球墨铸铁小样本数据驱动策略研究进展

张泽沛，黎振华，刘美红，涂雯雯，赵国荣，刘　禹，谢　明
（昆明理工大学机电工程学院，云南昆明 650500）

摘要：球墨铸铁成分复杂，其成分、组织与力学性能间存在强非线性耦合关系，传统试错法难以高效平衡研发成本与性能优化需求。数据驱动方法为突破这一瓶颈提供了新范式，但该领域试验数据普遍仅有几十至数百组，严苛的小样本约束使深度模型难以直接应用，亟需适配性策略支撑。本文从结构化与非结构化数据双重视角，系统梳理了近十年球墨铸铁小样本数据驱动研究进展。结构化数据方面，归纳了基于主成分分析与聚类联用的特征精简和性能边界划分策略，分析了支持向量机、浅层神经网络及集成学习（随机森林、XGBoost、CatBoost）在小样本回归与分类中的适用边界，重点论述了以神经网络或XGBoost为代理模型、结合遗传算法实现多目标逆向设计的“正向预测-逆向寻优”技术路径。非结构化数据方面，总结了几何数据增强与自监督学习在金相图像样本扩充中的应用，以及轻量化网络在降低标注依赖方面的成效。研究发现，现有策略的核心共识在于：浅层模型与集成学习因参数量少、抗过拟合强，目前仍是小样本数值型数据建模的主流选择；聚类预处理可将分类准确率从约80%提升至100%，数据增强可使识别准确率从86.67%提升至94.44%。然而，现有方法普遍存在物理机制仅用于事后验证而未能嵌入模型训练、逆向设计结果缺乏试验佐证、模型难以随新数据低成本迭代更新等共性局限。未来应着力发展物理约束嵌入的可解释学习框架、融合主动学习的半监督迭代策略，并建立标准化共享数据库，以推动数据驱动方法在球墨铸铁工程实践中的可靠落地。

关键词：球墨铸铁；数据驱动；小样本；机器学习；逆向设计；金相表征
中图分类号：TG143.5；TH142.1；TP181　**文献标识码：**A　**文章编号：**1001-4977（2026）09-0943-10
DOI：10.27014/j.cnki.zhuzao.2026.0121

Research Progress on Small Sample Data-Driven Strategies for Ductile Iron

ZHANG Ze-pei, LI Zhen-hua, LIU Mei-hong, TU Wen-wen, ZHAO Guo-rong, LIU Yu, XIE Ming
(Faculty of Electromechanical Engineering, Kunming University of Science and Technology, Kunming 650500, Yunnan, China)

Abstract: Ductile iron has a complex composition, with strongly nonlinear coupling among composition, microstructure and mechanical properties, making traditional trial-and-error approaches inefficient for balancing R&D cost and performance optimization. Data-driven methods provide a new paradigm to overcome this bottleneck. However, experimental data in this field are generally limited to dozens to several hundred samples, and such severe small-sample constraints hinder the direct application of deep models, calling for tailored strategies. This review systematically examines the research progress in small-sample data-driven strategies for ductile iron over the past decade from both structured and unstructured data perspectives. For structured data, it summarizes feature reduction and performance boundary delineation strategies based on principal component analysis combined with clustering, analyzes the applicability boundaries of support vector machines, shallow neural networks and ensemble learning (random forest, XGBoost, CatBoost) in small-sample regression and classification tasks, and highlights the “forward prediction—inverse optimization” paradigm that employs neural networks or XGBoost as surrogate models coupled with genetic algorithms for multi-objective inverse design. For unstructured data, it reviews the application of geometric data augmentation and self-supervised learning in metallographic image sample expansion, as well as the effectiveness of lightweight networks in reducing annotation dependence. Key findings indicate that shallow models and ensemble learning, characterized by fewer parameters and strong overfitting resistance, remain the mainstream choices for small-sample numerical data modeling; clustering pre-processing can improve classification accuracy from approximately 80% to 100%, and

基金项目：云南省贵金属实验室重大科技专项（YPML-202405020889）；云南省科技重大项目（202402AG050003-2）。
收稿日期：2026–03–17 收到初稿，2026–05–24 收到修订稿。
作者简介：张泽沛（2000–），女，硕士生，主要从事球墨铸铁成分和性能优化的机器学习研究工作。E-mail：18595283307@163.com
通信作者：刘美红，女，博士，教授，博士生导师。E-mail：13648861980@163.com
引用格式：张泽沛，黎振华，刘美红，等 . 球墨铸铁小样本数据驱动策略研究进展 [J]. 铸造，2026，75（9）：943–952.
Zhang Zepei，Li Zhenhua，Liu Meihong，et al. Research progress on small sample data-driven strategies for ductile iron [J]. Foundry，2026，75（9）：943–952.

data augmentation can enhance recognition accuracy from 86.67% to 94.44%. However, common limitations persist: physical mechanisms are used only for post-hoc verification rather than being embedded into model training, inverse design results lack experimental validation, and models are difficult to update iteratively at low cost as new data become available. Future efforts should focus on developing interpretable learning frameworks with physical constraints, semi-supervised iterative strategies integrated with active learning, and establishing standardized shared databases to promote the reliable deployment of data-driven methods in ductile iron engineering practice.

Key words: ductile iron; data-driven; small sample regime; machine learning; inverse design; metallographic characterization

球墨铸铁具有优异的综合力学性能、良好的铸造性能和相对低廉的制造成本，应用广泛[1]。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。然而，球墨铸铁成分复杂，其成分、组织与力学性能之间存在着复杂的非线性关系，且受热处理工艺、冷却速率等多重因素的共同影响[2-5]。传统试错法依赖于研究者的经验积累，通过设置离散的成分与工艺参数开展有限的试验探索，不仅耗费大量的时间和成本，也难以从有限样本中梳理出各变量之间的内在规律，制约了球墨铸铁材料的研发与优化进程[6-7]。

