

DOI:10.16410/j.issn1000-8365.2025.5097

机器学习在球墨铸铁研发中的应用

刘禹^{1,2}, 黎振华^{1,2,3}, 何远怀², 涂雯雯³, 韦贺^{1,2}

(1. 昆明理工大学材料科学与工程学院, 云南昆明 650093; 2. 金属先进凝固成形及装备技术国家地方工程研究中心, 云南昆明 650093; 3. 云南省轻金属增材制造工程研究中心, 云南昆明 650500)

摘要: 基于数据驱动的机器学习方法通过构建材料特征参数与目标性能间的复杂映射关系, 突破传统研发模式在时间与成本上的限制, 为球墨铸铁研发提供了全新范式。通过对基于机器学习的球墨铸铁研发过程中的应用进展进行系统梳理, 在阐释机器学习数据收集、数据预处理、模型构建与训练以及模型评估等基本实施框架的基础上, 综述了机器学习在组织与缺陷控制、力学性能的预测以及服役行为的预测等方面的应用, 探讨了球墨铸铁研发和应用过程中基于机器学习的一些急需解决的问题, 提出了基于机器学习的球墨铸铁研发方向及未来的发展趋势。

关键词: 机器学习; 球墨铸铁; 性能预测; 缺陷识别; 服役行为预测

中图分类号: TG113.12

文献标识码: A

文章编号: 1000-8365(2025)06-0520-11

Application of Machine Learning in the Research and Development of Ductile Iron

LIU Yu^{1,2}, LI Zhenhua^{1,2,3}, HE Yuanhuai², TU Wenwen³, WEI He^{1,2}

(1. Faculty of Materials Science and Engineering, Kunming University of Science and Technology, Kunming 650093, China; 2. National-local Joint Engineering Research Center for Technology of Advanced Metallic Solidification Forming and Equipment, Kunming 650093, China; 3. Research Center for Light Alloy and Additive Manufacturing, Kunming 650500, China)

Abstract: Data-driven machine learning methods, by establishing complex mapping relationships between material characteristic parameters and target properties, provide a novel paradigm for ductile iron research and development, overcoming the limitations of time and cost inherent in traditional research and development (R&D) approaches. Recent progress in the application of machine learning within the ductile iron R&D process is systematically reviewed. The fundamental implementation framework is elucidated, encompassing data collection, data preprocessing, model construction and training, and model evaluation. The applications of machine learning are summarized in various areas, including microstructure and defect control, prediction of mechanical properties, and prediction of service performance. Critical challenges demanding urgent solutions in machine learning-based ductile iron R&D and applications are discussed. Finally, research directions and future development trends for machine learning-driven ductile iron development are proposed.

Key words: machine learning; ductile iron; performance prediction; defect identification; service behavior prediction

球墨铸铁具有优良的综合力学性能和制造成本, 自上世纪 40 年代发明以来获得了广泛应用。随着高端装备和制造业的快速发展, 对球墨铸铁力学性能的要求日益提高^[1-5]。球墨铸铁合金体系复杂, 传统试错法是在经验指导下, 通过有限实验进行试错, 并设置离散的成分和工艺参数来探索优异的综合性能, 因此耗费大量的时间和成本, 然而由

于数据量有限, 对成分与性能关系的综合考虑不够全面, 导致效率低、成本高^[6-11]。

机器学习(machine learning, ML)是人工智能数据驱动领域快速发展的方向, 其利用实验数据的统计规律来构建特征量与目标性能之间关系的预测模型, 探索材料成分、组织、工艺和性能之间的关系, 在有限实验数据的情况下, 将材料成分、组织、工艺和

收稿日期: 2025-06-04

基金项目: 云南省重大科技专项(202402AG050003)

作者简介: 刘禹, 2000 年生, 硕士生, 研究方向为机器学习研发球墨铸铁. Email: 2078747465@qq.com

通信作者: 黎振华, 1976 年生, 博士, 教授, 研究方向为合金凝固与增材制造. Email: lzhkust@sina.com

引用格式: 刘禹, 黎振华, 何远怀, 涂雯雯, 韦贺. 机器学习在球墨铸铁研发中的应用[J]. 铸造技术, 2025, 46(6): 520-530.

LIU Y, LI Z H, HE Y H, TU W W, WEI H. Application of machine learning in the research and development of ductile iron[J]. Foundry Technology, 2025, 46(6): 520-530.

性能之间的关系探索到无限的空间,为材料设计提供了有力指导,大大减少了材料开发的时间,有效降低了研发成本^[12-14]。利用机器学习算法与球墨铸铁数据相结合,建立输入(如球墨铸铁的合金成分、组织和工艺等)与输出(如球墨铸铁力学性能、组织缺陷和腐蚀行为等)之间的映射关系,可以实现球墨铸铁合金成分、组织结构、加工工艺、服役性能预测与新材料研发,为球墨铸铁的研发提供了新的思路。

