

特约综述



张立强 博士、教授、博士生导师,中国金属学会冶金人工智能分会委员、中国冶金教育学会冶金实践教育分会理事、安徽省金属学会理事兼副秘书长、高效轧制国家工程研究中心特聘专家。主要研究方向为冶金过程智能制造和工业大数据、AI大模型及其冶金工业应用、连铸坯智能定重技术及应用。主持国家自然科学基金项目2项、国家重点实验室开放基金1项、中国宝武等企业重点项目30余项以及安徽省教育厅教改项目6项。主持的“连铸坯智能定重技术与成套装备”项目在国内多家企业应用,研发技术受到了学习强国、安徽卫视、安徽日报、世界金属导报等媒体关注。发表学术论文100余篇,授权发明专利12项。获安徽省科学技术二等奖、冶金科学技术奖三等奖、安徽省教学成果一等奖和三等奖等省部级教学科研奖励,同时获钢铁行业教育培训先进个人“突出贡献奖”、中国冶金教育学会先进工作者。

指导学生获全国大学生冶金科技竞赛一等奖、全国转炉模拟炼钢比赛特等奖以及挑战杯大学生科技作品竞赛奖等100余项。

机器学习在板坯质量预测中的研究进展与展望

张立强^a, 谢飞^b, 陶陶^b, 张超杰^a

(安徽工业大学 a. 冶金工程学院; b. 计算机科学与技术学院, 安徽 马鞍山 243032)

摘要: 板坯质量预测是优化钢铁生产流程、提升产品性能的关键环节。传统基于冶金机理的预测模型主要依赖物理规律与经验公式,难以适应高自动化生产环境中的复杂非线性关系,存在预测精度低、泛化能力弱等固有局限。随着机器学习技术的快速发展,单一模型通过特征学习与复杂非线性拟合能力,在裂纹风险评估、偏析预测等具体任务中展现了良好的性能优势,但仍面临高维数据过拟合、样本类别不平衡等挑战。为了克服这些限制,集成学习模型通过多弱学习器协同优化,显著提升了预测系统的准确性与鲁棒性,尤其是在处理工艺参数强耦合及强噪声干扰的工业场景中表现突出。为此,本文概述传统质量预测模型的典型建模方法及其存在的应用局限,综述神经网络等单一模型与随机森林等集成模型在板坯质量预测中的研究进展,重点分析集成质量预测模型在预测精度和工程适用性方面的优势。围绕动态建模优化、小样本增强学习、轻量化模型部署、可解释性提升及全流程协同预测等关键技术,进一步探讨未来发展方向,为构建高精度、强适应性的新一代板坯质量智能预测体系提供理论支撑与技术路径。

关键词: 板坯质量预测; 冶金机理; 机器学习; 单一模型; 神经网络; 集成模型; 随机森林; XGBoost

中图分类号: TF 777; TP 181 **文献标志码:** A **doi:** 10.12415/j.issn.1671-7872.24205



收稿日期: 2024-12-16

基金项目: 国家自然科学基金项目(52104317, 51874001); 安徽省高校协同创新项目(GXXT-2023-021)

作者简介: 张立强(1977—), 男, 河北邢台人, 博士, 教授, 主要研究方向为连铸坯智能定重技术与装备等。

引文格式: 张立强, 谢飞, 陶陶, 等. 机器学习在板坯质量预测中的研究进展与展望[J]. 安徽工业大学学报(自然科学版), 2025, 42(4):352-367.

Research Progress and Outlook of Machine Learning in Slab Quality Prediction

ZHANG Liqiang^a, XIE Fei^b, TAO Tao^b, ZHANG Chaojie^a

(a. School of Metallurgical Engineering; b. School of Computer Science & Technology, Anhui University of Technology, Maanshan 243032, China)

Abstract: Slab quality prediction is the key link to optimize steel production process and improve product performance. The traditional prediction model based on metallurgical mechanism mainly relies on physical laws and empirical formulas, which is difficult to adapt to the complex nonlinear relationship in the highly automated production environment, and has inherent limitations such as low prediction accuracy and weak generalization ability. With the rapid development of machine learning technology, the single model has shown good performance advantages in crack risk assessment, segregation prediction and other specific tasks through feature learning and complex nonlinear fitting ability, but it still faces challenges such as high-dimensional data over fitting and unbalanced sample categories. In order to overcome these limitations, the integrated learning model significantly improves the accuracy and robustness of the prediction system through the collaborative optimization of multiple weak learners, especially in the industrial scene dealing with strong coupling of process parameters and strong noise interference. Therefore, the typical modeling methods of traditional quality prediction models were outlined, along with their application limitations. The research progress of single model (e.g., neural network) and integrated models (e.g., random forest) in slab quality prediction was reviewed. The advantages of integrated quality prediction model in prediction accuracy and engineering application were analyzed. Based on these findings, the future development direction of key technologies were explored, including dynamic modeling optimization, small sample reinforcement learning, lightweight model deployment, interpretability improvement and whole process collaborative prediction are discussed, which provides theoretical support and technical path for the construction of a new generation of slab quality intelligent prediction system with high precision and strong adaptability.

Keywords: slab quality prediction; metallurgical mechanisms; machine learning; single model; neural network; ensemble model; random forest; XGBoost

在现代钢铁生产中,板坯作为关键中间产品,其质量直接决定了后续轧制、热处理等工序的顺利进行,并最终影响钢铁产品的综合性能^[1-2]。随着冶金工艺技术的持续革新和工业自动化水平的快速提升,板坯质量预测面临挑战。一方面,生产工艺参数间的耦合作用日益复杂,质量影响因素呈现非线性特征;另一方面,市场对产品品质的要求日趋严格,质量管控标准不断提高。传统基于冶金机理的质量预测方法主要依托物理冶金学理论和经验公式,通过建立工艺参数(成分、温度、拉速等)与板坯质量指标间的确定性关系来实现质量管控。这种方法能够反映冶金过程的内在规律,具有明确的物理意义和较好的解释性,但在应对现代钢铁生产却显现出明显的局限性:难以有效处理复杂的、实时变化的生

产数据;对工艺波动的自适应性不足;预测精度难以满足日益提升的质量控制要求。在此背景下,突破传统方法局限并建立更精准、更智能的板坯质量预测模型,对提升钢铁企业产品质量、降低生产成本及增强市场竞争力具有重要的现实意义。

近年来,人工智能技术的快速发展为钢铁工业智能化转型提供了技术支撑^[3]。在板坯质量预测领域,机器学习方法凭借其强大的数据挖掘能力和非线性建模优势,展现出显著的应用价值^[4-6]。研究^[7-8]表明,以神经网络、决策树等为代表的单一模型已在板坯质量预测、裂纹风险评估、成分偏析分析等关键质量指标预测中取得了较好效果。这些方法通过深度挖掘工艺参数与质量指标间的复杂映射关系,实现了较传统方法更精准的预测性能。然而,

单一模型在面对钢铁生产中的高维数据和复杂特征时,存在模型泛化能力差和过拟合的问题,导致预测结果在实际生产中存在一定的不确定性。为克服上述局限性,集成学习方法逐渐成为板坯质量预测中的主流方案。以极端梯度提升树(extreme gradient boosting, XGBoost)、随机森林(random forest, RF)为代表的集成学习模型,通过整合多个弱学习器的预测优势,不仅显著提升了模型的预测精度,更增强了系统的鲁棒性^[9-10]。特别在处理多变量、强耦合的复杂工艺条件时,这类方法表现出较强的适应性,已成为当前机器学习在钢铁质量预测中最具前景的技术路线之一。基于此,本文综述板坯质量预测领域的研究进展,梳理国内外学者在单一模型与集成模型用于板坯质量预测领域的研究成果及其应用效果,并对未来研究方向进行展望,以为钢铁行业智能化质量控制体系的完善提供理论支撑和技术参考。

1 传统板坯质量预测模型

传统质量预测模型经过长期的理论探索与工业实践,已形成以冶金学原理为核心的多维预测体系。该体系主要包含基于应力应变分析的力学性能预测模型、基于相变动力学与晶粒演化的微观组织预测模型,以及融合热力学与流体动力学的数值模拟预测模型。这些模型通过耦合传热-变形-相变多物理场作用机制,构建从工艺参数到质量指标的定量映射关系,为板坯质量预测奠定了理论基础。

1.1 基于应力应变的质量预测模型

基于应力应变的质量预测模型通过建立临界断裂应力与应变状态的定量关联,揭示板坯表面裂纹与内部裂纹的萌生及扩展机制,成为连铸坯缺陷预测的重要技术路径。在相关模型研究中,Won等^[11]通过分析脆性温度和应变速率对铸坯内部裂纹的影响,发现裂纹形成概率随着温度和应变的增加而上升,据此提出临界断裂应力模型并成功用于连铸坯内部开裂的预测。然而该研究未考虑凝固前沿的化学偏析效应,在合金钢等多元成分体系中的适用性受到限制。针对这一不足,Han等^[12]进一步通过分析耦合板坯凝固前沿应变状态与钢液化学成分对内部裂纹的影响,建立应变分析-微观偏析模型并用于板坯内部裂纹的预测,经硫印实验验证其预测结果具有较高的准确性。在此基础上,Poltrarak等^[13]进一步拓展研究维度,基于热拉伸实验标定的钢材材料法则,研究拉速和碳含量对裂纹临界值的影响规律,结合宏观腐蚀实验揭示了铸坯内部开裂机理,为