近年来，以数据与人工智能为标志的数据驱动研究范式，已成为继实验科学、理论分析和计算模拟之后的材料科学第四范式[8-9]。其中，机器学习作为数据驱动科学的核心技术之一，已在高熵合金[10-12]、铝合金[13-14]、镁合金[15]、铜合金[16]等诸多材料体系中展现出强大的预测与设计能力。但其应用效果高度依赖于数据的数量与质量，而目前球墨铸铁的试验数据规模普遍偏小，多数研究仅基于几十到几百个样本开展。这种小样本特征使得对数据量要求较高的深度模型难以直接应用。如何结合数据特征选取适宜的机器学习策略，成为提升模型泛化能力与可解释性的关键。

本文聚焦球墨铸铁在小样本约束下的数据驱动研究，从结构化数据与非结构化数据视角，梳理现有研究在特征处理、模型选择、逆向设计及图像分析中的应对方法，归纳不同策略的适用条件与现存局限，并对未来发展方向进行展望，以期为该领域的后续研究提供参考。

1 数据驱动与球墨铸铁小样本约束

1.1 数据驱动

数据驱动的机器学习借助算法从数据中挖掘规律与关系[17]。根据标注数据的使用情况，其可分为监督学习与无监督学习。监督学习依托特征变量和标签变量构建预测模型，主要包含回归和分类两类任务。无监督学习无需依赖预设标签，能够实现降维与聚类，消除数据共线性问题，进而为后续的监督学习提供低维输入。

数据驱动流程如图1所示，包含3个核心步骤。第一步，数据获取与预处理。数据大多来源于生产样本。受成本与周期限制，数据集规模较小（几十至数百组）。原始特征主要包括化学成分、工艺参数、缺陷以及金相图等。通过异常值剔除、归一化、主成分分析降维（PCA）等预处理操作，能够剔除冗余噪声，得到低维纯净输入数据。第二步，模型选择、训练与评估。结合小样本特点和任务目标优选模型，优先选用可抑制过拟合的基础算法，并采用均方根误差（RMSE）、均方误差（MSE）、决定系数（R2）等指标评估模型精度。第三步，模型验证与应用。使用独立测试集验证模型的泛化能力。经过验证的高精度模型不仅可用于正向性能预测，还能作为代理模型，支撑逆向设计等相关应用。

1.2 小样本约束下的常见机器学习算法

算法选择直接决定数据驱动研究的效果。决策树（DT）、支持向量机（SVM）和随机森林（RF）等基础算法，是处理此类小样本数值型数据常用且有效的工具。这类算法参数量少、抗过拟合能力强，部分具备可解释性，能够高效挖掘出成分-工艺-组织-性能之间的非线性映射关系。人工神经网络（ANN）等结构更为复杂的算法，在处理结构化数值数据时，需要严格控制隐藏层深度以避免过拟合；针对金相图像等非结构化数据，轻量化卷积神经网络结合数据增强或自监督学习，可自动提取图像高维特征并完成组织分类。小样本场景下球墨铸铁领域常用机器学习算法的总结如表1所示。

2 结构化数据的小样本驱动策略

2.1 基于无监督学习的特征精简与边界划分

球墨铸铁的性能受成分与工艺等多重因素耦合影响。当特征维度较高且样本量有限时，特征间的共线性会掩盖真实规律。因此，在小样本学习中先采用无监督降维与聚类提取精简特征，可为后续监督学习提供可靠输入[18]。

2.1.1 基于主成分分析的特征精简

高维特征间的相互牵制是小样本数据驱动研究中的常见问题。PCA可将原始变量组合成具有物理意义



图1 数据驱动全流程示意图

Fig. 1 Schematic diagram of the data-driven workflow

表1 球墨铸铁小样本场景下常用机器学习算法

Tab. 1 Common machine learning algorithms for ductile iron in small-sample scenarios

算法类别	算法原理	小样本下的使用
线性模型（多元线性回归、岭回归）	拟合特征与目标的线性关系	参数极少，无明显过拟合风险，可解释性强
支持向量机（SVM）	寻找最优超平面完成分类与回归	基于结构风险最小化，小样本泛化能力强
决策树模型（DT、CART）	递归分裂特征实现分类/回归	无需数据标准化，规则显式直观，可解释性好
集成学习（RF、XGBoost、CatBoost）	组合弱学习器投票或加权平均	提升预测精度，抗过拟合能力突出
神经网络（ANN）	前向/反向传播优化权重	需控制隐藏层深度，避免过拟合
轻量化深度学习（SimResNet）	简化结构降低参数量	面向图像任务，结合数据增强/预训练使用

的复合描述符。Tlatlik等[19]采用PCA结合岭回归分析核废料储存用球墨铸铁。首先使用PCA将6项微观参数降维为两个主成分（PC1：微观结构粗化度；PC2：石墨含量）。随后引入测试条件再次降维，再结合K-means与岭回归分析，发现在本研究范围内，测试条件对屈服强度的影响更为突出，抗拉强度和断裂伸长率则主要受石墨球化率和珠光体分数控制。

降维与聚类联用可在有限样本内实现工艺反向优化。Ha等[20]结合田口法与PCA，利用18组样本完成球墨铸铁工艺寻优。经过信噪比（S/N）变换与PCA处理，对包含力学性能及石墨微观组织特征在内的9项关键数据进行降维，提取出两个核心主成分（PC1由强度主导，PC2由韧性主导）。随后采用K-means算法将样本划分为高强度型、高韧性型与平衡型三类，据此确定可达成特定性能目标的优选工艺组合（例如使用含稀土球化剂、控制处理温度高于1 470 ℃，即可制备出高强度样品），最终实现从多变量信息中挖掘核心规律。

2.1.2 基于聚类算法的材料性能边界划分

聚类可将数据划分为类内紧密、类间分离的簇结构[21]。常见无监督聚类方法及适用场景如表2所示。

性能边界模糊时，监督学习分类器难以划定有效的决策边界。为实现用含碳化物球墨铸铁（NCIC）替代等温淬火球墨铸铁（ADI），Wilk-Kołodziejczyk等人[22]先采用期望最大化（EM）聚类将力学数据分为4簇，使后续分类器的准确率从80.9%提升至100%。聚类算法在服役性能评估中同样适用。针对球墨铸铁在输水管线复杂介质中的长期腐蚀行为，Ukoba等人[23]提出了一种结合自适应神经模糊推理系统（ANFIS）、粒子群优化算法（PSO）与模糊C均值聚类（FCM）的混合模型（ANFIS-PSO-FCM）。该模型以暴露时间、环境类型、重量损失为输入，同步预测腐蚀速率、硬度与