近年来,机器学习在球墨铸铁研究中的应用正成为材料开发的关键趋势,其核心价值在于辅助优化铸造及后续加工工艺,并精准预测关键性能。通过利用积累的球墨铸铁数据集训练机器学习模型,揭示工艺过程、合金组分、微观组织演变与最终力学行为、表面特性之间的复杂关系,为材料设计与工艺控制提供了强力的数据驱动工具。王艺^[15]针对球墨铸铁 QT700-2 开展了磨削实验,采集声发射信号与表面粗糙度数据以研究智能预测方法。实验采用 10/20/30 μm 不同磨削深度获取 200 组样本。结合 EMD(empirical mode decomposition)阈值降噪及时频分析(short-time Fourier transform, STFT)、小波变换提取信号特征后,构建了 BP 神经网络(back-propagation, BP)、支持向量回归机(support vector regression, SVR)及深度学习模型。利用遗传算法(genetic algorithm, GA)和粒子群算法(particle swarm optimization, PSO)优化模型参数,结果显示传统 BP 模型预测误差为 14.3%~20.3%,优化后 SVR 模型误差降至 10.7%~11.3%。研究进一步提出采用卷积神经网络(convolutional neural network, CNN)自动提取声发射时频图特征,结合 GA 优化 SVR 构建混合模型(CNN-GA-SVR),最终将表面粗糙度预测误差显著降低至 1.06%,远优于传统方法。Song 等^[16]通过物

理模拟制备 18 组 400 mm 厚壁球墨铸铁试样,从边缘到心部选取 4 个冷却速率位点(135~265 min),获得 72 组样本数据。以碳含量(3.2%~4.2%,质量分数,下同)、硅含量(1.7%~4.0%)、锰含量(0.1%~1.6%)及冷却时间为输入特征,断裂韧性为输出目标,构建了 XGBoost (extreme gradient boosting)、SVR、MLP (multi-layer perceptron)、高斯过程、Bagging (bootstrap aggregating)和随机森林(random forest, RF)6 种机器学习模型。经遗传算法优化及五折交叉验证, Bagging 模型预测精度最优($R^2=0.999\ 0$, RMSE=0.237 3),高斯过程次之($R^2=0.99$)。在扩展成分验证范围内($C\leq 4.2\%$, $Si\leq 4.0\%$, $Mn\leq 1.6\%$), Bagging 模型仍保持高精度($R^2=0.987\ 3$, RMSE=0.499 3)。该方法为核电容器、风电基座等厚壁铸件的成分与工艺设计提供了高效的预测手段。

本文在介绍机器学习基本原理和相关模型的基础上,综述了利用机器学习方法对球墨铸铁进行力学性能预测、组织缺陷识别和服役性能预测相关研究进展,并展望了机器学习在球墨铸铁研发中的应用前景。

1 机器学习

机器学习一般步骤包括数据集收集、数据预处理、模型选择与训练和模型性能评估^[17-18],如图 1 所示。首先,通过实验、公开数据集和文献收集合金数据,确定输入特征与输出特征;其次,对收集到的数据进行预处理,消除收集数据中存在缺失值、噪音或人工录入错误出现异常点。数据预处理一般包含数据清洗、数据转换、数据规约以及特征工程,从而提高数据质量,减少模型过拟合风险,提高模型泛化能力;最后,对数据进行分析,选择合适模型。例如,可

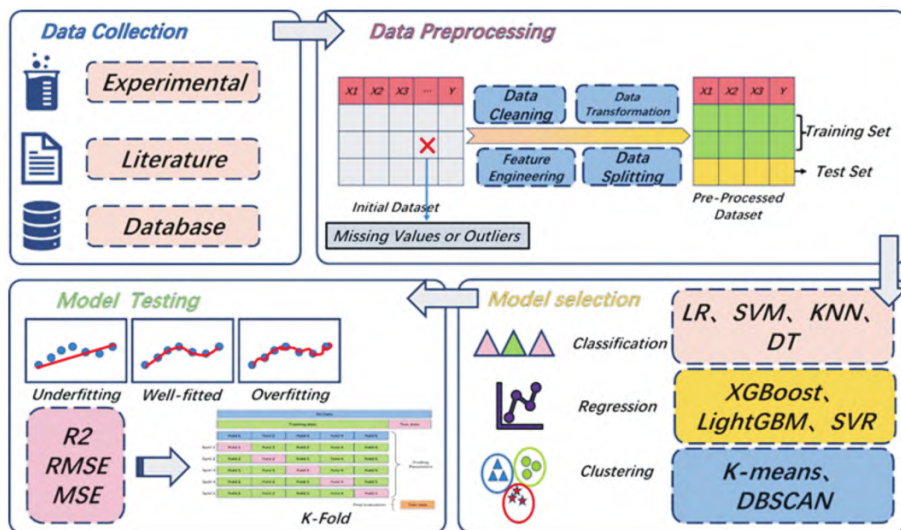


图 1 机器学习流程

Fig.1 Machine learning workflow

以通过判断数据有无类标,选择是用监督学习还是无监督学习;根据数据量大小和问题类型判断是回归问题还是分类问题,选择合适的模型;在实际问题操作时,往往是通过多个模型比较来选择合适的模型;最后,对模型进行评估和解释,通过评估指标选择更优的模型,使用交叉验证法评判模型性能的好坏;另外,也可针对一种模型采用多种不同的方法,每种方法给予不同的权重值,以对该模型进行综合“评分”。当获得理想的预测精度后,进一步调节模型参数,最终实现结果预测。

1.1 数据集收集

机器学习的关键是如何进行高质量数据集的搭建。科学合理的数据收集策略会对模型的预测精度和泛化能力产生直接影响。在材料科学领域,大量学者采用多源异构数据融合的方法构建数据集,其主要获取途径包括文献挖掘、数据库检索以及计算/实验生成这3个方面,其中,前两者因为有较高的可获得性而成为主流数据源,如图2a所示。

