, AHMAD Z A B, LEONG M S, et al. Challenges and opportunities of deep learning models for machinery fault detection and diagnosis: a review[J]. *Ieee Access*, 2019, 7: 122644-122662.
- [44] ZIO E. Reliability engineering: old problems and new challenges[J]. *Reliability Engineering & System Safety*, 2009, 94(2): 125-141.
- [45] 钟群鹏, 宋光雄, 张峥, 等. 机械失效模式, 原因和机理的诊断思路 and 主要依据 [J]. *北京航空航天大学学报*, 2004, 30(10): 913-918.
- ZHONG Q P, SONG G X, ZHANG Z, et al. Diagnosis methods and criterions for mechanical failure modes, causes and mechanisms[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2004, 30(10): 913-918.
- [46] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述 [J]. *自动化学报*, 2016, 42(9): 1285-1299.
- WEN C L, LV F Y, BAO Z J, et al. A review of data driven-based incipient fault diagnosis[J]. *Acta Automatica Sinica*, 2016, 42(9): 1285-1299.
- [47] 文成林, 吕菲亚. 基于深度学习的故障诊断方法综述 [J]. *电子与信息学报*, 2020, 42(1): 234-248.
- WEN C L, LV F Y. Review on deep learning based fault diagnosis[J]. *Journal of Electronics & Information Technology*, 2020, 42(1): 234-248.
- [48] 沈功田, 刘渊. 大型机械系统的健康管理理论研究及应用设想 [J]. *机械工程学报*, 2017, 53(6): 1-9.
- SHEN G T, LIU Y. Research and application assumptions of health management theory of large mechanical system[J]. *Journal of Mechanical Engineering*, 2017, 53(6): 1-9.
- [49] 吴圣川, 胡雅楠, 杨冰, 等. 增材制造材料缺陷表征及结构完整性评定方法研究综述 [J]. *机械工程学报*, 2021, 57(22): 3-34.
- WU S C, HU Y, YANG B, et al. Review on defect characterization and structural integrity assessment method of additively manufactured materials[J]. *Journal of Mechanical Engineering*, 2021, 57(22): 3-34.
- [50] WASHINGTON A, CLOTHIER R A, WILLIAMS B P. A bayesian approach to system safety assessment and compliance assessment for unmanned aircraft systems [J]. *Journal of Air Transport Management*, 2017, 62: 18-33.
- [51] LUCKY B O, TAKIM S. Manufacturing defects in the automobile industry, a case study of the remote causes and effects of Toyotas transmission malfunctions in cars[J]. *International Journal of Engineering and Applied Sciences*, 2015, 2(8): 257854.
- [52] 张新明, 邓运来, 张勇. 高强铝合金的发展及其材料的制备加工技术 [J]. *金属学报*, 2015, 51(3): 257-271.
- ZHANG X M, DENG Y L, ZHANG Y. Development of high strength aluminum alloys and processing techniques for the materials[J]. *Acta Metallurgica Sinica*, 2015, 51(3): 257-271.
- [53] DASGUPTA A, PECHT M. Material failure mechanisms and damage models[J]. *IEEE Transactions on Reliability*, 1991, 40(5): 531-536.
- [54] 曹枝军, 袁建辉, 苏怀宇, 等. 基于原位声发射信号的热障涂层三点弯曲失效模式的机器学习 [J]. *硅酸盐学报*, 2023, 51(2): 373-388.
- CAO Z J, YUAN J H, SU H Y, et al. Failure mode of thermal barrier coatings based on acoustic emission