表2 常见无监督聚类算法原理及其在材料数据驱动中的适用场合

Tab. 2 Principles of common unsupervised clustering algorithms and their applicability in the data-driven materials research

聚类方法大类	核心原理	球墨铸铁数据驱动中的适用场合
划分式聚类（如K-means）	预设簇数，迭代优化聚类中心	适用于边界清晰的成分/工艺数据，配合降维定位性能区间
模糊与概率聚类（如EM、FCM）	以概率/模糊隶属度实现软划分	适合处理性能边界模糊的数据
基于密度的聚类（如DBSCAN）	无需预设类簇数，依数据密度识别任意形状簇	适用于建模前识别并剔除数据噪声和异常值

强度。研究对比了FCM、减法聚类与网格分区三种方法，发现FCM处理异构腐蚀数据的效果最佳，预测精度达93.7%。

无监督学习虽不直接输出预测结果，但可通过降维精简特征、借助聚类划分边界，有效解决小样本场景下的维度灾难问题。在得到纯净的低维输入后，选用合适的监督学习模型挖掘成分、工艺与性能之间的映射关系，是构建高精度数据驱动模型的关键。

2.2 小样本约束下的监督学习预测

由于获取试验数据成本高、周期长，材料数据通常规模较小[24-25]，样本量往往只有几十到几百组。复杂的深度神经网络（DNN）容易陷入过拟合，而浅层机器学习模型因样本需求低、可解释性好、抗过拟合能力强，成为小样本场景下挖掘非线性规律的主流选择。图2为小样本浅层模型选择策略。

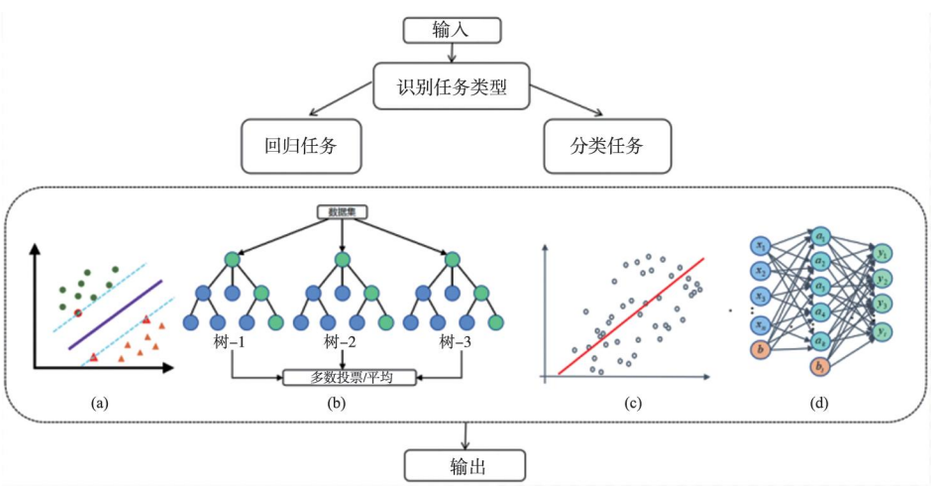

（a）SVM；（b）DT；（c）线性回归；（d）NN

图2 小样本场景下浅层模型的选择策略

Fig. 2 Selection strategies for shallow models in the small-sample regime

2.2.1 浅层模型在小样本中的回归与分类应用

模型与数据规模匹配是提升泛化能力的核心。对于存在强线性相关、样本数量极少的任务，多元线性回归（MLR）可避免过拟合并实现变量重要性解读。Ram和Gautam[26]探究了MLR在小样本场景下筛选关键合金元素的效果，并借助方差分析（ANOVA）量化了各类元素的贡献率。由于影响球墨铸铁性能的因素通常复杂且呈现非线性特征[27]，因此需要引入适配性更强的映射工具。Khalaf和Hanon[28]证实，相较于双隐层人工神经网络，单隐层ANN对摩擦系数的预测精度更高。Fragassa等人[29]利用浅层神经网络，在小样本条件下精准预测材料硬度，同时还原了性能的波动规律。

Gu等[30]对比了多种算法发现，针对不同力学性能需采用不同最优模型，其中高斯过程（GP）对硬度和抗拉强度预测效果最佳，集成树（ET）更适合屈服强度与伸长率预测；该研究还引入了Thermo-Calc热力学计算作为验证手段，将机器学习预测的成分-性能规律与热力学相变规律相互印证，证实数据驱动模型所捕捉的非线性规律具备物理可解释性。

分类任务中，SVM凭借强泛化能力与稳定性得到广泛应用[31-32]。Wilk-Kołodziejczyk等[22]将SVM用于铸铁材料类型判别，准确率优势显著。De Santis等[33]进一步证明了SVM在金相图像分类任务中具备较高的精度与鲁棒性。为清晰对比上述研究的方法与效果，相关研究对比如表3所示。

以上研究表明，合理选择浅层模型可显著缓解小样本局限。在回归任务中，线性模型和浅层神经网络已能获得可观精度；分类任务中，SVM泛化能力突

表3 球墨铸铁性能预测与分类相关研究对比

Tab. 3 Comparative studies on the performance prediction and classification of ductile irons

研究文献	任务类型	样本量	模型	关键结果	验证方式
[26]	回归（硬度、强度等）	10组	MLR	R^2=83%~90% 误差0.1%~8.94%	回归拟合、残差正态检验、方差分析
[28]	回归（摩擦系数）	81组	单隐层ANN	MSE=0.0123 R^2=0.9992	训练/测试/验证集划分、交叉验证
[29]	回归（拉伸性能）	48组（SGI27+CGI21）	ANN	预测误差<15%	相关性分析
[30]	回归（力学性能）	248组（源自文献）	GP ET	R^2>0.96 平均相对误差4.43%	文献数据/热力学验证
[22]	分类（材料类型）	264组	SVM	验证集准确率80.4%	训练/测试/验证集划分
[33]	分类（石墨形态）	192张金相图	SVM+PCA	总准确率97.3%	10折交叉验证 随机抽样重复验证