不同铸造条件下开裂风险的量化评估提供了理论基础。这些研究共同推动了应力应变模型从机理探索向工程应用的转化,但其在动态工况下的实时预测能力仍有待提升。

1.2 基于微观组织的质量预测模型

微观组织演化与裂纹形成的关联机制是质量预测的另一重要维度,通过揭示晶粒演化和相变动力学规律,构建工艺参数、组织演变与缺陷形成的多尺度关联框架。Brimacombe等^[14]研究表明,连铸板坯表面裂纹的产生与钢的第二个低延展性区域密切相关,当温度高于1340℃时,枝晶间液态膜的存在导致材料强度与延性骤降,这一发现从微观机理层面解释了内部裂纹和表面纵裂纹的形成本质。后续研究进一步证实,奥氏体晶粒尺寸分布对裂纹敏感性具有重要影响,其中粗大的奥氏体晶粒会显著增加横向裂纹风险,细小均匀的奥氏体晶粒则表现出更好的抗裂性能^[15-19]。基于此,Ai等^[20]提出基于热反弹过程的预测模型,通过耦合 α -铁素体析出动力学和奥氏体化动态相变过程,实现对板坯奥氏体晶粒尺寸分布的定量预测,实验验证该模型能准确模拟铸坯在不同热处理条件下的晶粒生长行为,但在实际应用中仍存在实时生产数据适应性不足和预测精度受限等问题,这也为后续研究指明了改进方向。

1.3 基于数值模拟的质量预测模型

在连铸坯质量预测研究从单一机理分析向多场协同控制演进的背景下,数值模拟技术凭借其多尺度与多物理场的耦合优势,实现对成分偏析、缩孔等典型缺陷的定量预测与工艺优化,成为预测复杂缺陷的关键工具。Luo等^[21]将电磁搅拌(strand electro-magnetic stirring, S-EMS)和机械复位(mechanical reduction, MR)技术相结合,通过数值模拟揭示了不同铸造条件下的偏析形成机制,S-EMS技术通过电磁力优化凝固前沿的流场,而MR技术则通过精确控制磁场液相区域流动抑制枝晶间富集溶质的流动,两者的协同作用能够显著降低铸坯的宏观偏析程度。该研究不仅为工艺优化提供了理论依据,其输出的高精度场变量数据更为板坯质量预测模型提供了可靠的输入参数。Chimani等^[22]开发了基于商业化数值模拟工具的预测方法,通过集成凝固传热、溶质传输和应力应变等多物理场模型,实现了连铸过程物理和化学变化的数字化映射。该方法将传统实验研究与数值仿真相结合,既降低了实验成本,又提高了预测结果的准确性,其与计算机辅助质量控制(computer aided quality control, CAQC)

系统的兼容性为构建智能化的板坯质量预测提供了新思路。这些研究共同推动了数值模拟技术从离线分析向在线预测的转变,但在实时计算效率和工业现场集成方面仍需进一步突破。

综上,传统板坯质量预测的三类典型建模方法呈现明显的优势互补特征:基于应力应变的质量预测模型凭借其清晰的物理机理,在裂纹萌生与扩展行为的定量表征方面具有优势,为工艺参数优化提供了直接的理论依据,但其对多场耦合的表征能力有限,难以解析质量缺陷的跨尺度演化规律;基于微观组织的质量预测模型通过揭示奥氏体晶粒尺寸分布与裂纹敏感性关系,在材料本征性能调控方面展现出突出价值,然而受限于组织演变的滞后特性,该模型对生产过程中实时工艺波动的动态响应能力不足,工业场景的普适性仍需提升;基于数值模拟的预测模型凭借多物理场耦合的技术优势,在偏析、缩孔等复杂缺陷的定量预测方面取得显著进展,但受制于高精度仿真所需要的海量计算资源,其在实时在线预测场景中的应用仍面临挑战。三类模型的差异化特征表明,构建融合多尺度机理与数据驱动的混合建模体系是突破现有技术瓶颈的重要方向。

2 机器学习模型在板坯质量预测中的应用

在板坯质量预测领域,现有机器学习模型按组成方式可分为单一质量预测模型和集成质量预测模型两类。前者通过独立算法实现特定质量指标的精准预测,后者则通过多模型协同提升预测系统的鲁棒性和泛化能力。

2.1 单一质量预测模型

单一质量预测模型是基于独立算法构建的预测方法,通过建立输入特征与质量指标间的映射关系实现缺陷预测。这类模型凭借结构简明、计算高效、可解释性强的优势成为工业质量预测领域的基石性方法,其主要包括神经网络、决策树和主成分分析及支持向量回归等典型算法模型。

2.1.1 基于神经网络的质量预测模型

神经网络的主要类型包括感知机、极限学习机和误差反向传播(back propagation, BP)神经网络。图 1 为神经网络的拓扑结构^[23],其由输入层、隐含层和输出层组成,每个输入节点对应一个特征变量,层间神经元通过加权连接实现信息传递与处理。该网

络通过不断调整权重以最小化预测输出与实际值之间的误差,从而有效学习数据中的非线性特征与复杂规律^[24]。

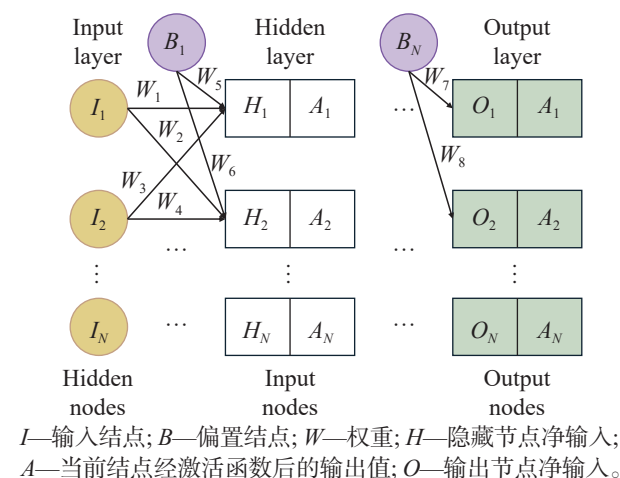


图1 神经网络拓扑结构^[23]

Fig. 1 Topological structure of neural network^[23]

早期研究主要基于基础神经网络构建铸坯质量预测的初步框架。由于具备误差反向传播的特性, BP神经网络成为首批应用于铸坯质量预测的模型之一。Li^[25]针对普碳钢、高碳钢等钢种的中间裂纹、中心裂纹和中心偏析缺陷,通过分析其形成机理构建了具有20-15-3拓扑结构的BP神经网络预测模型,并基于该模型开发了铸坯在线质量预测系统。该系统通过实时监控连铸工艺参数、分析关键影响因素并进行缺陷溯源,建立了包含多维度特征的冶金数据集,实现了质量缺陷的预测分析,为连铸工艺优化提供了数据支持。然而,受限于当时的硬件性能,该模型存在单次迭代时间过长(超过30 min)和预测准确率偏低的技术瓶颈,制约了其在工业现场的实际应用效果。为此,夏德银^[26]通过分析铸坯在结晶器内的凝固动力学特征和热量机制,构建了基于BP算法的人工神经网络预测模型,并利用Matlab进行仿真建模,结果表明:该模型将质量预测误差降至0.1左右,准确率得到显著提升。但受限于早期神经网络模型的架构局限性以及数据采集存在的系统性偏差,模型的泛化能力不足,最终未能达到工业应用标准。基于前人的研究成果,常运合等^[27]将实验预测转向工程实践应用,开发了基于BP神经网络的大方坯质量在线预报系统。该系统针对中间裂纹、中心裂纹和中心偏析等关键缺陷建立了预测模型,通过综合分析连铸过程中间包温度、结晶器振动参数和二次冷却速度等关键工艺参数,采集现场

生产数据进行模型训练,并经过特征工程处理后作为神经网络输入。如图 2 所示,该系统实现了质量缺陷的实时在线预测与可视化预警功能,已成功应

用于国内某钢厂,不仅验证了神经网络技术在工业质量预测场景的实用价值,更实现了铸坯质量预测研究从实验室仿真到工业化应用的突破。

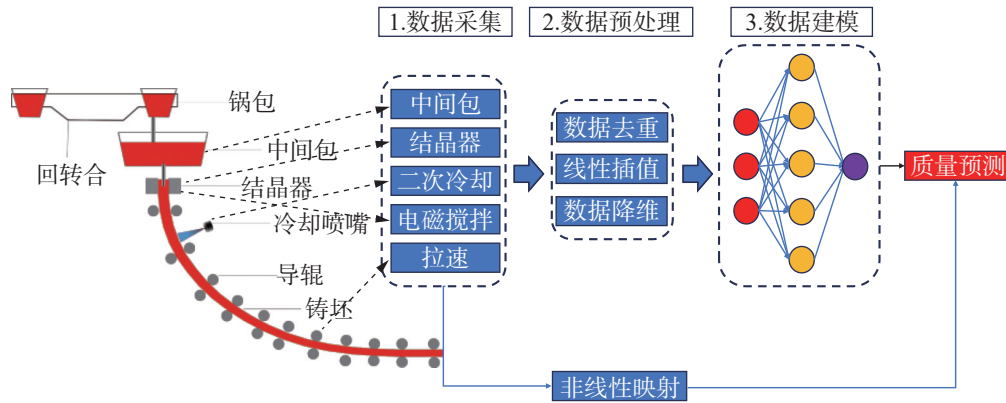


图2 基于 BP 神经网络的板坯质量预测模型

Fig. 2 The slab quality prediction model based on BP neural network

为突破基础神经网络模型在预测精度和计算效率等方面的局限,研究者开始从算法层面寻求解决方案。卢海彪等^[28]提出了一种基于加权极限学习机(weight extreme learning machine, WELM)的铸坯质量预测模型,通过比较不同激活函数的性能表现,证实采用 Sigmoid 函数配合 600 个隐含层节点的网络结构最具优势,不仅将模型训练时间压缩至 1.5 min,同时显著提升了泛化性能,最终实现了 99% 的异常板坯召回率和 0.97 的综合预测精度。然而,基础神经网络仍存在参数优化难题,这在一定程度上制约了模型在不同钢种间的迁移性能。王旭^[29]为提升预测模型精度和泛化能力,提出了基于智能优化算法的混合预测框架。该框架采用高相关滤波算法对输入参数进行降维以消除数据冗余,随后构建双向长短期记忆神经网络(long short term memory, LSTM)模型,并引入麻雀算法(sparrow search algorithm, SSA)对 LSTM 的关键参数(学习速率、迭代次数、隐含层结点数等)进行优化。该算法通过模拟麻雀群体的觅食协作行为,在解空间内实现有效搜索并最终找到全局最优解。实验验证表明经优化后的模型均方误差降至 0.062 6、预测准确率达到 98%,具有良好的非线性预测性和拟合能力。遗传算法(genetic algorithm, GA)是一种模拟生物进化过程的全局优化算法,通过选择、交叉、变异等操作有效解决复杂的全局优化问题^[30]。陈恒志等^[31]针对 60Si2Mn 弹簧钢的质量预测问题,建立了 GA 与 BP 神经网络相结合的混合优化模型。该模型运用主成分分析法对 160 组生产数据进行降维处理,有效降低了模型复杂度;同时采用 GA 对 BP 神经网络的学习速率、