- under three-point bending *via* machine learning based on in-situ acoustic emission signals[J]. *Journal of the Chinese Ceramic Society*, 2023, 51(2): 373-388.
- [55] BASTIDAS-RODRIGUEZ M X, PRIETO-ORTIZ F A, ESPEJO E. Fractographic classification in metallic materials by using computer vision[J]. *Engineering Failure Analysis*, 2016, 59: 237-252.
- [56] BASTIDAS-RODRIGUEZ M X, POLANIA L, GRUSON A, et al. Deep learning for fractographic classification in metallic materials[J]. *Engineering Failure Analysis*, 2020, 113: 104532.
- [57] YUE J G, WANG Y N, BESKOS D E. Uniaxial tension damage mechanics of steel fiber reinforced concrete using acoustic emission and machine learning crack mode classification[J]. *Cement and Concrete Composites*, 2021, 123: 104205.
- [58] DAS A K, SUTHAR D, LEUNG C K Y. Machine learning based crack mode classification from unlabeled acoustic emission waveform features[J]. *Cement and Concrete Research*, 2019, 121: 42-57.
- [59] KABIR M A B, HASAN A S, BILLAH A H M M. Failure mode identification of column base plate connection using data-driven machine learning techniques[J]. *Engineering Structures*, 2021, 240: 112389.
- [60] SAROTHI S Z, AHMED K S, KHAN N I, et al. Machine learning-based failure mode identification of double shear bolted connections in structural steel[J]. *Engineering Failure Analysis*, 2022, 139: 106471.
- [61] TAFSESE W Z, ZHU Y, CHEN G. Utilizing ensemble learning in the classifications of ductile and brittle failure modes of UHPC strengthened RC members[J]. *Archives of Civil and Mechanical Engineering*, 2024, 24(2): 86.
- [62] SCHNELLER W, LEITNER M, MAIER B, et al. Artificial intelligence assisted fatigue failure prediction[J]. *International Journal of Fatigue*, 2022, 155: 106580.
- [63] MOKHTARZADEH M, RODRÍGUEZ-ECHEVERRÍA J, SEMANJSKI I, et al. Hybrid intelligence failure analysis for industry 4.0: a literature review and future prospective[J]. *Journal of Intelligent Manufacturing*, 2024(4): 1-26.
- [64] ZHENG B, LI T, QI H, et al. Physics-informed machine learning model for computational fracture of quasi-brittle materials without labelled data[J]. *International Journal of Mechanical Sciences*, 2022, 223: 107282.
- [65] VELÁSQUEZ R M A, LARA J V M. Root cause analysis improved with machine learning for failure analysis in power transformers[J]. *Engineering Failure Analysis*, 2020, 115: 104684.
- [66] ZHENG X, BATTALGAZY B, MOLKERI A, et al. Role of length-scale in machine learning based image analysis of ductile fracture surfaces[J]. *Mechanics of Materials*, 2023, 181: 104661.
- [67] SCHMIES L, BOTSCH B, LE Q H, et al. Classification of fracture characteristics and fracture mechanisms using deep learning and topography data[J]. *Practical Metallography*, 2023, 60(2): 76-92.
- [68] ZHANG N, FU H, LIU P, et al. Machine learning-based quantitative analysis of metal ductile fracture surface[J]. *Materialia*, 2023, 32: 101904.
- [69] LI Z, ZHAO T, ZHANG J, et al. Fusing image and physical data for fatigue life prediction of nickel-based single crystal superalloys[J]. *Engineering Failure Analysis*, 2024, 162: 108343.
- [70] LIU G, BOYD M, YU M, et al. Identifying causality and contributory factors of pipeline incidents by employing natural language processing and text mining techniques[J]. *Process safety and environmental protection*, 2021, 152: 37-46.
- [71] CHOKOR A, NAGANATHAN H, CHONG W K, et al. Analyzing Arizona OSHA injury reports using unsupervised machine learning[J]. *Procedia engineering*, 2016, 145: 1588-1593.
- [72] GOH Y M, UBEYNARAYANA C U. Construction accident narrative classification: an evaluation of text mining techniques[J]. *Accident Analysis & Prevention*, 2017, 108: 122-130.
- [73] HALIM S Z, YU M, ESCOBAR H, et al. Towards a causal model from pipeline incident data analysis[J]. *Process Safety and Environmental Protection*, 2020, 143: 348-360.
- [74] NAKATA T. Text-mining on incident reports to find knowledge on industrial safety[C]//2017 Annual Reliability and Maintainability Symposium (RAMS). [S. l.]: IEEE, 2017: 1-5.
- [75] MAY H, A. Y. E., K. M. I., et al. Failure mode and capacity prediction for bolted T-stub connections using ensemble learning[J]. *Journal of Constructional Steel Research*, 2024, 212: 108288.
- [76] PINEAU A, PARDOEN T. Failure mechanisms of metals[J]. *Comprehensive Structural Integrity Encyclopedia*, 2007, 2: 687-783.
- [77] SANTECCHIA E, HAMOUDA A M S, MUSHARAVATI F, et al. A review on fatigue life prediction methods for metals[J]. *Advances in Materials Science and Engineering*, 2016, 2016(1): 9573524.
- [78] DYSON B F, MCLEAN D. A new method of predicting creep life[J]. *Metal Science*, 1972, 6(1): 220-223.
- [79] HARLOW D G, WEI R P. Probability approach for prediction of corrosion and corrosion fatigue life[J]. *AIAA*

