

doi:10.12068/j.issn.1005-3026.2025.20250092

热轧钢材组织性能预测——从物理模型到 人机混合智能的发展与展望

吴思炜, 周晓光, 刘振宇, 王国栋

(东北大学 数字钢铁全国重点实验室, 辽宁 沈阳 110819)

摘要: 本文梳理了钢材组织性能预测模型研究进展, 重点介绍人机混合智能驱动的热轧工业模型及其组成; 通过综合利用物理冶金原理和人工智能技术, 解析轧制过程显微组织演变机制. 此外, 围绕钢材热轧过程显微组织演变与力学性能高效预测、高强钢合金减量化设计和宽厚板高效轧制工艺开发3个方面, 介绍了基于人机混合智能驱动的热轧工业模型典型应用案例, 为推动钢铁研发由经验试错向人机混合智能驱动的钢铁材料理性设计提供参考.

关键词: 人机混合智能; 组织演变; 性能预测; 工业模型; 热轧

中图分类号: TB 3 文献标志码: A 文章编号: 1005-3026(2025)08-0011-09

Microstructure and Property Prediction of Hot-Rolled Steel: Development and Prospects from Physical Models to Human-Machine Hybrid Intelligence

WU Si-wei, ZHOU Xiao-guang, LIU Zhen-yu, WANG Guo-dong

(State Key Laboratory of Digital Steel, Northeastern University, Shenyang 110819, China. Corresponding author: LIU Zhen-yu, E-mail: zyliu@mail.neu.edu.cn)

Abstract: The research progress of steel microstructure and property prediction models was reviewed, and the hot-rolled industrial model driven by human-machine hybrid intelligence and its components were introduced. By comprehensively utilizing physical metallurgy principles and artificial intelligence technologies, the microstructure evolution in the rolling process was deciphered. In addition, typical application cases of hot-rolled industrial models driven by human-machine hybrid intelligence were introduced in terms of three aspects: microstructure evolution and mechanical property prediction of hot-rolled steel, alloy composition reduction design of high-strength steel, and efficient rolling process development of wide thick plates. This provides references for promoting the rational design of steel research and development from experience-based trial and error to be driven by human-machine hybrid intelligence.

Key words: human-machine hybrid intelligence; microstructure evolution; property prediction; industrial model; hot rolling

钢铁材料工艺研发作为钢铁生产的核心环节, 长期面临机理复杂、实验周期长、研发成本高等诸多挑战. 由于产品性能取样检测通常要等板卷下线2~7 d才能反馈实测值, 在时效上存在显著滞后性, 难以对产品质量控制形成有效反馈^[1];

在空间维度上, 因钢材沿长度方向温度分布不均, 不同取样位置性能并不相同, 因此取样点性能无法反映板卷整体性能分布, 导致产品性能均匀性难以量化描述. 传统工艺优化往往依靠工程师专业经验设计工艺参数, 通过试错法优化现有

收稿日期: 2025-07-23

基金项目: 国家重点研发计划项目(2021YFB3702404); 国家自然科学基金青年科学基金资助项目(52104370); 中信镍钢发展奖励基金资助项目(2022-M1824).

作者简介: 吴思炜(1989—), 男, 辽宁阜新人, 东北大学副教授; 刘振宇(1967—), 男, 内蒙古赤峰人, 东北大学教授, 博士生导师; 王国栋(1942—), 男, 辽宁大连人, 东北大学教授, 博士生导师, 中国工程院院士.

工艺,实时性低且稳定性差.显然,这种依赖工程师专业经验开发新材料的研发模式,已难以满足现代钢铁工业对“高质量、高效率、低成本”研发的现实需求.因此,建立热轧生产全流程显微组织演变和性能预测方法,明确成分、工艺对显微组织和力学性能的影响关系,破解显微组织演变“黑箱”对工艺优化设计具有重要意义.