机器学习模型的准确性一般受限于其训练和验证所用数据的质量与数量,这一问题在材料科学领域尤为突出,由于该领域普遍缺乏大规模、高质量且具有一致性的数据集^[9]。目前,大部分材料数据来自实验测量、理论计算以及工业生产。合金的数据集信息包括输入(特征)和输出(目标属性)。“输入”通常包括元素组成、原子参数、结构参数和工艺条件等。“输出”通常包括硬度、屈服强度、伸长率、耐腐蚀性和导电性等^[20]。因测量手段和实验方案不同、实验环境差异、理论计算误差以及数据录入错误等因素,收集到的材料数据与真实数据之间往往存在一定误差,使得材料数据的准确性降低,进而严重影响机器学习模型预测结果的准确性和合理性^[21]。因此,在收集数据集时,应尽量保证数据具有较高的一致性。

1.2 数据预处理

数据预处理是机器学习的重要一环。收集到的

原始数据一般存在数据缺失、噪声、数据格式不统一、输入变量纬度高和信息冗余等问题。通过去除噪声、填补缺失值和统一数据格式等方式,可以增强数据的准确性和一致性;通过特征工程和数据归一化等手段可以降低特征维度,并有效避免模型过拟合或欠拟合,同时减少数据量和维度可以提高训练效率。数据预处理主要是通过数据清洗、数据转换、数据规约和特征工程获得高质量数据,以提升模型性能,降低计算的复杂度。

数据清洗可以有效去除原始数据中的噪声和错误,处理缺失值、异常值和重复数据,从而提高数据的准确性,增强数据完整性和可靠性,为后续分析打下基础。数据转换可以改变数据格式及尺度,消除不同特征数据间的量纲差异,避免因某些特征数据范围过大而主导模型;转换数据类型,使模型可以处理非数值数据;改变数据分布,提高模型稳定性。数据规约是在保留主要信息的前提下尽量减少数据量,降低计算复杂度,避免维度灾难。特征工程通过专业知识创建、组合和转换特征,可以更有效地表达数据内在模式,提升模型的预测上限。

1.3 模型选择与训练

机器学习常用的算法主要分为四类,无监督学习算法、监督学习算法、半监督学习算法以及强化学习算法,如图2b所示。无监督学习算法是机器学习中较为常见的一种训练方式,与监督学习算法区分开来,主要特点是该类型的算法没有明确的目的性、不需要对数据使用标签以及无法量化效果,常见的算法有聚类算法(K-均值聚类、层次聚类等)、主成分分析(principal component analysis, PCA)、独立成分分析(independent component analysis, ICA)等^[22]。监督学习算法是机器学习中最为常见的,也是使用最多的一种算法类型,一般存在回归和分类两种问题,常见的算法有线性回归(linear regression, LR)、K-近邻回归(K-nearest neighbor regression, KNR)、随机森林回归




图2 数据资源与智能算法:(a) 材料领域机器学习数据来源;(b) 机器学习方法概述

Fig.2 Data resources and intelligent algorithms: (a) data sources for machine learning in materials science; (b) overview of machine learning methodologies

(random forest regression, RFR)、支持向量机(support vector machine, SVM)以及深度学习算法等^[23],如图3所示。而半监督学习是使用少量的标签数据,加上大量无标签数据进行学习,常见的算法有自训练、协同训练以及生成式模型等^[24]。

算法的选择依据一般有样本大小、样本数据分布情况、算法应用范围和算法特点等,通常根据数据特点和算法适合情况可以缩小合适算法的范围。机器学习通常需要将多种算法实际应用于数据集进行效果评价才能得到最合适的算法。算法选择时,保证建模精度的前提下,更倾向于使用简单的算法。

1.4 模型评估

模型评估在机器学习流程中占据着基础性地位,其作用在于可客观地对模型在真实场景下的泛化能力以及性能给予衡量,依靠对未见数据进行测试,可有效规避过拟合与欠拟合的情况发生,如图4。标准指标的存在可促进不同模型之间实现公正的

比较,评估过程可使模型与业务需求达成对齐,揭示如数据偏差、公平性等问题,以此指导模型不断进行迭代。评估过程中评估指标可以帮助衡量模型的好坏以指导模型的选择与调优,如图5所示。验证方法是防止模型过拟合及检查其泛化能力的重要方法,如图6所示。

2 ML 在球墨铸铁力学性能预测中的应用

准确掌握球墨铸铁的力学性能,是确保其在工程领域或日常应用正确选择的首要前提^[25]。近年来,ML逐渐成为材料性能预测与优化的常用工具。借助挖掘历史实验数据里的统计规律,通过ML模型构建成分、组织、工艺及性能间的定量映射关系,可以突破传统经验公式的线性假设限制。

Gu等^[26]基于百余篇文献收集了248组实验数据,筛选出C、Si、Mn、Mg、RE、Ni 6种核心元素作为输入特征,将抗拉强度、屈服强度、伸长率和布氏硬




图3 常用机器学习算法:(a) KNN;(b) SVM;(c) U-Net;(d) GAN;(e) XGBoost
Fig.3 Common machine learning algorithms: (a) KNN; (b) SVM; (c) U-Net; (d) GAN; (e) XGBoost




图4 模型拟合示意图:(a) 欠拟合;(b) 正确拟合;(c) 过拟合示意图
Fig.4 Schematic of model fitting: (a) underfitting; (b) correct fitting; (c) overfitting




图 5 评估指标示意图:(a) 混淆矩阵;(b) ROC 曲线与 AUC 值
Fig.5 Evaluation metrics: (a) confusion matrix; (b) ROC curve and AUC value