- [Journal](#), 1994, 32(10): 2073-2079.
- [80] BERETTA S, MURAKAMI Y. Statistical analysis of defects for fatigue strength prediction and quality control of materials[J]. *Fatigue & Fracture of Engineering Materials & Structures*, 1998, 21(9): 1049-1065.
- [81] LIU C, LI X, GE J, et al. A deep learning framework based on attention mechanism for predicting the mechanical properties and failure mode of embedded wrinkle fiber-reinforced composites[J]. *Composites Part A*, 2024, 186: 108401.
- [82] 颜秀文, 高梓文, 刘岩舒, 等. 基于多层感知机的失效模式预测方法研究 [J]. *价值工程*, 2024, 43(4): 106-108.
- YAN X W, GAO Z W, LIU S Y, et al. Research on failure mode prediction method based on multilayer perception machine[J]. *Value Engineering*, 2024, 43(4): 106-108.
- [83] 马高, 王瑶. 基于机器学习的钢管混凝土剪力墙破坏模式预测与解释 [J]. *地震工程与工程振动*, 2022, 42(3): 143-152.
- MA G, WANG Y. Failure mode prediction and explanation of concrete-filled steel tubular shear walls based on machine learning[J]. *Earthquake Engineering and Engineering Dynamics*, 2022, 42(3): 143-152.
- [84] CHEBBI T, TLILI B, BOUZAIENE H, et al. Failure mode prediction of resistance spot welded quenching and partitioning stainless steel[J]. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2021, 43: 1-15.
- [85] MANGALATHU S, JEON J S. Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques[J]. *Engineering Structures*, 2018, 160: 85-94.
- [86] BAO H, WU S, WU Z, et al. A machine-learning fatigue life prediction approach of additively manufactured metals[J]. *Engineering Fracture Mechanics*, 2021, 242: 107508.
- [87] ZHOU K, SUN X, SHI S, et al. Machine learning-based genetic feature identification and fatigue life prediction [J]. *Fatigue & Fracture of Engineering Materials & Structures*, 2021, 44(9): 2524-2537.
- [88] ZHANG X C, GONG J G, XUAN F Z. A deep learning based life prediction method for components under creep, fatigue and creep-fatigue conditions[J]. *International Journal of Fatigue*, 2021, 148: 106236.
- [89] WANG J, FA Y, TIAN Y, et al. A machine-learning approach to predict creep properties of Cr-Mo steel with time-temperature parameters[J]. *Journal of Materials Research and Technology*, 2021, 13: 635-650.
- [90] PEI Z, ZHANG D, ZHI Y, et al. Towards understanding and prediction of atmospheric corrosion of an Fe/Cu corrosion sensor *via* machine learning[J]. *Corrosion Science*, 2020, 170: 108697.
- [91] 牛瞳, 张娜, 熊希临. 基于原位观测及机器学习的7050铝合金腐蚀行为表征 [J]. *物理测试*, 2024, 42(1): 1-7.
- NIU T, ZHANG N, XIONG X L. Corrosion behavior characterization of 7050 aluminum alloy based on in-situ observation and machine learning[J]. *Physics Examination and Testing*, 2024, 42(1): 1-7.
- [92] 李绪尧. 基于机器学习的腐蚀管道剩余强度预测 [D]. 杭州: 杭州电子科技大学, 2024.
- LI X Y. Research on residual strength of corroded pipeline based on machine learning[D]. Hangzhou: Hangzhou Dianzi University, 2024.
- [93] 曹斐, 周戡, 王春晓, 等. 一种改进的支持向量回归的混凝土强度预测方法 [J]. *硅酸盐通报*, 2021, 40(1): 90-97.
- CAO F, ZHOU Y, WANG C, et al. An improved support vector regression method for concrete strength prediction[J]. *Bulletin of the Chinese Ceramic Society*, 2021, 40(1): 90-97.
- [94] BHANDARI U, RAFI M R, ZHANG C, et al. Yield strength prediction of high-entropy alloys using machine learning[J]. *Materials Today Communications*, 2021, 26: 101871.
- [95] ZHANG Z, GAO H, ZHANG Z, et al. Hardness-guided machine learning for tungsten alloy strength prediction[J]. *Materials Today Communications*, 2024, 39: 109070.
- [96] MAMUN O, WENZLICK M, HAWK J, et al. A machine learning aided interpretable model for rupture strength prediction in Fe-based martensitic and austenitic alloys[J]. *Scientific Reports*, 2021, 11(1): 5466.
- [97] DENG Z, YIN H, JIANG X, et al. Machine-learning-assisted prediction of the mechanical properties of Cu-Al alloy[J]. *International Journal of Minerals, Metallurgy and Materials*, 2020, 27: 362-373.
- [98] ANGELOPOULOS A, MICHAELIDIS E T, NOMIKOS N, et al. Tackling faults in the industry 4.0 era—a survey of machine-learning solutions and key aspects[J]. *Sensors*, 2019, 20(1): 109.
- [99] DIEZ-OLIVAN A, DEL S J, GALAR D, et al. Data fusion and machine learning for industrial prognosis: trends and perspectives towards Industry 4.0[J]. *Information Fusion*, 2019, 50: 92-111.
- [100] BERGÈS C, CÉNERAY C, ALBERMANN G, et al. Detection and prevention of assembly defects, by machine learning algorithms, in semiconductor industry for automotive[C]//2020 IEEE International Sympos-