动量因子、隐含层数等关键超参数进行优化,最终使模型预测准确率提升至 85%,训练时间缩短至 125 s。但该模型仍存在自适应能力不足以及多钢种预测准确率有待提高等局限。

为提升模型在实际工业场景中的适用性及多钢种预测能力,研究者们将大数据挖掘技术与智能算法相结合。Hou 等^[32]通过系统分析连铸生产全流程(包括钢包精炼、中间包冶金、结晶器凝固等环节),筛选出 25 个关键工艺参数作为输入特征,构建了基于 GA 优化的 BP 神经网络预测模型。该模型在多钢种预测任务中表现优异,结果如表 1 所示,低碳钢的预测精度达 94.7%(均方误差 0.044 5)、包晶钢为 93.3%(均方误差 0.052 1)、中碳钢为 85.4%(均方误差 0.146 5),均方误差指标的评估表明,模型在所有测试钢种上均保持稳定(误差均控制在 0.1 左右),尤其对工艺波动敏感的低碳钢展现出超预期的预测精度,充分验证了模型的可靠性。

表 1 GA-BP 混合优化模型性能评估对比^[32]

Tab. 1 Performance evaluation and comparison of GA-BP hybrid optimization model^[32]

钢种	平均绝对误差	均方误差	均方根误差	准确率/%	误报率/%
低碳钢	0.106 7	0.044 5	0.210 0	94.7	82.5
包晶钢	0.129 9	0.052 1	0.223 6	93.3	87.5
中碳钢	0.306 3	0.146 5	0.382 7	85.4	78.3

随着深度学习技术的快速发展,神经网络架构设计呈现出多样化创新趋势,研究者们探索不同网络拓扑结构与工业应用场景的适配性优化问题。Kong 等^[33]针对传统 BP 神经网络架构在工业应用

中的局限性提出双重改进策略:一方面,通过动态调整动量项改善网络权值更新稳定性,解决固定动量因子而导致的局部收敛问题;另一方面,引入最大误差学习法重构反向传播机制,优先修正误差贡献度最大的神经元参数,显著提升模型对冶金过程复杂特征的学习效率。如图 3 所示,该模型整合凝固传热模拟、应力应变计算等物理模型,结合连铸冶金过程理论分析与异常事件专家判定系统,将板坯切割为多个切片单元实时获取冶金信息,通过深度学习模型分析内部裂纹产生指数并预测各切片单元的裂纹发生概率,最终实现了 86.85% 的预测准确率。但受限于数据采集实时连续性的不足,模型预测更新速度滞后于实际生产动态变化。

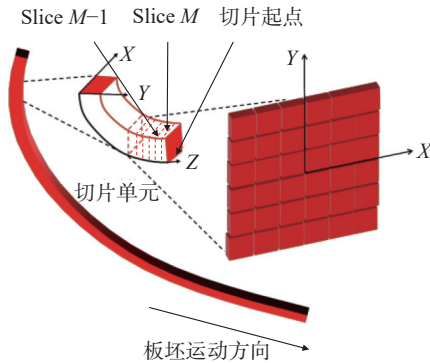


图3 板坯切片单元示意图

Fig. 3 Schematic diagram of slab slicing unit

针对上述技术瓶颈, Lu 等^[34]将深度神经网络 (deep neural network, DNN) 与实时过程数据相结合,开发了高效连铸过程预测模型。该模型利用 DNN 强大的特征提取能力有效克服了 BP 网络对复杂数据模式捕捉不足的缺陷,特别是通过集成 LSTM 等时序处理模块,实现了连铸过程的动态实时建模;同时能够实时监测温度场分布、应力应变等关键参数,并基于实时数据流快速生成预测结果,弥补了模型因数据更新延迟导致的预测滞后问题。经实验验证,该模型预测时间仅需 0.12 s,平均绝对百分比误差控制在 0.24%~0.60% 水平,不仅能准确预测铸造缺陷,还可通过闭环反馈机制智能调节工艺参数,又可降低缺陷发生概率。

2.1.2 基于决策树的质量预测模型

决策树 (decision tree, DT) 作为一种经典的监督学习模型,凭借其树形结构的直观性和可解释性在工业质量预测领域展现出独特优势。该模型通过逐层划分特征空间将原始数据集逐步分割为纯度递增的子集,最终构建出具有明确判别逻辑的树状决策结构^[35]。如图 4 所示,决策树以根节点为起点,

根据特征 E 对数据进行初始划分,随后通过特征 F 和特征 G 节点构建层级判断路径,引导数据流向对应叶节点以获取最终分类结果。这种基于规则推理的建模方式,为工业质量预测提供了透明化的分析框架,尤其适用于需要明确缺陷成因诊断的生产场景。




图4 决策树结构

Fig. 4 Decision tree structure

在基于决策树的铸坯质量早期研究中,算法改进与特征优化成为关键突破方向。曹俊^[36]通过改进监督学习探索算法 (supervised learning in quest 2, SLFQZ.2) 取代传统决策树分类 4.5(classification 4.5, C4.5) 模型,采用集成剪枝策略与可视化规则技术将分类准确率提升至 79.9% 的同时显著增强了模型的可解释性。基于炉温特征构建的决策树规则显示: 501~540 °C 和 561~570 °C 区间对应的铸坯质量完好率接近 100%, 而 541~550 °C, 581~620 °C 及 621~670 °C 区间的缺陷率则呈现阶梯式上升趋势 (分别达 3.18%, 6.79%, 37.33%), 证实了温度参数对质量缺陷的非线性调控作用。然而,该研究未能有效解决工业现场普遍存在的数据不平衡问题,导致模型在极端工况下的预测鲁棒性不足。针对这一局限, Kopper 等^[37]引入少数类过采样技术 (synthetic minority over-sampling technique, SMOTE) 进行数据平衡处理,基于 174 869 例高压压铸工业数据样本分析表明,传统决策树模型存在严重的类别偏差:良品分类准确率达 99.5%(167 470 例),但对过程缺陷废料的识别仅 5 294 例且伴随 1 577 例假阳性,暴露出对少数类样本的识别缺陷。经 SMOTE 算法增强后,模型性能显著提升:废料正确分类增至 5 693 例,假阳性率降低 25.3%,关键指标精确率、召回率与 F1 分数分别提升至 86.7%, 77.1% 和 81.6%,有效改善了质量预测的均衡性。然而,该模型在跨模具测试中泛化能力显著下降,表明工艺参数异质性制约了决策树的迁移学习效果。

为突破决策树在工业质量预测中的性能瓶颈,

研究者们采用数据协同优化策略。Sayed等^[38]基于伊朗某钢铁公司全流程生产数据,运用跨行业数据挖掘标准(cross-industry standard process for data mining, CRISP)构建多元异构数据集,通过系统性特征分析发现铝含量与缺陷存在显著阈值效应,采用熵值最大化准则确定 $w(\text{Al}) < 0.004\%$ 为关键分裂节点,并基于基尼不纯度指标量化钒、锡、钛等元素的非线性交互效应。采用数据分层策略(70%训练集)优化决策边界学习,最终模型在低碳钢缺陷预测中达到83%的准确率,较神经网络模型提升19%,显著增强了决策树模型的预测能力与可解释性,为缺陷预测提供了可靠的定量依据。

2.1.3 其他单一质量预测模型

在板坯质量预测领域,除神经网络与决策树外,其他单一模型凭借其可解释性或计算效率优势亦被广泛应用。彭平等^[39]通过构建包含出钢温度、增碳量、钢包温度、拉速等14个连铸工艺参数的因素矩阵,采用主成分分析(principal component analysis, PCA)方法将多维数据降至2个主成分,构建基于主成分的铸坯质量预测模型,实现了工艺参数的显著简化和计算效率的大幅提升,但由于数据降维过程不可避免地损失了非线性信息,导致模型预测准确率较低。为此,王宝等^[40]通过统计计算得到各影响因素的隶属函数,结合冶金机理和主成分分析法,基于最大隶属原则构建多元模糊模式的预测模型,通过模糊集理论有效处理工艺参数的不确定性,结果

表明:该模型在对20CrMnTiH齿轮钢的质量预测中准确率达到81.82%,较传统PCA模型有显著提升,展现出良好的工程应用价值。

混合动态优化方法可有效改善单一模型的局限性。赵济民等^[41]通过即时学习算法构建支持向量回归预测模型,如图5所示,该模型的核心在于动态局部建模机制,基于实时筛选邻近样本构建局部模型,通过引入时间衰减因子量化历史数据的时效性权重,强化工艺参数间的动态耦合关系;采用支持向量回归进行局部拟合,并建立模型库的更新数据库。这种局部建模与全局更新的混合策略显著提升了模型的适应能力,在三角裂纹缺陷预测中实现了90%的命中率。研究进一步引入多目标优化算法,在模型复杂性与泛化性能间取得了较好的平衡,为连铸过程质量控制提供了兼具实时性与解释性的智能决策工具。王怡青^[42]提出基于核主元分析(Kernel principal component analysis, KPCA)与智能优化算法融合的预测模型,通过引入蚁群算法构建核参数动态优化框架:基于蚁群算法的全局搜索能力优化KPCA参数,采用参数阶梯化处理工艺参数的多尺度特性,并结合组合赋权方法实现多维工艺参数的动态平衡,最后通过Matlab建立预报可视化平台,模型准确率达到82.5%。但该模型输入参数只包含工艺参数,未考虑连铸设备等关键影响因素,导致模型在实际生产环境中的适应性受到制约,需要加强工艺参数与设备状态的数据融合。