图 6 K 折交叉验证法
Fig.6 K-fold cross-validation

度作为输出目标。对比支持向量机、决策树、集成树和高斯过程 4 种算法,确定了高斯为抗拉强度与硬度的最优模型,阐明了成分、组织和性能跨尺度关联规律,如图 7 所示。Ram 等^[27]在研发铁素体基体硅钼球墨铸铁(silicon-molybdenum ductile cast iron, Si-Mo DCI)时,探究了 C、Si、Mo、Cu 元素含量对力学性能的影响。并对 10 组铸态样品的显微组织、硬度、拉伸性能进行了回归分析。Fernandez-Calvo 等^[28]基于铸铁件制造数字孪生系统(OLIMPO),采集了 173 批次汽车制动锚固件的生产数据,通过构建基于贝叶斯网络的模型预测控制(model predictive control, MPC)算法,并将其集成至数字孪生平台,实现了对屈服强度的在线实时预测,最终满足了高屈服强度的制动锚固件生产要求。

Fragassa 等^[29]采用 ML 方法,结合球墨铸铁(spheroidal graphite cast iron, SGI)和蠕墨铸铁(vermicular graphite cast iron, VGI)实验数据,构建了包括金相参数(石墨形态、铁素体/珠光体含量)与力学性能(极限抗拉强度、屈服强度)的预测模型。研究了随机森林、人工神经网络、K-近邻三类算法在 27 组 SGI 和 21

组 VGI 微观组织与拉伸性能数据验证的有效性。实验发现,ANN 的预测误差最低,UTS 误差仅 0.2%,可以准确反映实验数据本身的变异性,以及 KNN 存在系统性低估倾向。

机器学习已经改变了球墨铸铁的力学性能预测模式,通过建立化学成分、显微组织、工艺参数与目标变量(抗拉强度、伸长率等)的多维复杂映射关系,有效突破了传统经验公式的线性假设局限,实现了球墨铸铁力学性能预测智能化与优化。有效加速材料早期研发阶段的成分与工艺设计,显著提升了球墨铸铁材料开发的效率与精度。

3 ML 在组织缺陷识别中的应用

球墨铸铁的力学和物理性能取决于石墨球化级别、铸造缺陷及基体组织形态等因素。在工业化生产中,裂纹、缩孔、缩松、夹渣、夹杂和白口等缺陷直接导致铸件废品率高,生产成本增加^[30-31]。为减少缺陷,需要对其生产工艺和显微组织进行深入研究,然而显微组织表征是一个复杂的过程,极其消耗人力和时间成本。ML 可以通过提取合适的特征符,对显微




图7 ML预测铁素体球墨铸铁力学性能结果:(a)成分-机械性能模型训练结果,包括MSE;(b)最佳拉伸强度模型的机械性能预测曲线;(c)铁素体元素含量-相组成的热力学预测曲线^[26]

Fig.7 Machine learning-based prediction of the mechanical properties of ferritic ductile iron: (a) composition-mechanical property model training results with MSE (mean squared error); (b) mechanical property prediction curve of the optimal tensile strength model; (c) thermodynamic prediction curve for the ferrite element content-phase composition relationships^[26]

组织进行定量分析,大大降低成本。

Alrfou等^[32]运用K-means聚类算法对灰度显微图像进行预分割,借助肘部法确定最佳聚类数生成二值掩膜作为训练标签,以此降低人工标注成本,构建基于U-Net架构的全卷积神经网络,引入焦点损失函数以解决石墨-背景像素类别不平衡的问题,采用数据提高技术把13张原始图像扩充至万级训练样本以提升模型泛化能力。结果表明,计算图像的交并比(intersection over union, IOU)达到了96.3%,石墨面积分数预测值与人工ImageJ测量误差小于 $\pm 0.4\%$,形态学开运算可以有效分离粘连颗

粒,如图8所示。De Santis等^[33]开发了基于机器学习的自动化分类系统,借助图像分析、主成分降维和级联支持向量机策略,实现了石墨形态的精确分类。针对传统ASTM标准依赖人工视觉评估问题,该方法从显微图像中提取石墨颗粒的面积、固态度和偏心率等10维特征,经过PCA降维后构建了两级SVM分类器:首级分类器以97.3%的准确率区分标准球状石墨与非标准形态,次级分类器以98.9%的准确率细分Type II与III,并在含噪声图像中呈现出较强的鲁棒性。李健满等^[34]针对蠕化率预测问题,突破传统图像模式识别的时效性限制,提出基于铁




图 8 无监督协同监督学习对球墨铸铁石墨球分割结果:(a) 原始球墨铸铁显微组织中的石墨球分布;(b) 显示石墨球分布的预测输出结果;(c) 标注了预测输出的原始显微照片,显示了石墨球分布^[32]

Fig.8 Segmentation of graphite nodules in ductile iron via unsupervised-coordinated supervised learning: (a) graphite nodule distribution in the original ductile iron microstructure; (b) predicted output displaying the graphite nodule distribution; (c) original micrograph annotated with the predicted results, showing the graphite nodule distribution^[32]

水温度数据的机器学习方法;设计自适应滤波算法,结合最小均方误差与高频信号折中处理环境干扰,避免了传统参照信号偏差问题,构建了免疫记忆克隆选择算法优化支持向量机模型,融合全局搜索与局部寻优能力提升参数效率,实现了蠕化率 9 级分类,实验验证分类精度高达 85.294%。

Zhang 等^[35]针对球墨铸铁管(ductile iron pipe, DCIP)表面缺陷检测中,缺陷样本稀缺(<0.2%)的难题,提出基于 CutPaste-Mix 数据增强的自监督二分类模型,融合擦除、放大和旋转策略生成伪缺陷样本,结合 Res Net-18 提取特征,利用高斯密度估计计

算异常分数进行分类。结果表明,该方法在 DCIP 数据集与实际生产中模型评估指标(area under the curve, AUC)分别达到 99.4%和 99.5%,显著优于传统单分类模型(如 Deep One-Class 的 83.4%),经自动化图像采集系统验证具备产线高效性和实用价值。