- sium on the Physical and Failure Analysis of Integrated Circuits (IPFA). [S. l.]: IEEE, 2020: 1-9.
- [101] XU Z, SALEH J H. Machine learning for reliability engineering and safety applications: review of current status and future opportunities[J]. Reliability Engineering & System Safety, 2021, 211: 107530.
- [102] LIU S, KAPPES B B, AMIN-AHMADI B, et al. Physics-informed machine learning for composition-process-property design: shape memory alloy demonstration[J]. *Applied Materials Today*, 2021, 22: 100898.
- [103] PAN G, WANG F, SHANG C, et al. Advances in machine learning-and artificial intelligence-assisted material design of steels[J]. International Journal of Minerals, Metallurgy and Materials, 2023, 30(6): 1003-1024.
- [104] HASSAN M, SADEK A, ATTIA H. A real-time deep machine learning approach for sudden tool failure prediction and prevention in machining processes[J]. *Sensors*, 2023, 23(8): 3894.
- [105] KUMAR A, RIZVI S A A, BROOKS B, et al. Using machine learning to assess the risk of and prevent water main breaks[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. [S. l.]: 2018: 472-480.
- [106] DEY B, GOSWAMI D, HALDER S, et al. Deep learning-based defect classification and detection in SEM images[C]//Metrology, Inspection, and Process Control XXXVI. [S. l.]: SPIE, 2022: PC120530Y.
- [107] MOHAMMADI M G, MAHMOUD D, ELBESTAWI M. On the application of machine learning for defect detection in L-PBF additive manufacturing[J]. Optics & Laser Technology, 2021, 143: 107338.
- [108] KRUMMENACHER G, ONG C S, KOLLER S, et al. Wheel defect detection with machine learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 19(4): 1176-1187.
- [109] 有移亮, 张峥. 失效分析标准化探讨 [J]. 金属热处理, 2019, 44(增刊1): 650-653.
- YOU Y L, ZHANG Z. Discussions on standardization of failure analysis[J]. Heat Treatment of Metals, 2019, 44(Suppl 1): 650-653.

收稿日期: 2024-08-26; 修订日期: 2024-09-15

基金项目: 国家科技重大专项(J2019-VI-0022-0138)

通讯作者: 有移亮(1979—), 男, 博士, 副教授, 研究方向为失效分析预测预防, 联系地址: 北京市海淀区学院路37号北京航空航天大学新主楼(100191), E-mail: yyl@buaa.edu.cn

(本文责编: 徐永祥)