出。这类浅层模型与样本规模匹配性好，能够在数据量有限时稳定完成回归与分类任务。

2.2.2 集成学习预测模型构建

复杂形貌识别与强交互工艺参数场景需进一步提升模型拟合能力。相较于依赖海量数据的深度网络，基于树模型的集成学习在小样本下更具优势[34]。

决策树因其结构直观、易于解释，能自适应划分非线性特征空间。Wilk-Kołodziejczyk等先后将其应用于球墨铸铁的工艺优化与缺陷识别。在ADI的研究中[35]，基于432组试验数据构建了分类与回归树（CART）模型，以热处理工艺与成分为输入、冲击功为输出，R^2高达0.967，显著优于线性回归（R^2=0.82）与ANN（R^2=0.93）。更重要的是，CART模型生成了可解释的决策规则。针对CT图像中石墨与缺陷难以区分问题[36]，采用决策树实现灰度、体积等特征分类。该研究不仅挖掘出关键体积阈值，并通过网格搜索交叉验证（GridSearchCV）将训练集测试精度差控制在1.5%以内，调参后的决策树结构如图3所示[36]。但上述研究共同揭示出单一树模型存在精度上限，图像分类准确率仅约75%，难以满足工业场景中对缺陷类型进行

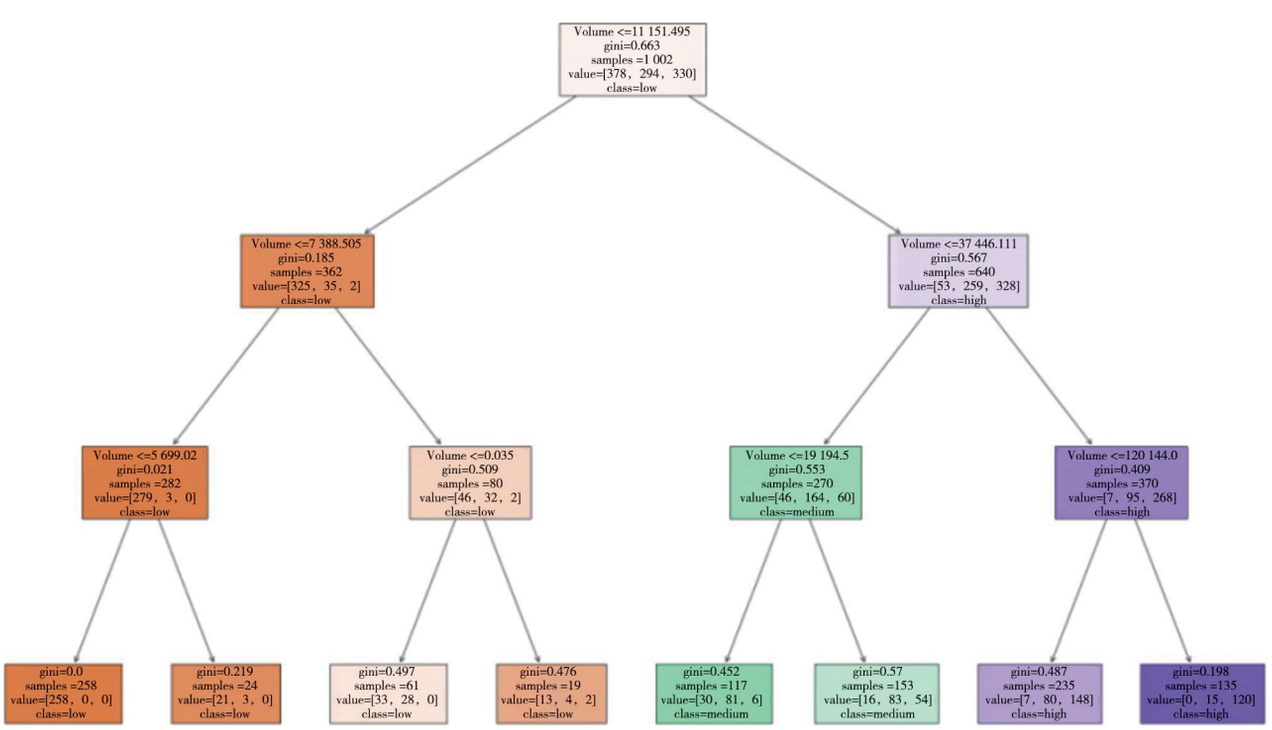

图3 超参数优化后的决策树结构

Fig. 3 Decision tree structure after hyperparameter optimization

精准识别与定级的需求。因此，此类研究需结合更多特征或数据扩增以提高预测精度、满足工业需求。

为突破单一树模型的精度上限，集成学习可通过组合多个弱学习器提高拟合能力[34]。Song等[37]针对厚大断面球墨铸铁，用72个有效样本，以C、Si和Mn元素含量及冷却速率为输入特征，断裂韧性为输出，构建了包括Bagging、RF和XGBoost等集成模型，其中Bagging模型的预测精度最优，R^2达0.999 0，RMSE仅0.237 3。这说明，集成学习在处理高成本有限数据时具有较强的抗过拟合能力。

集成学习虽精度更高，但会丢失单一树模型的可解释性，因此需引入可解释框架[38]。Su等[39]基于200个文献样本构建数据集，划分为多个性能子集，以C、Si、Mn、Mg、Re、Ni含量及退火温度、时间为输入特征，对比六种集成算法，发现CatBoost预测抗拉强度（R^2=0.871）和伸长率（R^2=0.898）时表现最佳，极端随机树更适用于低温冲击能的预测。结合SHAP量化特征贡献，指出Ni、Si和退火温度分别是影响抗拉强度、伸长率和低温冲击性能的关键因素。Gebhardt等[40]提出的简化残差网络以石墨颗粒的几何特征预测疲劳强度，在小样本下避免过拟合，计算效率提升显著，相对误差仅1.58%，表明合理设计的深度学习可适配小样本场景。

综上，集成学习可有效提升预测精度。但是在实际的工程中，往往所需的不是这个成分最高能提升多少性能，工艺与性能有多强的关系等，而是基于目标性能反推成分与工艺。这种通过满足性能目标而寻找生产条件的研究，可使用逆向设计进行。