Wang 等^[36]提出基于双光光度立体视觉(dual-light photometric stereo vision, DTLPSV)的 DCIP 表面微缺陷在线检测方法。针对气孔、针孔、划痕等微米级缺陷识别难题,设计了对称双光源系统与高速线阵相机协同成像架构,在朗伯反射模型下建立表面纹理梯度解析模型,开发环境光动态补偿算法。构建八通道视觉检

测阵列,集成伺服升降机构实现了 DN350-1 000 mm 管径自适应,并采用双光源时序曝光技术获取表面深度特征图谱,将微缺陷三维形貌转换为二维梯度对比度差异。结果表明,该系统在 6 m 管长检测范围内可实现对 30 μm 级缺陷的识别,较传统二维成像漏检率下降 60%,最高耐受 80 $^{\circ}\text{C}$ 管体温度,单管检测周期缩短至 120 s,为高温复杂工况下的铸管质量在线检测提供了创新解决方案。

Wilk-Kołodziejczyk 等^[37]开发了一种基于决策树的机器学习模型,用于自动化分析球墨铸铁 CT 图像中的夹杂物缺陷。通过定义三阶段灰度分类标准(浅灰:1~40 为细微结构,中灰 40~60 为疏松孔隙,深灰 60~95 为气孔/孔洞)并标注 2000 余颗粒数据,构建了分类模型。经超参数优化(树深度=3、叶节点最小样本数=15),模型在训练/验证/测试集上的准确率分别达到 75.5%、75.8%和 74.3%,将铸件质检时间从人工 4~6 h 缩短至算法 15 min,在工业应用中提升缺陷检出率 22%。

这些成果表明,机器学习在球墨铸铁的研发中具有显著价值,通过对材料样本不足进行数据增强处理以及优化算法解决前期人工标注投入大的问题,实现了对球墨铸铁的显微组织进行高效分析以及对缺陷智能检测。显著降低了球墨铸铁的废品率,带来了切实的降本增效。

4 ML 在服役行为预测中的应用

球墨铸铁服役条件各异,服役特性主要分为腐蚀速率、蠕变率和疲劳强度等。Wang 等^[38]构建了循环水环境模拟系统,结合电化学传感器与 ML 技术,系统分析了球墨铸铁、表面处理球墨铸铁以及碳钢的腐蚀行为和关键影响因素,实验采用 Au/Ti 叉指传感器实时监测水质参数,还借助电偶电流传感器获取 3 种材料的腐蚀电流数据,构建了基于随机森林算法的腐蚀决策模型。结果发现,温度是加速腐蚀的主要因素,表面处理球墨铸铁在 60~90 $^{\circ}\text{C}$ 范围内腐蚀速率呈线性增加趋势,而球墨铸铁与碳钢的腐蚀峰值出现在 80 $^{\circ}\text{C}$,表面处理球墨铸铁因表面存在稳定钝化膜,在高温与氯离子耦合环境下更耐蚀,其腐蚀电流密度远低于未表面处理的球墨铸铁,机器学习模型整合温度与水质参数双变量,实现腐蚀电流预测精度达 $R^2=0.925$ 、平均绝对误差 6%,验证了电化学传感器替代传统多参数监测的可行性。

Ukoba 等^[39]将球墨铸铁试样在近中性、5 mol/L 的 NaOH 和 5 mol/L 的 NaCl 溶液中浸泡 180 天,结合混合自适应神经模糊推理系统(adaptive neu-

ro-fuzzy inference system, ANFIS) - 粒子群优化模型,系统分析了其腐蚀行为与结构完整性,结果表明,NaCl 条件下因 Cl^- 渗透引发纳米级晶界腐蚀而达到最高腐蚀速率;而碱性条件下,由于试样铁素体含量超过 85%和马氏体钝化层的形成,呈现最佳耐腐蚀性。借助模糊 C 均值聚类优化的混合自适应神经模糊推理系统-粒子群优化模型,预测精度达 93.7%,较传统混合自适应神经模糊推理系统,误差降低 38%,体现了腐蚀速率与显微硬度、拉伸强度的非线性关系的有效性,如图 9 所示。

Gebhardt 等^[40]提出基于简化残差神经网络(simplified residual neural network, SimResNet)的数据驱动方法,预测球墨铸铁微观结构与疲劳强度关系。模型提取石墨球最大费雷特直径、面积和长径比作为输入特征,结合安定定理,输出微观力学数值模拟结果。单特征预测结果表明,非球形石墨(V 组)误差值 $\eta=1.55$,球形石墨(RN 组) $\eta=2.37$,形态分布差异直接影响模型性能。多特征组合验证模型捕捉复杂非线性关系能力,精度提升有限。模型预测与数值模拟误差小于 1.58%,计算时间从 8 h 缩减至 40 s,为工业材料疲劳性能评估提供了高效工具。