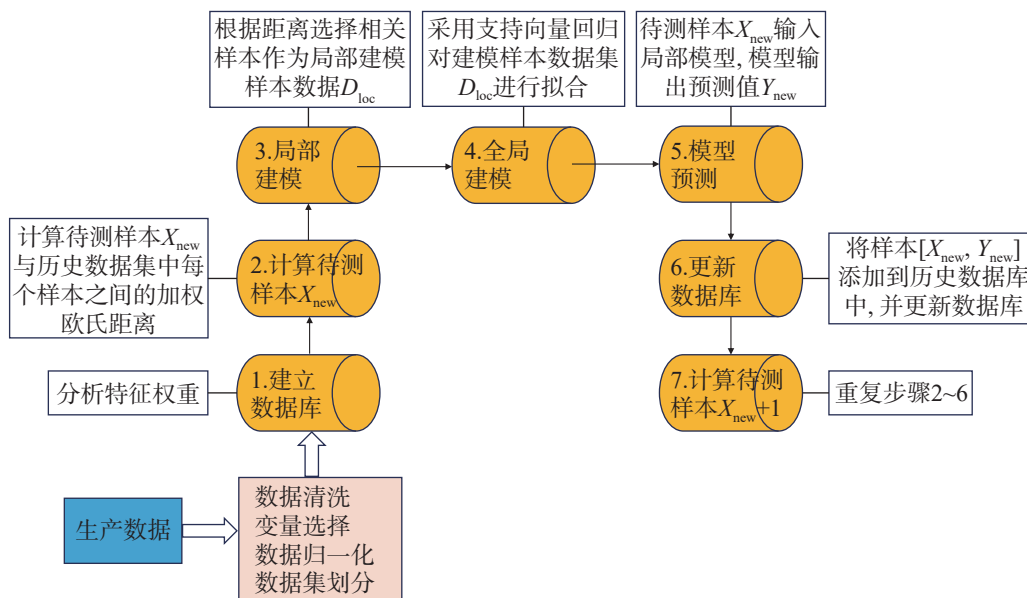


图5 基于即时学习的局部质量预测模型^[41]

Fig. 5 Local quality prediction model based on just-in-time learning^[41]

针对复杂工业场景下的质量预测难题, Normanton 等^[43]率先将无监督学习与监督学习相结合, 采用自组织映射 (self-organizing map, SOM) 对高维冶金数据进行非线性特征降维, 再通过多层感知机 (multi-layer perceptron, MLP) 构建质量分类预测模型, 成功规避了物理预测模型适应性差的局限性。实验结果表明, 这种特征学习与分类预测的架构显著提升了模型的表达能力, 但由于训练数据仅包含单一质量等级的样本, 缺乏表面质量与内部质量差异化的关键特征, 导致模型易陷入局部最优, 预测命中率仅为 60%。这一局限促使学者将规则引擎与传统统计模型相结合, Franěk 等^[44]构建基于关联规则和逻辑回归的预测模型, 通过分析板坯连铸过程中冷却水流量、拉速等关键热工艺参数对缺陷类型的关联规律生成可解释规则, 最终形成兼具可解释性与预测精度的规则库, 为板坯质量预测提供了

一套基准规则体系。邓比涛等^[45]基于计算器模式的规则器开发铸坯质量预测系统且在钢厂成功应用, 通过动态更新规则使预测命中率达到 90.2%, 显著提升了铸坯质量管控水平并实现成本节约。超参数优化更是多方法融合策略的核心技术。Zhao 等^[46]构建了基于最小二乘支持向量机 (least squares support vector machine, LSSVM) 的质量预测模型, 如图 6 所示^[46], 通过整合连铸工艺关键环节与质量指标形成冶金数据集, 针对 LSSVM 模型参数选择的不确定性, 采用改进的粒子群优化算法 (improved particle swarm optimization, IPSO) 对正则化参数、核函数类型、核矩阵参数进行智能寻优, 实现了板坯裂纹和中心偏析的精准预测, 平均误差率仅为 5.03%。相比于传统线性与非线性模型, 该模型展现出优异的拟合能力和泛化性能, 为连铸质量预测提供了有效的超参数优化方法。

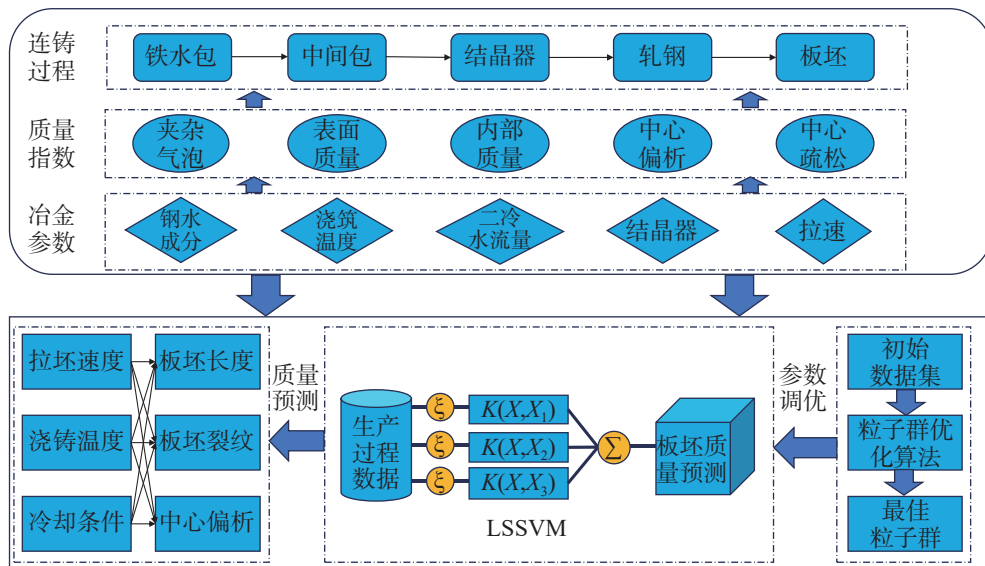


图6 基于 IPSO-LSSVM 的板坯质量预测模型^[46]

Fig. 6 Slab quality prediction model based on IPSO-LSSVM^[46]

2.2 集成质量预测模型

集成模型是一种通过融合多个基学习器的预测结果来提升性能的机器学习方法, 相比单一模型能有效缓解噪声干扰、降低过拟合风险, 并在复杂工业场景下保持较高的预测精度^[47-49]。在质量预测领域, 根据基学习器的组合方式集成模型可分为基于随机森林、基于 XGBoost 及其他集成质量预测模型。

2.2.1 基于随机森林的质量预测模型

随机森林 (random forest, RF) 是一种基于决策树

的集成学习方法, 核心是由多棵决策树构成的分类器, 其模型结构如图 7^[50]。该算法首先通过 Bootstrap 抽样多个样本集, 再运用 Bagging 技术并行训练多棵差异化的决策树 (每棵树仅使用部分样本和特征)。预测阶段通过集体投票或均值聚合获得最终结果, 这种独特机制使模型兼具抗过拟合特性与高鲁棒性, 不仅能有效处理高维数据^[51-53], 还能在保持预测精度的同时显著提升模型稳定性。

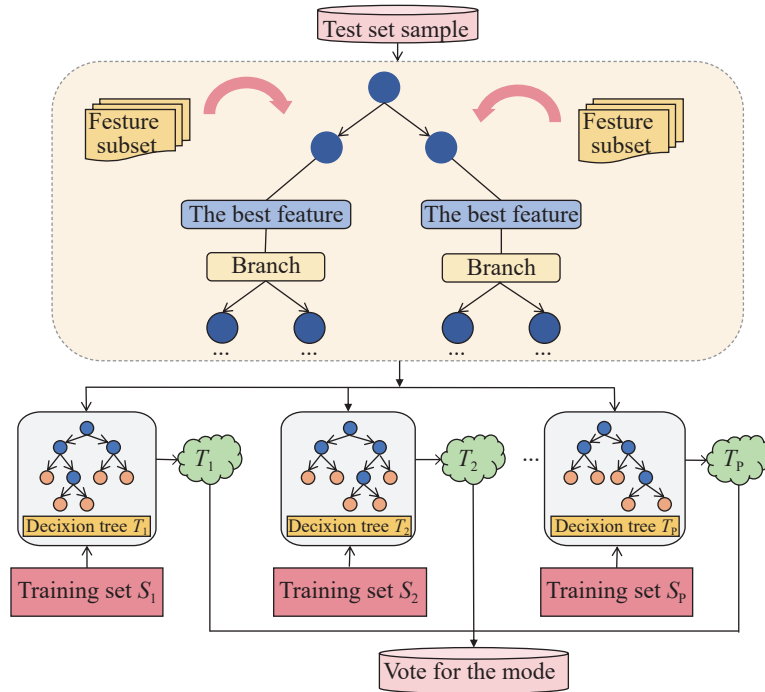


图7 随机森林网络结构^[50]

Fig. 7 Architecture of random forest network^[50]

基于随机森林的算法优势, Varfolomeev 等^[54]开发了板坯质量预测随机森林模型, 如图 8 所示: 对于单棵决策树的模型结构, 在树的每层通过特征阈值进行数据分割, 叶节点输出最终的预测结果; 对于随机森林的整体结构, 通过集成多棵决策树降低过拟合并输出最终的预测结果。该研究不仅识别出影响板坯裂纹的关键因素, 还将预测模型成功转化为工业软件, 实验证实其准确率较传统回归模型提高了 10%。然而, 随机森林作为多棵决策树组成的集成模型, 计算复杂度高且耗时较长, 使其难以匹配高速生产需求。针对这一不足, 张赫等^[55]结合 K 均值

聚类实现轻量化优化: 首先, 基于热电偶温度时序数据提取 16 维特征, 并利用随机森林的基尼重要性评估筛选出 6 个关键特征, 使特征维度减少 62.5%, 提升模型计算效率; 其次, 采用 K 均值聚类替代复杂的神经网络结构, 通过无监督学习对降维后的特征进行分类。改进后的模型仅需 7 次迭代即可收敛 (误差平方和降至稳定值), 在 80 例测试样本 (40 例正常工况、40 例纵裂样本) 中准确率达到 100%, 未出现漏报或误报情况。相较于 Varfolomeev 等^[54]的随机森林模型, 该模型的轻量化与分类耗时特性为工业高速生产场景提供了优化范式。