2.3 基于代理模型的成分、工艺逆向设计

逆向设计是根据所需性能反向确定具体工艺或合金成分的方法，需先构建精度可靠的代理模型替代成本高昂的物理实验。

ANN与遗传算法集成已经成为材料科学中逆向设计的主流范式。面对涉及大量元素及工艺间复杂交互的高维非线性空间，DNN效果更优。Ferro等[41]提出DNN-遗传算法混合策略，在保证性能前提下降低关键原材料（CRMs）依赖，流程如图4所示（依据文献[41]重绘）。其核心思路是在力学性能达标前提下，通过优化化学成分最小化CRMs的使用，降低供应链风险。研究基于1 160条数据，29种化学元素含量为输入构建模型。同时，为验证全维度输入的必要性，与Gu等[30]选取铁素体球墨铸铁的C、Si、Mn、Mg、Ni和RE等6种关键元素进行了消融对比。结果显示，29元素的模型在抗拉强度预测上的R^2为0.963，高于6种元素模型的

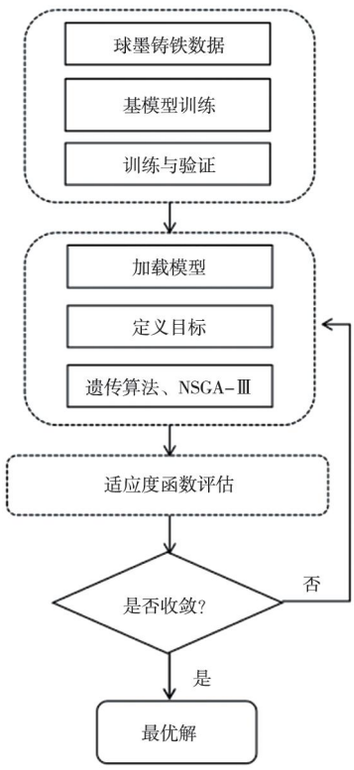

图4 深度神经网络与遗传算法集成的逆向设计简化流程图

Fig. 4 Simplified flowchart for inverse design integrating deep neural networks and genetic algorithms

0.936。获取高精度正向预测模型后，以DNN为代理模型结合遗传算法，以最小化合金临界性指数（CI_a）为目标，冶金规则为约束反推成分。该方法在三种典型球墨铸铁牌号中均有成效，CI_a降幅达30.3%~32.3%，研究对优化后的成分进行的冶金可行性约束有效克服了纯数据驱动模型在外推时易脱离冶金物理规律的缺陷，为此类逆向寻优方法提供了一种切实可行的研究思路。

为打破传统机器学习模型仅能正向预测的局限，Wiangkham等[42]将XGBoost与遗传算法结合，实现ADI多性能协同优化。基于243组数据构建代理模型，以四项热处理参数为输入、四项力学性能为输出，采用NSGA-Ⅲ搜索帕累托最优解。经种群迭代后获得稳定最优解区域，且平行坐标图的验证表明优化结果与实验数据高度一致。在样本量受限的情况下，该方法可有效替代试错试验，为工业场景提供兼顾多项性能的最优工艺组合。

基于代理模型的逆向设计实现“预测-寻优”的模式，大幅降低研发成本，为球墨铸铁多目标性能定制提供了可借鉴的技术路径。与传统正向预测不同，逆向设计的核心在于高精度代理模型与优化算法的深度融合，其结果必须满足冶金约束才能用于实际生产。

3 非结构化数据的小样本驱动策略

显微组织的自动量化与缺陷识别是球墨铸铁质量评价的关键。石墨形态直接影响力学性能，不规整石墨易引发应力集中与裂纹萌生。金相图像数据具有高维度、高信息密度的特点，样本获取与标注成本远高于结构化数据。传统图像分析（QIA）依赖人工设定特征阈值，效率低且主观性强；深度学习模型特征提取能力强，但对标注样本需求量大，难以在小样本场景直接应用。针对这一矛盾，目前主要解决路径包括：数据增强和无监督预标注扩充样本；简化网络结构降低模型对样本量的需求。

3.1 基于数据增强的样本扩充策略

针对金相图像样本稀缺的问题，几何数据增强是激活深度神经网络的有效手段之一。Germain等[43]以19张含多类石墨共存的显微图像为基础，经旋转、裁剪增强生成4 339张子图。基于Xception卷积神经网络实现石墨颗粒自动分类，I类片状石墨识别准确率达90.3%，V/VI类球状石墨联合识别准确率超90%，效果显著优于传统QIA。

为实现多类型铸铁的细致化分类，Zhao等[44]从ASM数据库选取不同种类铸造合金金相图像，通过旋转、高斯噪声添加和镜像等方法扩充数据。对比表明，数据增强使预测准确率从86.67%提升至94.44%。研究采用MobileNetV2网络与ImageNet预训练，实现15个细分类别识别，可同时区分材料类型、显微镜型号、放大倍数及蚀刻剂类型等信息，验证了预训练与数据增强结合的有效性。

图像识别除样本量不足外，标注成本高是另一难题。为实现石墨球与基体图像分割，Alrfou等[45]提出无监督学习协同有监督深度学习的优化路径。先利用K-means聚类生成二值掩膜作为训练标签，避免昂贵的人工标注；再基于U-Net构建分割模型，通过翻转、转置、随机旋转和网格变形的数据增强方式扩充样本，并采用焦点损失函数缓解数据不平衡。模型测试集交并比（IoU）达96.3%，石墨面积分数预测值与人工测量值误差控制在 ± 0.4%以内，仅需13张样本即可完成训练。

Rosenberger等[46]将实例分割引入球墨铸铁断口分析，基于Mask R-CNN从断口SEM图像中检测石墨颗粒。与金相磨面不同，断口分析可直接观察参与断裂的石墨球，避免随机截面导致的尺寸误估。为缓解样本有限的问题，采用切块、翻转、随机亮度/对比度/饱和度等增强方式。模型检测精确率达70%，召回率75%，其预测标注结果如图5所示[46]。同时采用4象限背散射电子信号重建断口三维形貌，对面积分数和颗粒密度三维修正，使结果更接近真实值。研究发现，相较于磨平分析，断口石墨颗粒平均直径更大、圆度更低，为裂纹萌生机制研究提供了更真实失效数据。