当前钢材热轧过程模型已经取得了长足发展^[2-3],然而在钢材热轧过程中,显微组织演变、轧制载荷和表面氧化行为呈强耦合关系,是“牵一发而动全身”的复杂系统.一方面,热轧过程温度与轧制载荷的综合作用使轧件内部发生微合金元素碳氮化物的析出、奥氏体再结晶和加工硬化等物理冶金学行为,这些显微组织演变直接影响轧件的变形抗力,进而影响轧制力的设定;另一方面,在轧制过程中轧件暴露在高温和空气环境下,不可避免地会发生表面氧化.轧制载荷的设定会影响轧件表面氧化铁皮厚度演变.同时,作为轧辊与轧件的界面介质,氧化铁皮厚度的变化影响着界面摩擦系数,进而对轧制力产生影响.总之,热轧产品的组织演变、轧制载荷和表面氧化行为呈现强耦合特点^[4],只有解耦其关系,才能实现热轧产品组织性能、三维尺寸、表面质量的协同优化控制,提升产品综合质量.传统的解决方法是将组织性能、三维尺寸和表面质量在一定假设条件下分离求解,并未考虑到其耦合关系及相互作用,因此无法反映轧件内部真实的显微组织演变过程.人机混合智能的出现为破解上述困境提供了全新途径.人机混合智能并非简单地用机器替代人类,而是结合专家经验和机器学习算法对数据的挖掘能力,构建“机理+数据”的混合驱动训练模式.人机混合智能与热轧工业模型的融合可以理解为专家知识和机器智能的协同优化.其中,研究人员的专家经验为机器学习建模提供指导和可解释性,机器学习算法的数据挖掘能力拓展了人类的认知边界,两者共同推动钢材研发由经验驱动向人机混合智能驱动转型.

本文梳理了钢材组织性能预测模型发展现状,并重点介绍了基于人机混合智能的热轧工业模型架构及其建模方法;在此基础上,分析了热轧钢材显微组织和力学性能高效预测、高强钢合金减量化设计和高强船板钢高效轧制工艺设计3个典型案例的应用效果;最后展望了基于人机混合智能的热轧工业模型在推动钢铁智能制造进程中的发展方向.

1 钢材组织性能预测的发展现状

钢材组织性能预测研究自 20 世纪 70 年代至今,已开展了半个多世纪,其发展主要分为以下 3 种技术路线:

第 1 种路线为物理冶金机理引导的钢材组织性能预测模型,该模型主要由专家知识主导,可以认为是人类智能的体现.在物理冶金学原理的指导下,通过对热轧显微组织演变规律的长期探索,研究者建立了轧件从出加热炉、轧制、冷却到成品的全流程显微组织演变模型,描述了热轧过程发生的物理冶金学行为^[5-8].20 世纪中末期, Sellars 等^[9-10]针对热轧 C-Mn 钢、高强度低合金钢等不同成分体系钢材建立了热轧过程显微组织演变模型,开启了钢材组织性能预测研究领域.随着物理冶金理论不断发展,近些年针对物理冶金行为有了更多深入的研究, Wang 等^[11]利用 Estrin-Mecking 方程研究了管线钢加工硬化和动态回复的应力-应变行为,结合特征应变建立了动态再结晶动力学模型,取得了较好的预测效果. Zurob 等^[12-13]建立了析出动力学和再结晶软化动力学模型,解耦了析出、回复和再结晶过程之间的关系. Collins 等^[14]通过考虑碳分配模型、热力学边界条件和马氏体转变行为,开发了一个预测低合金钢连续冷却转变(CCT)行为的模型,模型能够较好地反映实验测量结果.由此可见,这一路线的特点是研究者们以物理冶金理论为基础,基于大量实验室实验,建立描述热轧生产过程中特定环节或全流程组织演变的数学模型,实现组织演变及力学性能的模拟与预测,为钢材工艺优化设计提供依据.