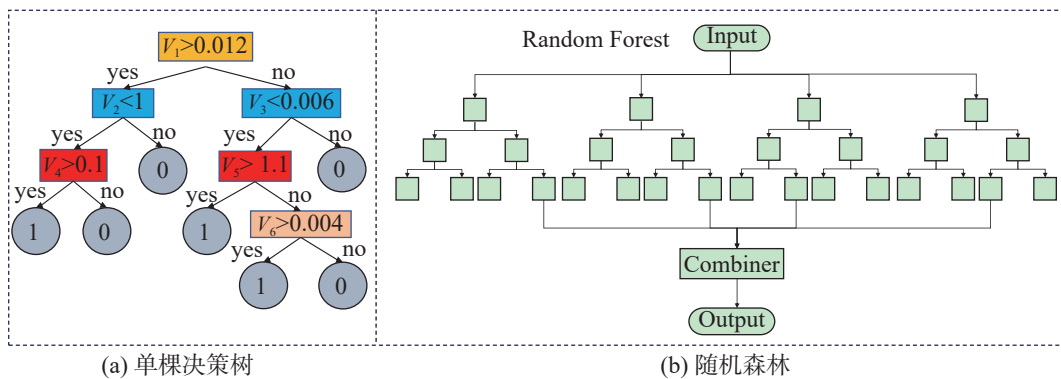


图8 基于随机森林网络的板坯预测模型

Fig. 8 Slab prediction model based on random forest network

2.2.2 基于 XGBoost 的质量预测模型

XGBoost 是一种基于梯度提升框架的集成学习

算法, 核心在于通过正则化项有效控制模型复杂度, 从而避免过拟合。如图 9 所示^[56], 该模型结构具有

明确的层次性: 首棵决策树基于初始数据集建立基准预测值, 作为模型起点; 次棵树则以首棵树的残差为训练目标, 学习第一棵树未能准确拟合的部分。以此类推, 将这种可接受的策略重复多次, 直到满足预设的停止条件, 最终的预测结果为每个学习者预

测结果的总和^[57-58]。相较于传统梯度提升方法, XGBoost 通过引入剪枝和并行计算等技术提升模型的计算效率和预测性能, 使其在处理大规模数据时展现出明显优势。

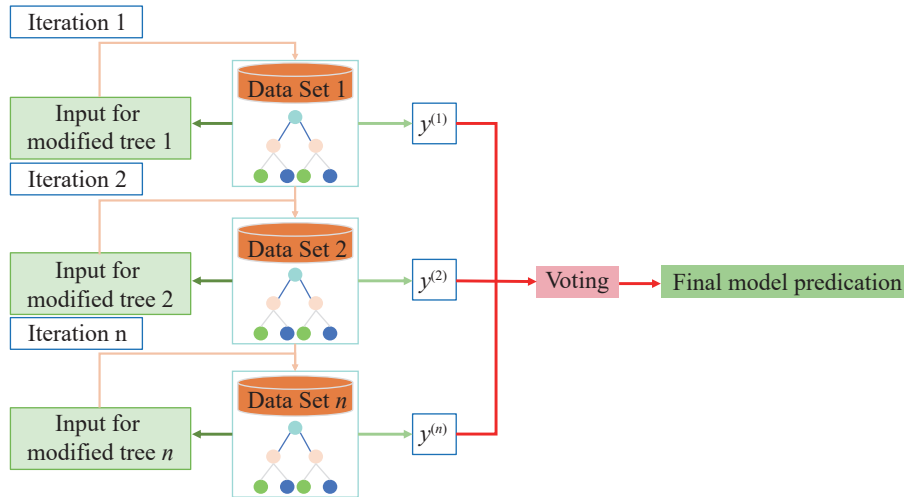


图9 XGBoost 网络结构^[56]

Fig. 9 Architecture of XGBoost network^[56]

在智能制造领域, 利用 XGBoost 与工业云平台的协同应用已成为优化工艺参数和预测铸坯质量的主流方案。Uyan 等^[59] 基于工业 4.0 云架构实时采集低压铸造过程的质量数据, 采用 XGBoost 集成学习算法构建铸造缺陷预测模型, 实现了 87% 的合格零件预测准确率, 不仅能够精准预测缺陷类型, 还能为生产工艺参数的优化提供数据支持。然而, XGBoost 模型的预测性能高度依赖于超参数优化配置, 而传统网格搜索方法在云平台的高并发场景下, 面临计算效率低与资源消耗大的挑战。

贝叶斯优化 (Bayesian optimization, BO) 算法是一种基于贝叶斯定理的概率统计方法, 常用于优化计算成本高、没有明确解析形式的目标函数, 尤其适用于超参数优化、实验设计, 以及需减少计算开销的优化问题^[60-62]。针对 XGBoost 预测过程中存在的不足, Ji 等^[63] 提出基于 BO 算法的 XGBoost 铸坯

夹渣缺陷预测方法, 通过分析不同特征对夹渣缺陷的影响, 构建 BO 优化的 XGBoost 预测模型, 并与主流集成模型进行对比实验, 如表 2 所示^[63]: 相对于梯度提升决策树 (gradient boosting decision tree, GBDT)、自适应提升 (adaptive boosting, Adaboost)、自适应合成采样 (adaptive synthetic sampling, ADASYN)、合成少数类过采样技术 (SMOTE) 等算法, XGBoost 展现出优异的预测性能。BO-XGBoost 虽训练耗时有所增加, 但在准确率 (0.756) 和精确度 (0.718) 方面排名位列第一, 曲线下面积 (area under the curve, AUC) 达 0.811, 在处理数据不平衡的夹渣缺陷预测任务时表现出更强的分类能力。此外, BO-XGBoost 较粒子群算法 (particle swarm optimization, PSO) 优化的 XGBoost 在精确度上提升约 2%, 且泛化能力更强, 表明其能有效处理高维复杂数据, 特别在处理非线性关系时表现出色。

表 2 不同模型的预测性能指标^[60]

Tab. 2 Prediction performance indicators of different models^[60]

模型	训练时间/s	AUC值(排序)	准确率(排序)	精确度(排序)
GBDT	1.632	0.680 (7)	0.652 (7)	0.656 (7)
Adaboost	0.434	0.657 (8)	0.644 (8)	0.621 (8)
XGBoost	0.546	0.764 (4)	0.715 (4)	0.694 (4)
ADASYN-XGBoost	0.783	0.745 (6)	0.701 (5)	0.649 (5)
SMOTE-XGBoost	0.791	0.749 (5)	0.700 (6)	0.644 (6)
BO-XGBoost	9.158	0.811 (1)	0.756 (1)	0.718 (1)
PSO-XGBoost	5.633	0.810 (3)	0.755 (2)	0.699 (2)
GA-XGBoost	10.474	0.811 (1)	0.752 (3)	0.696 (3)

2.2.3 其他集成质量预测模型

尽管基于树的集成模型(如 RF 和 XGBoost)在质量预测领域展现出较高的适用性,但工业场景复杂的生产工况(如多源数据耦合、动态工艺波动等)仍需探索更多元的模型融合策略。当前研究主要结合动态适应性优化、时间序列与数据平衡、降维与深度学习融合等方面构建新型集成框架。

1) 动态工况下的模型鲁棒性优化。动态工况下的模型鲁棒性是板坯质量预测的核心挑战,为解决这一难题,姜广森等^[64]开发了连铸板坯表面质量预报专家系统,通过集成混合式神经网络与逻辑模块提升模型稳定性;同时通过在结晶器宽和窄面布置热电偶实时采集温度数据,并结合冶金学理论、设备参数及专家经验知识,实现对黏结漏钢、表面裂纹等典型缺陷的综合判定。实验结果表明:该系统能够有效适应动态生产条件的变化,但受限于冶金知识库固化程度较高且神经网络权值自适应能力不足,其在动态工况下的泛化性能仍有待进一步提升。为此,王悦新等^[65]针对表面纵裂等缺陷,提出

了融合模糊专家系统与神经网络的集成预测模型,基于 2 000 炉生产数据构建具有自更新能力的分段规则库,实现工艺异常与缺陷风险的动态关联,解决传统专家系统知识库固化问题;通过模糊产生式规则处理结晶器液面波动、拉速等关键参数的不确定性,并引入纵裂指数预测模型来量化动态输入参数的影响权重。实验结果表明:该模型在测试集准确率达 92.8%,显著提升了动态生产条件下的质量预测性能。在此基础上,Sun 等^[66]提出了基于聚类减法的模糊自适应预测复合模型(adaptive neuro fuzzy inference system, ANFIS),其结构如图 10^[66]:通过聚类分析和聚类减法对裂纹数据集进行分组,降低处理数据量和模型复杂度;在划分训练集和测试集后,采用模糊逻辑处理工艺参数的不确定性和模糊特征,并利用 ANFIS 的自适应机制动态调整模型参数,最终输出优化后的质量预测结果。模拟结果证明,该模型能够根据板坯生产过程中的早期征兆进行质量预警,在动态扰动下的稳定性和工况适应能力得到显著提升。