D'Agostino 等^[41]基于实验和人工神经网络建模,探讨了铁素体-珠光体球墨铸铁疲劳裂纹扩展行为,揭示了应力比对裂纹扩展速率的作用机理。拉伸试样在 $R=0.1\sim 0.8$ 范围内的疲劳测试表明,石墨球/基体界面剥离形成初始损伤,铁素体解理主导裂纹扩展路径,珠光体塑性变形抑制扩展进程。突破了传统 Paris 模型对 R 值引发 $\text{da}/\text{d}N-\Delta K$ 曲线发散/收敛/平行特征的描述瓶颈,并构建了以 R 和 ΔK 为输入的径向基函数网络模型。在 $R=0.6$ 工况下,该模型预测误差低于 3.8%,精准捕获了 R 值通过裂纹闭合效应(石墨阻碍闭合、铁素体脆断)调控扩展速率的非线性机制,为球墨铸铁件多轴疲劳寿命评估建立了高精度预测体系。Vantadori 等^[42]探讨缩孔对球墨铸铁疲劳强度的影响,构建了融合极值理论、 $\sqrt{\text{area}}$ 模型及 Carpinteri 多轴临界平面准则的评估体系。针对 EN-GJS-700-2 材料开展单轴(拉/压、扭转)与多轴(拉-扭复合)疲劳试验,发现 92%失效试样的裂纹源为近表面最大微缩孔。采用极值统计法确定缺陷分布特征,优化重现周期至 $T_{\text{op}}=5.37$,据此计算单轴疲劳极限 $\sigma_w=173.8\text{ MPa}$ 、 $\tau_w=143.6\text{ MPa}$ 。结果表明,86%试样疲劳寿命预测误差可以控制在 $\pm 20\%$ 以内,单轴载荷断裂面方向预测准确率达 100%(拉伸 90 $^{\circ}$ 、扭转 45 $^{\circ}$),多轴工况预测倾角 30 $^{\circ}$ 与部分实验结果吻合。如图 10 所示。




图9 球墨铸铁在近中性溶液中腐蚀预测及实验结果:(a) 自适应神经模糊推理系统模型架构;(b) 输入变量与腐蚀速率的相关性热图;(c) 实验和预测拉伸强度的比较测试图^[39]

Fig.9 Corrosion prediction and experimental validation of ductile iron in near-neutral solutions: (a) ANFIS model architecture; (b) correlation heatmap between the input variables and corrosion rate; (c) comparison of the experimental and predicted tensile strength^[39]




图10 缩孔对球墨铸铁疲劳强度影响预测结果:(a) 拉伸疲劳试验中剪切应力幅值与等效法向应力幅值的关系图;(b) 剪切应力幅值与等效正应力幅值的对比(针对扭转疲劳试验);(c) 双轴疲劳试验中剪切应力幅值与等效法向应力幅值关系图^[42]

Fig.10 Predicted effects of shrinkage cavities on fatigue strength in nodular graphite iron: (a) relationship between shear stress amplitude and equivalent normal stress amplitude in tensile fatigue tests; (b) comparison of shear stress amplitude and equivalent normal stress amplitude in torsional fatigue tests; (c) correlation of shear stress amplitude and equivalent normal stress amplitude in biaxial fatigue tests^[42]

这些研究表明,机器学习能高效辨别影响服役性能的核心因素,并揭示了微观结构与环境因素共同作用下的非线性影响机制,并实现了对服役性能的高精度预测。这不仅帮助研究者揭示了传统方法难以捕捉的复杂失效机理,更提供了可量化、可预测、可优化的工具,有效推动了材料设计范式从“试错型”向“模型驱动型”的关键转变,显著提升了工业

构件的安全性与服役寿命。

5 总结与展望

(1)机器学习在球墨铸铁成分设计、更高性能和缺陷控制,以及良好的服役行为方面提供了方法,加快了新型球墨铸铁结构件的研发。然而,作为材料科学领域一门新兴技术,机器学习也存在一些亟需解

决的问题。如对静态载荷下的抗拉强度、伸长率等力学指标研究相对成熟,但对于动态载荷下的疲劳强度、冲击韧性等预测精度仍有待提升;对合金元素的交互作用的影响机理解释较少,铸造热力学-凝固动力学多尺度关联机制表征不足;对缩孔、缩松和白口等铸造缺陷的预测研究不足,微观组织与宏观性能关联也不够明确;实验数据较为碎片化,工业标准化程度不足。

(2)未来研究应重点突破以下几个方向:首先,构建涵盖成分-工艺-组织-性能全要素的标准化数据库,建立材料基因工程数据平台;其次,通过高维特征解析技术,阐明多元合金元素的交互作用对珠光体/铁素体基体组织的调控机制;再次,发展融合凝固相变动力学与连续介质力学的多尺度跨域建模框架,实现从微观组织到宏观性能的定量推演;最后,开发基于物理信息嵌入的可解释性机器学习方法,重点提升动态力学性能和铸造缺陷的预测精度。这些突破将推动机器学习从数据相关性分析向因果性机理阐释的范式转变,为球墨铸铁的智能化设计提供理论支撑和技术保障。

参考文献:

- [1] 中国铸造协会. 铸造行业“十四五”发展规划[J]. 铸造工程, 2021, 45(4): 1-14.
China Foundry Association. Development plan for the foundry industry in the "14th Five-Year Plan" period[J]. Foundry Engineering, 2021, 45(4): 1-14.
- [2] 王峰. 球墨铸铁的应用及技术发展[J]. 湖北理工学院学报, 2021, 37(6): 54-58.
WANG F. Application and technological development of ductile iron[J]. Journal of Hubei Polytechnic University, 2021, 37(6): 54-58.
- [3] 邵悦翔. 汽车覆盖件模具用高强度合金球墨铸铁的研究[D]. 芜湖: 安徽工程大学, 2019.
SHAO Y X. Research on high strength alloy ductile iron for automobile panel dies[D]. Wuhu: Anhui Polytechnic University, 2019.
- [4] 吕培楷, 林有希, 齐先军. 球墨铸铁消失模铸造涂料的研究进展[J]. 特种铸造及有色合金, 2019, 39(4): 407-411.
LYU P K, LIN Y X, QI X J. Research progress in EPC coatings for nodular cast iron[J]. Special Casting & Nonferrous Alloys, 2019, 39(4): 407-411.
- [5] 刘鹏, 甄立军, 王章明, 于越, 肖远余. 球墨铸铁铸件铸造技术研究进展[J]. 中国铸造装备与技术, 2017(4): 1-6.
LIU P, ZHEN L J, WANG Z M, YU Y, XIAO Y Y. Research progress on casting technology of nodular cast iron casting[J]. China Foundry Machinery & Technology, 2017(4): 1-6.
- [6] 易超. 微合金化对铸态高强韧球墨铸铁材料显微组织和力学性能的影响[D]. 哈尔滨: 哈尔滨理工大学, 2024.
YI C. Effects of microalloying on microstructure and mechanical properties of as-cast high strength and toughness ductile iron material[D]. Harbin: Harbin University of Science and Technology, 2024.
- [7] 曾大新, 何汉军, 张元好, 张战场, 肖海波. 铸态高强度高伸长率球墨铸铁研究进展[J]. 铸造, 2017, 66(1): 38-43, 49.
ZENG D X, HE H J, ZHANG Y H, ZHANG Z C, XIAO H B. Development of as-cast ductile iron with high strength and high elongation[J]. Foundry, 2017, 66(1): 38-43, 49.
- [8] 王文慧. 镍和铬对硅固溶强化球墨铸铁组织和性能的影响[D]. 郑州: 郑州大学, 2019.
WANG W H. Effects of nickel and chromium on microstructure and properties of silicon solution strengthened ductile iron[D]. Zhengzhou: Zhengzhou University, 2019.
- [9] SANDIKOGLU A, GECU R. Microstructural, mechanical and tribological characterization of aluminum-alloyed ductile cast irons based on aluminum content[J]. Journal of Alloys and Compounds, 2021, 879: 160428.
- [10] 骆军, 何世洋, 李志立, 李永博, 王风, 张继业. 热电材料高通量实验制备与表征方法[J]. 无机材料学报, 2019, 34(3): 247-259.
LUO J, HE S Y, LI Z L, LI Y B, WANG F, ZHANG J Y. Progress on high-throughput synthesis and characterization methods for thermoelectric materials[J]. Journal of Inorganic Materials, 2019, 34(3): 247-259.
- [11] JORDAN M I, MITCHELL T M. Machine learning: Trends, perspectives, and prospects[J]. Science, 2015, 349(6245): 255-260.
- [12] KAUFMANN K, VECCHIO K S. Searching for high entropy alloys: A machine learning approach[J]. Acta Materialia, 2020, 198: 178-222.
- [13] YU B W, ZHANG L Q, YE X X, WU J Q, YING H Y, ZHU W, YU Z Y, WU X M. State-of-the-art review on various applications of machine learning techniques in materials science and engineering[J]. Chemical Engineering Science, 2024, 306: 121147.
- [14] YANG Y, XIONG X M, CHEN J, PENG X D, CHEN D L, PAN F S. Research advances of magnesium and magnesium alloys worldwide in 2022[J]. Journal of Magnesium and Alloys, 2023, 11(8): 2611-2654.
- [15] 王艺. 球墨铸铁和氧化锆陶瓷磨削声发射智能监测研究[D]. 长沙: 湖南大学, 2020.
WANG Y. Research on acoustic emission intelligent monitoring for grinding of ductile iron and zirconia ceramics[D]. Changsha: Hunan University, 2020.
- [16] SONG L, ZHANG H C, ZHANG J X, GUO H. Prediction of heavy-section ductile iron fracture toughness based on machine learning[J]. Scientific Reports, 2024, 14: 4681.
- [17] RODRIGUES J F JR, FLOREA L, DE OLIVEIRA M C F, DIAMOND D, OLIVEIRA O N JR. Big data and machine learning for materials science[J]. Discover Materials, 2021, 1: 12.
- [18] FANG T Y, XIE L L, NIU Y R, HONG D, ZHU Y W, WANG Z Y, ZHENG X B. Thermal shock cycle finite element simulation and optimization design of Yb₂SiO₇-based high temperature abradable sealing coatings based on machine learning[J]. Ceramics International, 2025, 51(11): 14160-14173.
- [19] SCHMIDT J, CERQUEIRA T F T, ROMERO A H, LOEW A, JÄGER F, WANG H C, BOTTI S, MARQUES M A L. Improving machine-learning models in materials science through large