第 2 种路线为数据驱动的钢材显微组织和力学性能预测模型.在面临大规模数据集时,机器学习算法可以高效挖掘数据之间蕴含的非线性关系,弥补了人类智能对复杂非线性关系归纳总结困难的局限,从而实现了以机器学习为主,以专家知识验证为辅的学习模式.一方面,机器学习模型可以直接用于构建自变量和因变量之间的对应关系.如人工神经网络^[15-17]、深度学习^[18]、集成学习^[19]等算法已被广泛应用于构建轧制力与化学成分、工艺参数及设备条件之间的关系. Rahaman 等^[20]基于机器学习算法开发了马氏体相变起始温度预测模型,并结合专家经验对模型合理性进行验证.与经典热力学模型相比,该模

型具有更好的预测精度.Pattanayak等^[21]通过采用人工神经网络、随机森林和支持向量机算法,建立了管线钢力学性能预测模型,其预测精度高于传统模型.另一方面,机器学习算法和多目标优化理论相结合,可以满足合金成分优化^[22-23]、工艺参数调控^[24-25]、机器学习超参数优化^[26]等多种需求.Song等^[27]将改进粒子群优化和XGBoost算法融合,获得了潜在的最优化学成分和工艺参数,设计出具有优异强塑性的钢材.Diao等^[28]提出了一种以综合性能为目标函数的优化策略,实现对正火温度、淬火温度、回火温度工艺参数的优化,以开发具有优异综合性能的新型钢材.然而,在预测显微组织和热力学参数时,由于机器学习模型所需的数据成本高昂,极大地增加了建模难度.

第3种路线为机理和数据混合驱动的钢材组织性能预测模型,该模型为人类智能和机器智能协同建模的学习模式,这种模式既保留了人类的专家经验,又发挥了机器智能信息挖掘的优势^[29-30].为了实现低成本的显微组织预测,研究人员将研究重点转移至物理冶金和机器学习算法相融合^[31-32].文献^[33]基于物理冶金学原理建立热轧钢材组织演变的基础框架,可以对显微组织进行预测,并保证了模型的可解释性;在此基础上,结合工业数据和智能优化算法,对模型基础框架中的关键参数进行寻优,在保证其模型可解释性的基础上提升其预测精度.通过这种方式,实现专家经验和机器智能相互协同,即以人类智能主导的物理冶金学机理模型保证了其合理性,机器辅助的数据驱动模型提高基础模型预测精度,进而实现模型的持续优化.这种架构不仅适用于热轧工业过程,更为整个材料领域的智能化转型提供了可推广的范式.为了提高模型的泛化能力,Li等^[34]将物理冶金学理论与机器学习算法相结合,开发了预测Nb微合金钢热轧过程动态再结晶行为模型.与传统方法相比,该模型预测精度明显提高,同时泛化能力得以改善.Jiang等^[35]通过数据驱动的机器学习方法研究了Hall-Petch关系的物理本质,揭示了影响多晶金属屈服强度的关键物理量及其机理.通过计算而非实验拟合方法直接预测多晶金属的屈服强度,探讨了晶粒结构和力学性能之间的关系.Zhang等^[36]建立了316不锈钢屈服强度、堆垛层错能、纯疲劳寿命和蠕变断裂时间预测模型,结合变形条件,采用物理信息神经网络成功预测了316不锈钢的蠕

变疲劳寿命.当前研究通过深度融合物理机制与机器学习,显著提升了材料性能预测的精度与泛化能力,同时增强了模型的可解释性,为材料设计与工艺优化提供了理论支撑.

综上所述,针对钢材组织演变过程,融合机理和数据对不同物理冶金现象建模已开展了广泛研究,取得了显著效果^[37].钢铁工业属于流程型工业,其生产连续性导致上下游工序的遗传特征和协同效应是其突出特点,考虑各工序模型的交互影响是确保模型能够精准描述热轧全流程组织演变的关键.为此,针对热轧全流程工序,将专家的物理冶金知识融入机器学习,以数据挖掘反馈优化机理模型参数,形成以人机混合智能为核心的热轧全流程工业模型,是构建高精度、高鲁棒性且具备可解释性组织演变模型新的发展方向.