综上，基于数据增强的金相图像分析仍以实验室验证为主，多在标准试样或公开数据库测试，真实工业环境泛化能力尚未充分评估。如何在实际生产中考虑制样差异、图像采集条件变化等干扰，是这些方法走向应用的关键。同时，如何在保证精度的前提下降低专用设备和人工标注依赖，也需进一步探索。

3.2 基于模型简化降低样本需求策略

除了从数据层面扩充样本，选择更适配的网络结构也能缓解模型对样本量的依赖。Zhang等[47]针对球墨铸铁管（DCIP）表面缺陷样本占比低于0.2%的问题，提出基于CutPaste-Mix的自监督学习方案，全程无需真实缺陷样本参与训练。模型通过擦除、放大和旋转三种方法对无缺陷图像进行局部处理，模拟不规则特征以生成正样本，与原始无缺陷图像（负样本）构成自监督任务。考虑到工业生产线对检测速度的要求，选定计算复杂度低、梯度传播稳定的ResNet-18网络。利用该网络提取正常图像的特征，通过高斯密度估计建立正常样本统计基准，实现异常图像分类。模型在DCIP专用数据集上ROC曲线下面积高达0.995。验证方面，模型在现场连续采集的10 000张图像中测试，识别出43张异常图像，经人工比对确认其中20张为真实缺陷。自动过滤绝大多数正常图像后，人工复核范围缩小至0.5%以下，可显著降低人工检测负担，具备工业现场应用潜力。

Gajoch等[48]系统比较三种深度学习模型在ADI微观组织缺陷检测中的表现。采用K-means聚类生成训练标签，分别训练ResNet50图像分类、U-Net像素级分割、YOLOv8目标检测。结果显示，ResNet分类准确率78%，适用于初步筛选；U-Net分割IoU达0.66，适合精细定量分析；YOLO检测mAP达0.83，推理时间仅0.02~0.03秒/图，适合工业在线检测。该研究为不同应用场景下模型选择提供了参考。

可见，通过自监督学习与多模型对比等模型层面优化，同样能有效降低深度学习对样本量的需求。但当前研究仍面临挑战：Zhang等[47]指出，异常检测中模型难以区分真实缺陷与水渍、油污等噪声干扰，可引入多任务学习或者与物理信息融合，引导模型关注具有物理意义的缺陷特征。此外，非结构化数据分析多基于二维图像，难以捕捉微观结构的三维空间特征，