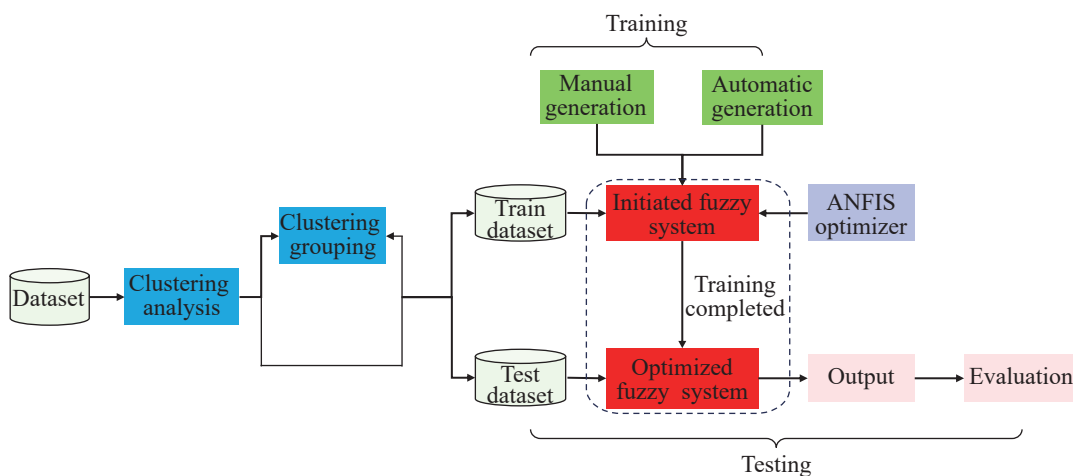


图10 ANFIS模型架构^[66]

Fig. 10 Architecture of ANFIS model^[66]

2) 时序特征与数据不平衡的处理策略。郭志成^[67]开发了图模式匹配与贝叶斯网络融合的混合预测模型,通过图模式匹配技术有效缓解数据倾斜问题,采用动态相似度评估路径调整输入特征,结合节点重要度选择算法和工况特征模式构建预测框架。实验结果表明:模型在对正常铸坯的预测准确率达 90.7%,对夹渣缺陷识别准确率为 82.8%,表现出优异的数据拟合能力。但受限于对工艺参数长期时序依赖关系的建模不足,模型在动态工况适应性方面仍存在提升空间。基于此,Wu 等^[68]提出多尺度卷

积循环神经网络(multi-scale convolutional recurrent neural network, MCRNN)与 LSTM 相结合的集成模型,其结构如图 11 所示:利用卷积神经网络提取铸造参数(如温度、压力)的局部空间特征,结合 LSTM 捕捉冷却过程的长期时序演化规律,经多层卷积和池化操作提取数据中的复杂模式,有效捕捉工艺参数间的动态交互效应,最后通过全连接层和 Softmax 层实现质量预测;同时引入随机欠采样算法,通过随机删除部分多数类样本使各类别的样本数大致相等,减少模型偏向于多数类样本的风险,提升模

型在少数类样本上的预测能力。实验结果表明: 采样比例为 1:2 时, MCRNN 可显著减少对正常板的

误判; 还可通过平衡数据集捕捉时间序列的长期和短期变化趋势, 有效提升模型的整体预测精度。

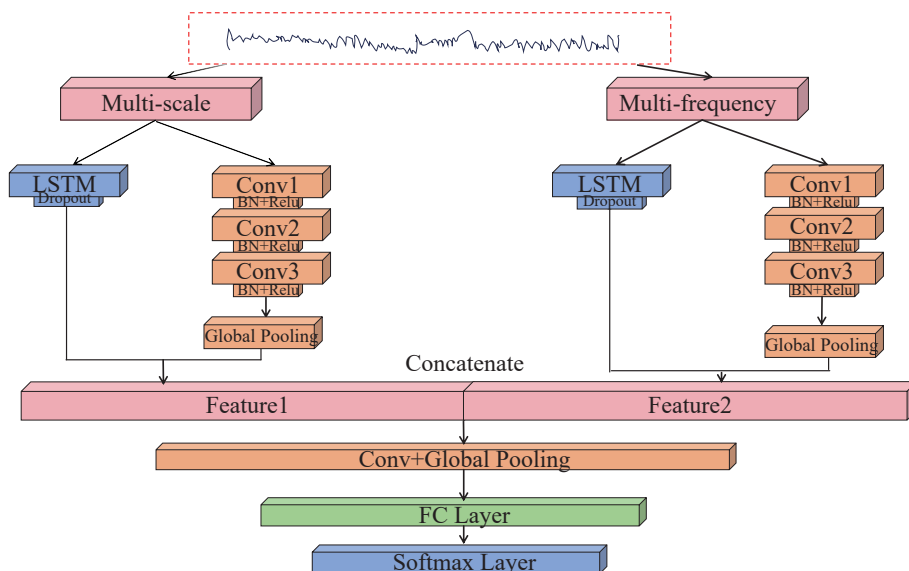


图 11 基于多尺度卷积循环神经网络的预测模型^[68]

Fig. 11 Prediction model of multi-scale convolutional recurrent neural network^[68]

3) 降维技术与深度学习的协同优化。降维技术与深度学习的融合为提升质量预测模型性能提供了新思路。安波等^[69]根据影响连铸坯质量的主要因素, 构建 BP 神经网络和 Kohonen 自组织特征映射相结合的混合模型。首先利用 Kohonen 网络通过自组织映射降维将 26 维输入压缩至 1 维竞争层, 通过无监督聚类将高维输入映射到 120 个神经元的响应区域, 在训练收敛 11 208 次后相关系数达到 0.92 以上, 最终将平均相对误差降至 7.86%, 有效避免了模型陷入局部最优。但是该模型依赖静态特征映射规则, 当生产工况波动导致数据分布偏移时, 无法通过无监督机制重构特征空间。针对这一缺陷, 研究者转向探索更具适应性的融合方案, 即结合动态降维技术与深度学习的集成建模方法。Zou 等^[70]采用主成分分析法降低输入变量的维度, 提出基于主成分分析 (PCA) 和深度神经网络 (DNN) 的集成质量

预测模型, 其 DNN 结构如图 12, 包括特征提取 (a) 和输出分类 (b) 两个核心模块。该模型首先运用 PCA 提取裂纹影响因子的正交主成分, 将原始高维特征投影至低维空间实现降维; 再利用 DNN 卷积层的 2D 矩阵乘法运算进行空间特征交互, 最终通过全连接层完成动态特征映射与分类决策。为弱化数据划分对数据驱动模型预测精度的影响, 采用 k 折叠交叉方法 (DT, ELM 和 BP 神经网络) 评估模型性能, 对比实验结果如表 3^[70]: 经 PCA 优化的模型在预测精度 (92.2%) 和结果稳定性方面明显改善; 尽管 DNN 因网络结构复杂导致计算耗时较长, 但其性能显著优于 DT 与 ELM 等传统方法。ELM 虽凭借随机权重机制实现 0.004 s 的快速计算, 但预测精度有限。研究证实, 基于 PCA-DNN 集成模型在内部裂纹预测任务中具有更高的精度和更强的泛化能力。




图 12 深度学习 (DNN) 网络模型结构^[70]

Fig. 12 Architecture of deep learning (DNN) network model^[70]

表3 不同模型的性能指标^[70]Tab. 3 Performance indicators of different models^[70]

预测模型	准确率/%		方差		计算时间/s
	PCA	No-PCA	PCA	No-PCA	
DNN	92.2	88.8	1.36	2.56	1.468
ELM	69.8	68.0	4.16	5.20	0.004
BP	73.2	69.4	1.76	3.44	1.053
DT	—	84.8	—	2.96	4.762

3 结论与展望

板坯质量预测技术的发展历程呈现出从传统质量预测模型到数据驱动模型转变。传统模型虽然在机理解释性方面保持优势,但面对现代智能化生产的高维、动态特性时,其适应性和计算效率的局限性日益凸显。相比之下,以机器学习为代表的驱动方法凭借强大的非线性建模能力与大数据处理优势,为板坯质量预测实现了技术突破。单一模型在特定场景下表现优异,如 Hou 等^[32]提出的 GA-BP 神经网络对三类钢种的预测准确率最高达 94.7%,均方误差控制在 0.044 5。而集成模型通过多模型协同进一步提升了预测性能,BO-XGBoost 模型的 AUC 值达 0.811,PCA-DNN 更是实现了 92.2% 的裂纹预测精度,展现出显著的工程应用价值。然而,当前模型仍面临数据依赖性强、计算资源消耗大、泛化能力不足及可解释性欠缺等产业化瓶颈。未来研究可从以下方面进行突破:

1) 多源数据融合与动态优化建模。现有模型对实时生产数据的动态适应性不足,如 Xi 等^[6]开发的应变分析模型和 Ai 等^[20]提出的微观组织模型,虽能反映特定冶金机理,但难以实时适应生产数据的动态变化特性。未来研究应深度整合工业物联网技术,实现温度传感器、拉速监测、结晶器振动信号等实时生产数据与数值模拟结果的多源融合;其次,构建具有 LSTM 时序预测的动态更新混合模型,通过动态权重调整机制增强模型对复杂工况的响应能力;同时,亟须建立工艺参数、图像硫印等多源异构数据的标准化处理框架,解决特征对齐问题,避免因数据分布差异导致的预测偏差。这种融合动态优化与多源数据处理的建模策略,有望提升模型在复杂工业环境中的适应性和预测精度。

2) 小样本学习增强与迁移学习。当前机器学习模型如 Wu 等^[68]的 MCRNN 模型、Zhao 等^[46]的 IPSO-LSSVM 模型,在样本数据充足时表现优异,但实际生产中缺陷样本数据较少,导致模型易受类

别不平衡的影响。未来可探索基于生成对抗网络或迁移学习的缺陷数据增强技术,结合冶金机理生成物理约束下的虚拟样本,提升模型在少样本场景下的泛化能力;此外,可将奥氏体晶粒尺寸与裂纹敏感性的定量关系等冶金规则嵌入神经网络损失函数,通过物理引导式训练减少对纯数据驱动的依赖。

3) 轻量化模型和边缘计算。当前集成模型如 Varfolomeev 等^[54]的随机森林模型预测精度高,但计算时间限制了其在实时预测中的应用。未来可结合模型蒸馏与硬件加速技术,将复杂集成模型压缩为轻量级模型,同时适配边缘计算设备,优化数据采集频率与模型更新策略,通过特征选择减少冗余计算、降低计算时间,使模型满足毫秒级响应的实时工业生产要求。