- datasets[J]. *Materials Today Physics*, 2024, 48: 101560.
- [20] 吴铮, 李全安, 陈晓亚, 郑泽宇, 张娜娜, 王政. 机器学习在镁合金应用中的研究进展[J]. *工程科学学报*, 2024, 46(10): 1797-1811.
- WU Z, LI Q A, CHEN X Y, ZHENG Z Y, ZHANG N N, WANG Z. Applications of machine learning on magnesium alloys[J]. *Chinese Journal of Engineering*, 2024, 46(10): 1797-1811.
- [21] 施思齐, 孙拾雨, 马舒畅, 邹欣欣, 钱权, 刘悦. 融合材料领域知识的数据准确性检测方法[J]. *无机材料学报*, 2022, 37(12): 1311-1325.
- SHI S Q, SUN S Y, MA S C, ZOU X X, QIAN Q, LIU Y. Detection method on data accuracy incorporating materials domain knowledge[J]. *Journal of Inorganic Materials*, 2022, 37(12): 1311-1325.
- [22] LI R S, MA H, WANG R, SONG H, ZHOU X M, WANG L, ZHANG H O, ZENG K, XIA C Y. Application of unsupervised learning methods based on video data for real-time anomaly detection in wire arc additive manufacturing[J]. *Journal of Manufacturing Processes*, 2025, 143: 37-55.
- [23] 胡瑞祎. 基于机器学习预测半导体材料弹性及介电性质[D]. 西安: 西安理工大学, 2024.
- HU R Y. Predicting elastic and dielectric properties of semiconductor materials using machine learning[D]. Xi'an: Xi'an University of Technology, 2024.
- [24] LI Z Z, FENG D W, LI D S, LU X C. Learning to select pseudo labels: A semi-supervised learning method for named entity recognition[J]. *Frontiers of Information Technology & Electronic Engineering*, 2020, 21(6): 903-916.
- [25] FRAGASSA C. Material selection in machine design: The change of cast iron for improving the high-quality I in woodworking[J]. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 2016, 231: 18-30.
- [26] GU S Y, YAO Z X, LI M W, QU N, BU E J, BAI X S, LIU Y, LAI Z H, ZHU J C. Mechanical properties prediction of ferrite ductile iron via machine learning[J]. *Physica Scripta*, 2023, 98(12): 126003.
- [27] RAM N, GAUTAM V. Prediction of effect of alloying elements on properties of ferritic grade Si-Mo ductile cast iron using regression analysis[J]. *Materials Today: Proceedings*, 2022, 62: 3855-3859.
- [28] FERNÁNDEZ-CALVO A I, GARAY J, JOHNSON D, MONTEIRO C, GONZÁLEZ-ZABALA A, SUÁREZ R. New approach to develop ductile cast iron digital grade for automotive components[J]. *International Journal of Metalcasting*, 2023, 17: 1558-1568.
- [29] FRAGASSA C, BABIC M, BERGMANN C P, MINAK G. Predicting the tensile behaviour of cast alloys by a pattern recognition analysis on experimental data[J]. *Metals*, 2019, 9(5): 557.
- [30] FUTAS P, PRIBULOVA A, SABIK V, PETRIK J, BLASKO P, BRZEZIŃSKI M. Elimination of shrinkage in ductile iron castings using computer simulation of casting and solidification[J]. *Processes*, 2024, 12(3): 506.
- [31] XU W D, ZHANG W, LIU X M, QU Y D, HAO Y H, LIU S, LI G L. Effect of copper on the microstructure and fracture toughness of heavy-section pearlitic ductile iron[J]. *Journal of Alloys and Compounds*, 2025, 1026: 180440.
- [32] ALRFOU A, KORDIJAZI A, ROHATGI P, ZHAO T. Synergy of unsupervised and supervised machine learning methods for the segmentation of the graphite particles in the microstructure of ductile iron[J]. *Materials Today Communications*, 2022, 30: 103174.
- [33] DE SANTIS A, IACOVIELLO D, DI COCCO V, IACOVIELLO F. Classification of ductile cast iron specimens: A machine learning approach[J]. *Frattura ed Integrità Strutturale*, 2017, 42: 231-238.
- [34] 李建满. 机器学习在球墨铸铁蠕化率问题的应用研究[D]. 天津: 河北工业大学, 2011.
- LI J M. Research on vermicularity of ductile iron based on machine learning[D]. Tianji: Hebei University of Technology, 2011.
- [35] ZHANG H X, SUN Q, XU K. A self-supervised model based on CutPaste-Mix for ductile cast iron pipe surface defect classification[J]. *Sensors*, 2023, 23(19): 8243.
- [36] WANG S, XU K, LI B H, CAO X Y. Online micro defects detection for ductile cast iron pipes based on twin light photometric stereo[J]. *Case Studies in Construction Materials*, 2023, 19: e02561.
- [37] WILK-KOŁODZIEJCZYK D, NOWOTNY A, KRZAK I, TCHÓRZ A, JAŚKOWIEC K, MAŁYSZA M, BITKA A, GŁOWACKI M, KSIĄŻEK M, MARCJAN Ł. Development of a model for detection and analysis of inclusions in tomographic images of iron castings using decision trees[J]. *Scientific Reports*, 2025, 15(1): 1880.
- [38] WANG B Q, ZHAO L, CHEN Y F, ZHU L S, LIU C, CHENG X Q, LI X G. Intelligent corrosion analysis and life prediction of ductile iron pipe systems using machine learning and electrochemical sensors[J]. *Journal of Materials Research and Technology*, 2024, 33: 725-741.
- [39] UKOBA K, AKINRIBIDE O J, ADELEKE O, AKINWAMIDE S O, JEN T C, OLUBAMBI P A. Structural integrity and hybrid ANFIS-PSO modeling of the corrosion rate of ductile irons in different environments[J]. *Kuwait Journal of Science*, 2024, 51(3): 100234.
- [40] GEBHARDT C, TRIMBORN T, WEBER F, BEZOLD A, BROECKMANN C, HERTY M. Simplified ResNet approach for data driven prediction of microstructure-fatigue relationship[J]. *Mechanics of Materials*, 2020, 151: 103625.
- [41] D'AGOSTINO L, DE SANTIS A, DI COCCO V, IACOVIELLO D, IACOVIELLO F. Fatigue crack propagation in ductile cast irons: an artificial neural networks based model[J]. *Procedia Structural Integrity*, 2017, 3: 291-298.
- [42] VANTADORI S, RONCHEI C, SCORZA D, ZANICHELLI A, LUCIANO R. Effect of the porosity on the fatigue strength of metals[J]. *Fatigue & Fracture of Engineering Materials & Structures*, 2022, 45(9): 2734-2747.

(责任编辑: 杨浩雪)