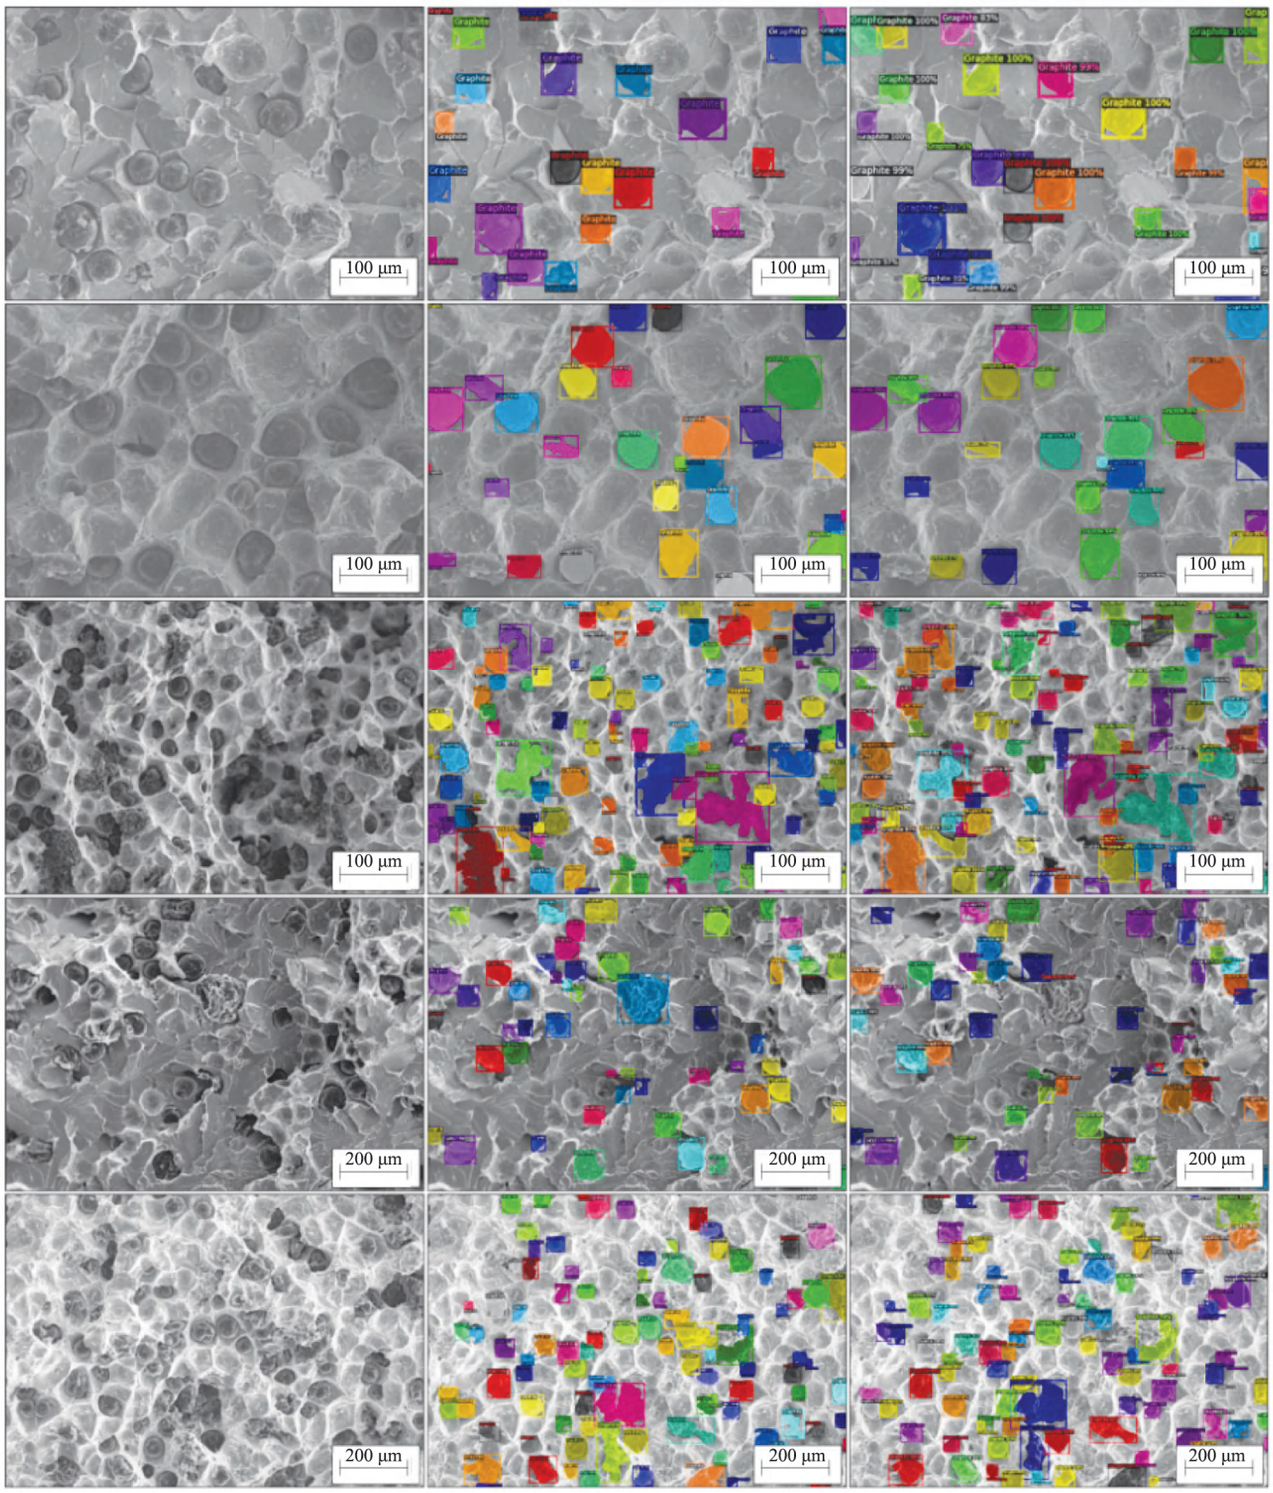

图5 Mask R-CNN模型在球墨铸铁断口图像上的石墨颗粒识别效果

Fig. 5 Graphite nodule recognition performance of the Mask R-CNN model on the ductile iron fracture images

未来可结合三维表征，实现贴近真实工况的微观组织分析。

4 总结与展望

小样本数据驱动球墨铸铁研究已取得长足进步，但目前，大量研究模型和数据分散在各类文献中，样本量小、格式不统一，缺乏标准化共享数据库，难以直接复用。从验证与应用的层面看，现有研究多停留在实验室数据或文献数据验证，工业现场实测较少，模型在实际生产环境中的泛化能力、稳定性仍需进一

步检验。发展适合小样本场景的迁移学习和数据增强方法，利用相近钢铁材料的数据积累，通过迁移学习引入相关领域知识或采用数据增强，可一定程度上缓解样本不足，但生成样本的可靠性及物理合理性需认真分析。引入相变动力学、分子动力学等原理嵌入模型训练，研发可解释性学习策略，在样本有限时做出符合冶金规律的预测，并通过逆向寻优方法获得优化结果，这些都为解决小样本问题提供了思路。未来仍需结合试验验证，进一步评估工艺参数波动、多目标权衡、生产条件及随机扰动等因素的影响，从数据、算法、机制与应用等方面推动球墨铸铁领域机器学习研究的发展。

参考文献：

[1] 李克锐，李增利，崔宇，等. 我国铸铁生产技术现状与发展趋势 [J]. 铸造，2022，71（2）：123–135.

[2] Górny M，Kawalec M，Gracz B，et al. Influence of cooling rate on microstructure formation of Si-Mo ductile iron castings [J]. Metals，2021，11（10）：1634.

[3] Ahmed M，Soliman M，Youssef M，et al. Effect of niobium on the microstructure and mechanical properties of alloyed ductile irons and austempered ductile irons [J]. Metals，2021，11（5）：703.

[4] Akinribide O J，Olusunle S O O，Akinwamide S O，et al. Impact of heat treatment on mechanical and tribological behaviour of unalloyed and alloyed ductile iron [J]. Journal of Materials Research and Technology，2021，14：1809–1819.

[5] Richard L. 固溶强化铁素体球墨铸铁 [J]. 铸造，2010，59（6）：622–627.

[6] Valizadeh A，Sahara R，Souissi M. Alloys innovation through machine learning：a statistical literature review [J]. Science and Technology of Advanced Materials：Methods，2024，4（1）：2326305.

[7] Rahman A，Hossain M S，Siddique A B. Machine learning approaches for diverse alloy systems [J]. Journal of Materials Science，2025，60（29）：12189–12221.

[8] Agrawal A，Choudhary A. Perspective：materials informatics and big data：realization of the “fourth paradigm” of science in materials science [J]. APL Materials，2016，4：053208.

[9] 刘源，魏世忠. 数据驱动的钢铁耐磨材料性能预测研究综述 [J]. 机械工程学报，2022，58（10）：31–50.

[10] Huang W，Martin P，Zhuang H L. Machine-learning phase prediction of high-entropy alloys [J]. Acta Materialia，2019，169：225–236.

[11] 谢建新，宿彦京，薛德祯，等. 机器学习在材料研发中的应用 [J]. 金属学报，2021，57（11）：1343–1361.

[12] Wen C，Zhang Y，Wang C，et al. Machine learning assisted design of high entropy alloys with desired property [J]. Acta Materialia，2019，170：109–117.

[13] Chaudry U M，Hamad K，Abuhmed T. Machine learning-aided design of aluminum alloys with high performance [J]. Materials Today Communications，2021，26：101897.