4) 可解释性与工艺反演调控。现有模型绝大多数为黑箱模型,缺乏对预测结果的冶金学解释,难以直接指导生产工艺参数调优。未来需结合可解释人工智能技术定量解析关键质量影响因素,如加入 SHAP 值反演分析 Li 等^[60]的 XGBoost 模型,明确各工艺参数如拉速与 C 含量等对夹渣缺陷的阈值效应,辅助工艺参数动态修正;构建冶金知识图谱,将模型预测结果映射至冶金规则库,实现从质量预测到模型诊断再到工艺的闭环优化。

5) 全流程协同预测与多目标优化。现有研究多聚焦于连铸单一工序分析,而实际板坯缺陷由炼钢成分控制、连铸工艺参数和轧制热力学条件的跨工序耦合作用引发。亟须构建全流程参数的协同预测框架,整合炼钢成分、连铸工艺与轧制热力学条件,利用图神经网络建模工序间的复杂耦合关系;同时,融合王旭^[29]提出的 SSA-LSTM 时序优化方法与 Franěk 等^[44]的关联规则挖掘技术,实现从钢液洁净度到板坯裂纹的多阶段因果推理;结合多目标优化算法,在质量预测精度与生产成本等关键指标间实现动态平衡,突破传统单一质量导向的优化局限。

参考文献:

- [1] 蔡开科. 连铸坯质量控制 [M]. 北京: 冶金工业出版社, 2010.
- [2] 王欢, 王志政, 臧红臣, 等. 板坯高效生产与铸坯质量控制技术的应用 [J]. 安徽冶金科技职业学院学报, 2024, 34(4):58-62.
WANG H, WANG Z Z, ZANG H C, et al. Application for high-efficient slab production and slab quality control technology[J]. Journal of Anhui Vocational College of Metallurgy and Technology, 2024, 34(4):58-62.
- [3] BELAQZIZ S, HAJJAMI E S, AMELLAL H, et al. Smart

- applications of artificial intelligence and big data[M]. CRC Press, 2024.
- [4] GENG X X, WANG F Y, WU H H, et al. Data-driven and artificial intelligence accelerated steel material research and intelligent manufacturing technology[J]. *Materials Genome Engineering Advances*, 2023, 1(1):e10.
- [5] ZHENG D, WU R X, SUFIAN M, et al. Flexural strength prediction of steel fiber-reinforced concrete using artificial intelligence[J]. *Materials*, 2022, 15(15):5194.
- [6] XI H, WU X, CHEN X H, et al. Artificial intelligent based energy scheduling of steel mill gas utilization system towards carbon neutrality[J]. *Applied Energy*, 2021, 295:117069.
- [7] 米春风, 卢琨, 汪文艳, 等. 基于机器视觉的带钢表面缺陷检测研究进展[J]. *安徽工业大学学报(自然科学版)*, 2022, 39(2):180-188.
- MIC F, LU K, WANG W Y, et al. Research progress on hot-rolled strip surface defect detection based on machine vision[J]. *Journal of Anhui University of Technology (Natural Science)*, 2022, 39(2):180-188.
- [8] 陈亮希, 张燕龙, 陈兴玉, 等. 浮空器主缆绳表面的小样本学习缺陷检测研究[J]. *安徽工业大学学报(自然科学版)*, 2022, 39(3):312-316,322.
- CHEN L X, ZHANG Y L, CHEN X Y, et al. Research on surface defect detection of aerostat main cable based on few-shot metric learning[J]. *Journal of Anhui University of Technology (Natural Science)*, 2022, 39(3):312-316,322.
- [9] 李一恒, 孙抗, 赵来军. 基于 Stacking 集成学习的无缝钢管连轧电耗预测[J]. *电子测量技术*, 2024, 47(8):53-60.
- LI Y H, SUN K, ZHAO L J. Electricity consumption prediction for seamless steel pipe continuous rolling based on Stacking ensemble learning[J]. *Electronic Measurement Technology*, 2024, 47(8):53-60.
- [10] 甘青松, 丁文静, 张竞丹. 基于多模型堆叠集成算法的连铸保护渣缺陷分析[J]. *冶金自动化*, 2024, 48(6):57-65.
- GAN Q S, DING W J, ZHANG J D. Defects analysis of protective slag based on multi-model stacked ensemble algorithm[J]. *Metallurgical Industry Automation*, 2024, 48(6):57-65.
- [11] WON Y M, YEO T J, SEOL D J, et al. A new criterion for internal crack formation in continuously cast steels[J]. *Metallurgical and Materials Transactions B*, 2000, 31(4):779-794.
- [12] HAN Z Q, CAI K K, LIU B C. Prediction and analysis on formation of internal cracks in continuously cast slabs by mathematical models[J]. *ISIJ International*, 2001, 41(12):1473-1480.
- [13] POLTARAK G, FERRO S, CICUTTI C. Estimation of internal cracking risk in the continuous casting of round bars[J]. *Steel Research International*, 2017, 88(4):1600223.
- [14] BRIMACOMBE J K, SORIMACHI K. Crack formation in the continuous casting of steel[J]. *Metallurgical Transactions B*, 1977, 8(2):489-505.
- [15] ZHU M Y, CAI Z Z. Formation mechanism and control technology of transverse corner cracks during slab continuous casting of microalloyed steels[J]. *Steel Research International*, 2023, 94(12):2300119.
- [16] LI Q H, LAN P, WANG H J, et al. Formation and control of the surface defect in hypo-peritectic steel during continuous casting: a review[J]. *International Journal of Minerals, Metallurgy and Materials*, 2023, 30(12):2281-2296.
- [17] CAI Z Z, AN J Z, CHENG B, et al. Effect of austenite grain size on the hot ductility of Nb-bearing peritectic steel[J]. *Metallurgical and Materials Transactions A*, 2023, 54(1):141-152.
- [18] 周红, 陶龙杰, 李智丽, 等. 0.22C-0.45Mn 钢低温奥氏体晶粒长大行为的研究[J]. *安徽工业大学学报(自然科学版)*, 2023, 40(1):52-58.
- ZHOU H, TAO L J, LI Z L, et al. A study of grain growth behavior of cryogenic austenite in 0.22C-0.45Mn steel[J]. *Journal of Anhui University of Technology (Natural Science)*, 2023, 40(1):52-58.
- [19] LYU S J, WU H H, WANG K Y, et al. The austenite to polygonal ferrite transformation in low-alloy steel: multi-phase-field simulation[J]. *Journal of Materials Research and Technology*, 2023, 24:9630-9643.
- [20] AI S Y, ZHANG Y M, LONG M J, et al. A prediction model for austenite grain size distribution of casting slab in thermal rebound process: considering α -ferrite precipitation and re-austenization[J]. *Journal of Materials Research and Technology*, 2024, 32:1788-1800.
- [21] LUO S, LI K K, WANG W L, et al. Numerical simulation of macrosegregation in continuously cast slab with application of S-EMS and MR[J]. *Journal of Materials Research and Technology*, 2023, 24:6893-6907.
- [22] CHIMANI C M, RESCH H, MÖRWALD K, et al. Precipitation and phase transformation modelling to predict surface cracks and slab quality[J]. *Ironmaking & Steelmaking*, 2005, 32(1):75-79.
- [23] JIANG C H, HUANG Z H, PEDAPATI T, et al. Network properties determine neural network performance[J]. *Nature Communications*, 2024, 15(1):5718.
- [24] 昌欢, 朱子康, 顾宝澍, 等. 基于 BP 神经网络的钢尾渣-矿渣基充填料强度预测[J]. *安徽工业大学学报(自然科学版)*, 2022, 39(3):256-261,267.
- CHANG H, ZHU Z K, GU B S, et al. A study of strength prediction of steel slag tailings-slag based filler based on BP neural network[J]. *Journal of Anhui University of Technology (Natural Science)*, 2022, 39(3):256-261,267.
- [25] LI P Z. Online quality prediction system of bloom castings based on BP neural network[J]. *Ironmaking & Steelmaking*, 2011, 46(5):33-37.
- [26] 夏德银. 连铸生产过程中铸坯质量预测研究[D]. 沈阳: 东北大学, 2009.
- XIA D Y. Research on Quality Prediction of Continuous Casting Slab in the Production Process[D]. Shenyang: Northeastern University, 2009.