2 基于人机混合智能的热轧工业模型

热轧产品综合质量受表面氧化、轧制载荷、显微组织演变的综合影响,为实现对热轧钢材表面氧化、轧制载荷、显微组织演变等关键过程的数字解析,研究人员基于热轧工业大数据挖掘技术,融合轧钢工艺原理和人机混合智能开发出集成显微组织演变、氧化皮厚度演变、界面摩擦及轧制力变化的热轧钢材工业模型.在此基础上,结合多目标优化理论与方法,实现了热轧产品质量综合调控,其基本流程如图1所示.

1) 基于数据的物理机制挖掘与知识学习.热轧生产过程中,各工序关联密切且会发生回复、再结晶、相变、析出等多种物理冶金学现象.虽然针对钢材高温变形行为已经开展了大量实验研究,并建立了相关数学模型^[38-39].但是,当前建模均是在一定假设条件下进行的,且模型参数都是基于实验室实验结果拟合确定,这些原因使所建立模型在实际工业应用中偏差较大,无法真实反映热轧生产过程.针对上述难题,Gao等^[40]采用符号回归等人工智能算法,在不需要理论假设的条件下,根据数据内涵寻找变量间内禀关系并建立数学表达式,结合专家经验挖掘出数据集所蕴含的物理冶金学规律.以热轧过程形变诱导析出为例,通过对已有实验数据的挖掘和知识的提取,建立了形变诱导析出开始/结束时间与成分、变形工艺的对应关系,精准预测了形变诱导析出行

为.与传统 Dutta-Sellars 模型相比,预测精度提高 1 倍以上.

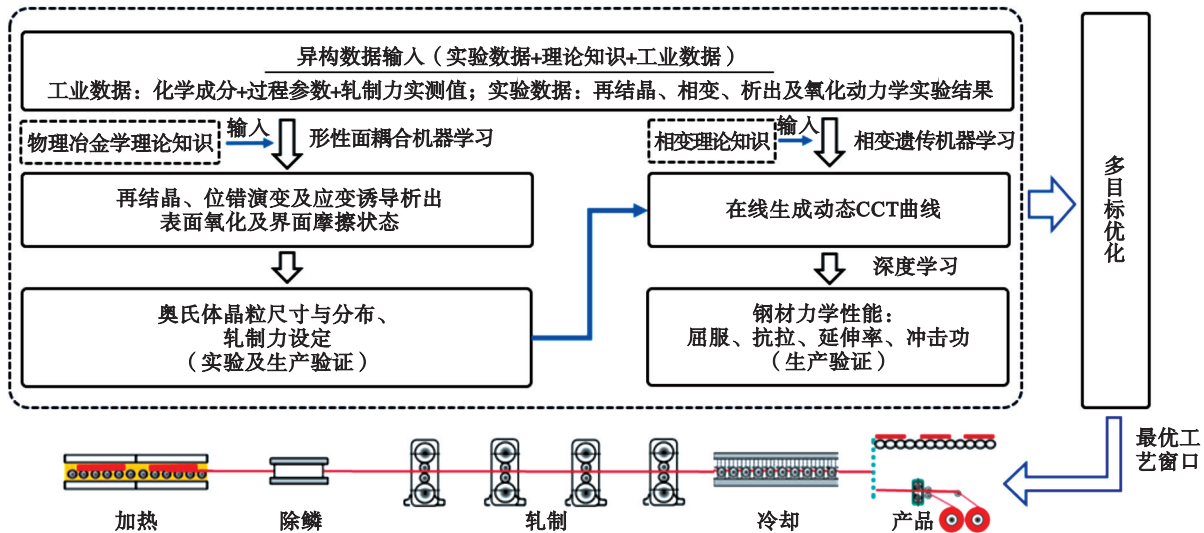


图1 基于人机混合智能的钢材热轧工业模型流程图

Fig. 1 Flow chart of hot-rolled industrial model of steel based on human-machine hybrid intelligence