[14] 赵婉辰，郑晨，肖斌，等. 基于Bayesian采样主动机器学习模型的6061铝合金成分精细优化 [J]. 金属学报，2021，57（6）：797–810.

[15] Moses A，Chen D，Wan P，et al. Prediction of electrochemical corrosion behavior of magnesium alloy using machine learning methods [J]. Materials Today Communications，2023，37：107285.

[16] Wang C，Fu H，Jiang L，et al. A property-oriented design strategy for high performance copper alloys via machine learning [J]. npj Computational Materials，2019，5（1）：87.

[17] 李浩，王昊琪，程颖，等. 数据驱动的复杂产品智能服务技术与应用 [J]. 中国机械工程，2020，31（7）：757–772.

[18] Bhat N，Birbilis N，Barnard A S. Unsupervised learning and pattern recognition in alloy design [J]. Digital Discovery，2024，3（12）：2396–2416.

[19] Tlatlik J，Hohe J，Varfolomeev I. Composite descriptors for cast iron microstructures：a data-driven approach to understanding microstructure–property relationships [J]. Engineering Fracture Mechanics，2025，330：111655.

[20] Ha J，Hong J，Kim J，et al. Integrated analysis of spheroidal graphite cast iron by Taguchi design，principal component analysis，and cluster-based methods [J]. International Journal of Metalcasting，2025：1–19.

[21] 王庆锋，刘家赫，卫炳坤，等. 数据驱动的聚类分析故障识别方法研究 [J]. 机械工程学报，2020，56（18）：7–14.

[22] Wilk-Kołodziejczyk D，Regulski K，Gumienny G. Comparative analysis of the properties of the nodular cast iron with carbides and the austempered ductile iron with use of the machine learning and the support vector machine [J]. The International Journal of Advanced Manufacturing Technology，2016，87（1–4）：1077–1093.

[23] Ukoba K，Akinribide O J，Adeleke O，et al. 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.

[24] Halevy A，Norvig P，Pereira F. The unreasonable effectiveness of data [J]. IEEE Intelligent Systems，2009，24（2）：8–12.

[25] Himanen L，Geurts A，Foster A S，et al. Data-driven materials science：status，challenges，and perspectives [J]. Advanced Science，2019，6（21）：1900808.

[26] 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.

[27] Chuzhoy L，Devor R E，Kapoor S G，et al. Microstructure-level modeling of ductile iron machining [J]. J. Manuf. Sci. Eng.，2002，124（2）：162–169.

[28] Khalaf A A，Hanon M M. Prediction of friction coefficient for ductile cast iron using artificial neural network methodology based on experimental investigation [J]. Applied Sciences，2022，12（23）：11916.

[29] Fragassa C，Babic M，Bergmann C P，et al. Predicting the tensile behaviour of cast alloys by a pattern recognition analysis on experimental data [J]. Metals，2019，9（5）：557.

[30] Gu S，Yao Z，Li M，et al. Mechanical properties prediction of ferrite ductile iron via machine learning [J]. Physica Scripta，2023，98（12）：126003.

[31] Cervantes J，Garcia-Lamont F，Rodríguez-Mazahua L，et al. A comprehensive survey on support vector machine classification：applications，challenges and trends [J]. Neurocomputing，2020，408：189–215.

[32] 范志明，甘磊，淦志强，等. 基于特征迁移的小样本增材制造疲劳寿命预测方法 [J]. 机械工程学报，2025，61（17）：255–265.

[33] De Santis A，Iacoviello D，Di Cocco V，et al. Classification of ductile cast iron specimens：a machine learning approach [J]. Frattura ed Integrità Strutturale，2017，11（42）：231–238.

[34] Dong X，Yu Z，Cao W，et al. A survey on ensemble learning [J]. Frontiers of Computer Science，2020，14（2）：241–258.

[35] Wilk-Kołodziejczyk D，Regulski K，Giętka T，et al. The selection of heat treatment parameters to obtain austempered ductile iron with the required impact strength [J]. Journal of Materials Engineering and Performance，2018，27（11）：5865–5878.

[36] Wilk-Kołodziejczyk D，Nowotny A，Krzak I，et al. 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.

[37] Song L，Zhang H，Zhang J，et al. Prediction of heavy-section ductile iron fracture toughness based on machine learning [J]. Scientific Reports，2024，14（1）：4681.

[38] Lundberg S M，Lee S I. A unified approach to interpreting model predictions [C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook：Curran Associates Inc.，2017：4768–4777.

[39] Su S，Yao P，Xue J，et al. Machine learning methods for predicting tensile strength，elongation，and low-temperature impact energy of annealed ductile iron [J]. Physica Scripta，2025，100（12）：126006.

[40] Gebhardt C，Trimborn T，Weber F，et al. Simplified ResNet approach for data driven prediction of microstructure-fatigue relationship [J]. Mechanics of Materials，2020，151：103625.

[41] Ferro P，Spiller S，Tang K，et al. Sustainable ductile iron design：leveraging machine learning and genetic algorithms for critical raw materials reduction [J]. Engineering Applications of Artificial Intelligence，2026，163：113117.

[42] Wiangkham A，Ariyarit A，Aengchuan P，et al. Multi-objective optimization of tensile and hardness properties for austempered ductile iron via NSGA-III and XGBoost [J]. Materials Today Communications，2025，46：112458.

[43] Germain L，Sertucha J，Hazotte A，et al. Classification of graphite particles in metallographic images of cast irons-Quantitative image analysis versus deep learning [J]. Materials Characterization，2024，217：114333.

[44] Zhao Q，Kang J，Wu K. Study on the recognition of metallurgical graphs based on deep learning [J]. Metals，2024，14（6）：732.

[45] Alrfou K，Kordijazi A，Rohatgi P，et al. 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.

[46] Rosenberger J，Tlatlik J，Beckmann C，et al. Extracting ductile cast iron microstructure parameters from fracture surfaces：a deep learning based instance segmentation approach [J]. Engineering Fracture Mechanics，2024，311：110586.

[47] Zhang H，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.

[48] Gajoch S，Wilk-Kołodziejczyk D，Marcjan Ł，et al. Development and implementation of a defect detection model for microstructures using image processing methods [J]. Materials，2025，18（22）：5207.

（编辑：潘继勇，pjy@foundryworld.com）