- [27] 常运合, 曾智, 张家泉, 等. 基于BP神经网络的大方坯质量在线预报模型[J]. 钢铁, 2011, 46(5):33-37.
CHANG Y H, ZENG Z, ZHANG J Q, et al. Online quality prediction system of bloom castings based on BP neural network[J]. *Iron & Steel*, 2011, 46(5):33-37.
- [28] 卢海彪, 张辉琪, 刘雨寒, 等. 基于加权极限学习机的连铸坯质量预测[J]. 冶金自动化, 2023, 47(S1):106-111.
LU H B, ZHANG H Q, LIU Y H, et al. Quality prediction of continuous casting slab based on weighted limit learning machine[J]. *Metallurgical Industry Automation*, 2023, 47(S1):106-111.
- [29] 王旭. 面向神经计算的连铸坯质量预测方法研究[D]. 唐山: 华北理工大学, 2021.
WANG X. Research on Quality Prediction Methods of Continuous Casting Slab for Neuromorphic Computing[D]. Tangshan: North China University of Science and Technology, 2021.
- [30] MEHROLIYA S, TOMAR S, ARYA A, et al. A novel hybrid GA-PSO algorithm-based optimization of transmission and expansion planning[J]. *SN Computer Science*, 2023, 4(5):690.
- [31] 陈恒志, 杨建平, 余相灼, 等. 基于主成分分析的连铸坯质量预测研究[C]//第十一届中国钢铁年会论文集: S18 冶金自动化与智能管控. 北京: 中国金属学会, 2017: 14-20.
CHEN H Z, YANG J P, YU X Z, et al. Research on quality prediction of continuous casting slab based on principal component analysis[C]//Proceedings of the 11th China Iron & Steel Annual Conference: S18 Metallurgical Automation and Intelligent Management. Beijing: The Chinese Society for Metals, 2017:14-20.
- [32] HOU Z B, PENG Z Q, LIU Q, et al. Quality prediction of hot rolled products and optimization of continuous casting process parameters based on big data mining[C]//Materials Processing Fundamentals 2023. Cham: Springer Nature Switzerland, 2023:65-73.
- [33] KONG Y W, CHEN D F, LIU Q, et al. A prediction model for internal cracks during slab continuous casting[J]. *Metals*, 2019, 9(5):587.
- [34] LU Z Q, REN N, XU X W, et al. Real-time prediction and adaptive adjustment of continuous casting based on deep learning[J]. *Communications Engineering*, 2023, 2:34.
- [35] YU Z, NGUYEN T D, JU L, et al. Hierarchical skin lesion image classification with prototypical decision tree[J]. *NPJ Digital Medicine*, 2025, 8(1):26.
- [36] 曹俊. 铸坯质量的多元统计分析及决策树规则研究[D]. 武汉: 武汉科技大学, 2008.
CAO J. Multivariate Statistical Analysis and Decision Tree Rule Research on Slab Quality[D]. Wuhan: Wuhan University of Science and Technology, 2008.
- [37] KOPPER A E, APELIAN D. Predicting quality of castings via supervised learning method[J]. *International Journal of Metalcasting*, 2022, 16(1):93-105.
- [38] SAYED M S, HAMID R E. Applying data mining methods to predict defects on steel surface[J]. *Journal of Theoretical and Applied Information Technology*, 2010, 20(2):87-92.
- [39] 彭平, 卢金雄, 李炳源, 等. 运用主成分分析法建立钢坯质量预测模型[J]. 钢铁, 1991, 26(10):12-13, 18.
PENG P, LU J X, LI B Y, et al. Model prediction on steel quality by principal component analysis[J]. *Gangtie*, 1991, 26(10):12-13, 18.
- [40] 王宝, 张志刚, 陈海芳, 等. 连铸大方坯内部质量多元模糊模式预测研究[J]. 计算机与应用化学, 2012, 29(12):1416-1420.
WANG B, ZHANG Z G, CHEN H F, et al. Prediction of internal quality of the continuous casting blooms based on multivariate fuzzy pattern recognition[J]. *Computers and Applied Chemistry*, 2012, 29(12):1416-1420.
- [41] 赵济民, 何杨, 刘建华, 等. 基于即时学习算法的铸坯质量预测方法[J]. 连铸, 2022, 47(6):54-60,67.
ZHAO J M, HE Y, LIU J H, et al. Predictive method of casting slab quality based on just-in-time learning algorithm[J]. *Continuous Casting*, 2022, 47(6):54-60,67.
- [42] 王怡青. 连铸坯中心偏析质量分析及预报研究[D]. 沈阳: 东北大学, 2014.
WANG Y Q. Research on Quality Analysis and Prediction of Center Segregation in Continuous Casting Slab[D]. Shenyang: Northeastern University, 2014.
- [43] NORMANTON A S, BARBER B, BELL A, et al. Developments in online surface and internal quality forecasting of continuously cast semis[J]. *Ironmaking & Steelmaking*, 2004, 31(5):376-382.
- [44] FRANĚK Z, PYSZKO R. Logit model and prediction quality of continuously cast slabs[C]//METAL Conference Proceedings, Metal 2020 Conference Proceedings. TANGER Ltd, 2020:23-28.
- [45] 邓比涛, 韩志伟, 刘强, 等. 中冶赛迪铸坯质量在线预测系统研发及实践[J]. 连铸, 2022, 47(6):80-87.
DENG B T, HAN Z W, LIU Q, et al. Development and application of CISDI continuous casting online quality prediction system[J]. *Continuous Casting*, 2022, 47(6):80-87.
- [46] ZHAO L P, DOU R S, YIN J J, et al. Intelligent prediction method of quality for continuous casting process[C]//2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference. Xi'an, China: IEEE, 2016:1761-1764.
- [47] ZHU Q Y, QIN A K, SUGANTHAN P N, et al. Evolutionary extreme learning machine[J]. *Pattern Recognition*, 2005, 38(10):1759-1763.
- [48] PARIKH D, POLIKAR R. An ensemble-based incremental learning approach to data fusion[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2007, 37(2):437-450.
- [49] MUHLBAIER M D, TOPALIS A, POLIKAR R. Learn ++NC: combining ensemble of classifiers with dynamically weighted consult-and-vote for efficient incremental learning of new classes[J]. *IEEE Transactions on Neural Networks*,

- 2009, 20(1):152–168.
- [50] ZHOU J, YANG P X, YONG W X, et al. A comparative analysis of hybrid RF models for efficient lithology prediction in hard rock tunneling using TBM working parameters[J]. *Acta Geophysica*, 2024, 72(3):1847–1866.
- [51] PALLEMBERG R, FLEITMANN M, STROTH A M, et al. Random forest and gradient boosted trees for patient individualized contrast agent dose reduction in CT angiography[J]. *Studies in Health Technology and Informatics*, 2023, 302:952–956.
- [52] 邱一卉, 林成德. 基于随机森林方法的异常样本检测方法[J]. *福建工程学院学报*, 2007, 5(4):392–396.
- QIU Y H, LIN C D. Outlier detection based on random forest[J]. *Journal of Fujian University of Technology*, 2007, 5(4):392–396.
- [53] ZHANG X, ZHOU J. An empirical comparison of random forest and other machine learning algorithms for predicting software defects[J]. *Journal of Software Engineering and Applications*, 2020:1133–1155.
- [54] VARFOLOMEEV I A, ERSHOV E V, VINOGRADOVA L N. Statistical control of defects in a continuously cast billet based on machine learning and data analysis methods[J]. *Automation and Remote Control*, 2018, 79(8):1450–1457.
- [55] 张赫, 段海洋, 王旭东, 等. 基于随机森林和聚类的连铸坯纵裂纹预报方法[J]. *连铸*, 2022, 47(6):21–28,44.
- ZHANG H, DUAN H Y, WANG X D, et al. Longitudinal crack prediction method of continuous cast slab based on random forest and clustering[J]. *Continuous Casting*, 2022, 47(6):21–28,44.
- [56] MALAKOUTI S M, KARIMI F, ABDOLLAHI H, et al. Advanced techniques for wind energy production forecasting: leveraging multi-layer Perceptron + Bayesian optimization, ensemble learning, and CNN-LSTM models[J]. *Case Studies in Chemical and Environmental Engineering*, 2024, 10:100881.
- [57] Utkarsh, JAIN P K. Predicting bentonite swelling pressure: optimized XGBoost versus neural networks[J]. *Scientific Reports*, 2024, 14(1):17533.
- [58] 沈雅倩, 黄志甲, 周涛. 基于 XGBoost 分类算法的热舒适预测模型[J]. *安徽工业大学学报(自然科学版)*, 2022, 39(1):74–78,99.
- SHEN Y Q, HUANG Z J, ZHOU T. Thermal comfort prediction model based on XGBoost classification algorithm[J]. *Journal of Anhui University of Technology (Natural Science)*, 2022, 39(1):74–78,99.
- [59] UYAN T Ç, OTTO K, SANTOS SILVA M, et al. Industry 4.0 foundry data management and supervised machine learning in low-pressure die casting quality improvement[J]. *International Journal of Metalcasting*, 2023, 17(1):414–429.
- [60] LI H, YANG Z W, LV H, et al. Research on mine water source classifications based on BO–CatBoost[J]. *Environmental Monitoring and Assessment*, 2024, 196(10):876.
- [61] AWASTHI D, KHARE P, SRIVASTAVA V K. PBNHWA: NIFTI image watermarking with aid of PSO and BO in wavelet domain with its authentication for telemedicine applications[J]. *Multimedia Tools and Applications*, 2024:1–13.
- [62] QIU Y G, ZHOU J, KHANDELWAL M, et al. Performance evaluation of hybrid WOA–XGBoost, GWO–XGBoost and BO–XGBoost models to predict blast-induced ground vibration[J]. *Engineering with Computers*, 2022, 38(5):4145–4162.
- [63] JI Y, WANG W L, ZHOU L J, et al. Prediction and feature analysis of entrapped slag defect on casting slab based on optimized XGBoost model[J]. *Metallurgical and Materials Transactions B*, 2024, 55(4):2026–2036.
- [64] 姜广森, 毕学工, 金焱, 等. 连铸板坯表面质量预报专家系统[J]. *山东冶金*, 2005, 27(3):36–39.
- JIANG G S, BI X G, JIN Y, et al. Surface quality forecasting expert system of continuous casting slab[J]. *Shandong Metallurgy*, 2005, 27(3):36–39.
- [65] 王悦新, 邱以清, 刘相华. 连铸坯质量判定模糊专家系统[J]. *东北大学学报(自然科学版)*, 2009, 30(7):989–992.
- WANG Y X, QIU Y Q, LIU X H. On the fuzzy expert system for quality judgement of continuous casting slabs[J]. *Journal of Northeastern University (Natural Science)*, 2009, 30(7):989–992.
- [66] SUN J, WANG J X, LIU Z W. Study on crack forecast model of continuous casting slab[C]//2009 International Asia Conference on Informatics in Control, Automation and Robotics. Bangkok, Thailand: IEEE, 2009:410–413.
- [67] 郭志成. 基于图模式匹配的连铸坯质量预测方法研究[D]. 北京: 冶金自动化研究设计院, 2024.
- GUO Z C. Research on Quality Prediction Method of Continuous Casting Slab Based on Graph Pattern Matching[D]. Beijing: Automation Research and Design Institute of Metallurgical Industry, 2024.
- [68] WU X, JIN H L, YE X M, et al. Multiscale convolutional and recurrent neural network for quality prediction of continuous casting slabs[J]. *Processes*, 2021, 9(1):33.
- [69] 安波, 闫彬, 刘永姜. 基于 BP 和 Kohonen 神经网络结合的铸坯在线质量评估[J]. *中北大学学报(自然科学版)*, 2016, 37(3):268–272.
- AN B, YAN B, LIU Y J. The online quality evaluation of continuous casting billet based on BP and kohonen neural network[J]. *Journal of North University of China (Natural Science Edition)*, 2016, 37(3):268–272.
- [70] ZOU L L, ZHANG J S, HAN Y S, et al. Internal crack prediction of continuous casting billet based on principal component analysis and deep neural network[J]. *Metals*, 2021, 11(12):1976.