2) 轧制过程“组织演变-轧制载荷-界面状态”强耦合机器学习.在热轧过程中,轧件内部显微组织演变、界面摩擦系数和轧制力相互作用、相互影响.在众多因素中,轧制力作为生产过程可实时测量的参数,可以用来评价显微组织演变计算的准确性.因此,对比轧制力预测值和实际值,并通过流变应力模型间接校正显微组织演变模型参数,可实现耦合状态下的模型评价,并揭示出轧制过程中奥氏体再结晶及晶粒形态的演变过程.此外,热轧生产过程中在钢材表面会生成氧化铁皮,氧化铁皮可以作为轧辊与轧件界面的润滑介质,进而影响轧制载荷.Cui等^[41]考虑轧件和轧辊的摩擦系数等影响因素,建立了非等温氧化动力学模型,实现了对热轧全流程氧化铁皮厚度的预测.在此基础上,可进一步预测轧制力,从而提升板形的控制精度.

3) 冷却过程动态相变遗传机器学习.轧制结束后,热轧钢材需经历加速冷却过程以控制其相变行为.轧后奥氏体组织状态和冷却路径共同作用决定了相变产物、各相比例及晶粒的细化程度.在轧制工艺参数基本不变的前提下,冷却路径将直接决定钢材的相组成进而决定其最终力学性能.快速精准获得连续冷却转变曲线有助于制定出正确的冷却路径,实现对热轧钢材性能的精准调控.此外,相变过程贝氏体含量和形态的精确控制对于开发兼具高强度、高韧性和良好变形性的高强钢至关重要.然而,由于不同形态贝氏体形成的热力学条件和转变机制相似,传统物理模型无法区分不同形态贝氏体.Cao等^[42]提出

一种基于梯度提升树和支持向量回归的机器学习方法,实现不同成分和工艺参数下热轧钢材的相变产物分数及形态预测.在此基础上,建立不同钢种CCT数据库,结合物理冶金学原理开发了动态相变的遗传性机器学习建模方法,实现了不同钢种连续冷却相变曲线的快速生成.

4) 基于多模态数据的力学性能深度学习.高强钢在冷却阶段发生复杂的相变行为,受冷却路径影响十分敏感.在力学性能预测过程中,传统仅依赖最终显微组织特征等数据的建模方法无法充分反映冷却路径波动对产品显微组织及性能的影响,导致预测结果与实际性能间存在显著偏差.Cao等^[43]考虑连续冷却CCT曲线与冷却路径对最终显微组织的影响,引入卷积神经网络建立了力学性能深度学习模型.该模型不仅克服了传统数据驱动机器学习模型在处理非结构化数据时特征丢失的问题,还提升了模型对多模态信息的理解能力,从而实现力学性能的精准预测.

5) 热轧工艺智能设计.为实现热轧产品显微组织或性能的定制化控制,需要针对用户对产品组织及性能的个性化需求进行工艺的优化并快速设计出最优生产工艺^[44-45].为此,针对实际生产过程,将目标函数 F 设定为预测力学性能与目标力学性能的差,按式(1)求解多目标优化问题.

$$\left. \begin{aligned} \text{Min } F = +\infty, & \quad P < T \text{ 或 } P > T + \mu; \\ \text{Min } F = P - T, & \quad T \leq P \leq T + \mu. \end{aligned} \right\} \quad (1)$$

式中: P 和 T 分别是力学性能的预测值和目标值; μ 是目标力学性能的阈值.在求解多目标优化问题过程中,评价函数设置为多目标优化问题的目

标函数,以显微组织、设备能力、待优化工艺参数等作为约束条件.在此基础上,针对产品质量要求,研究人员开发了热轧钢材工艺智能优化系统^[46],并在工业生产中实现了钢材高表面质量与性能稳定性控制.

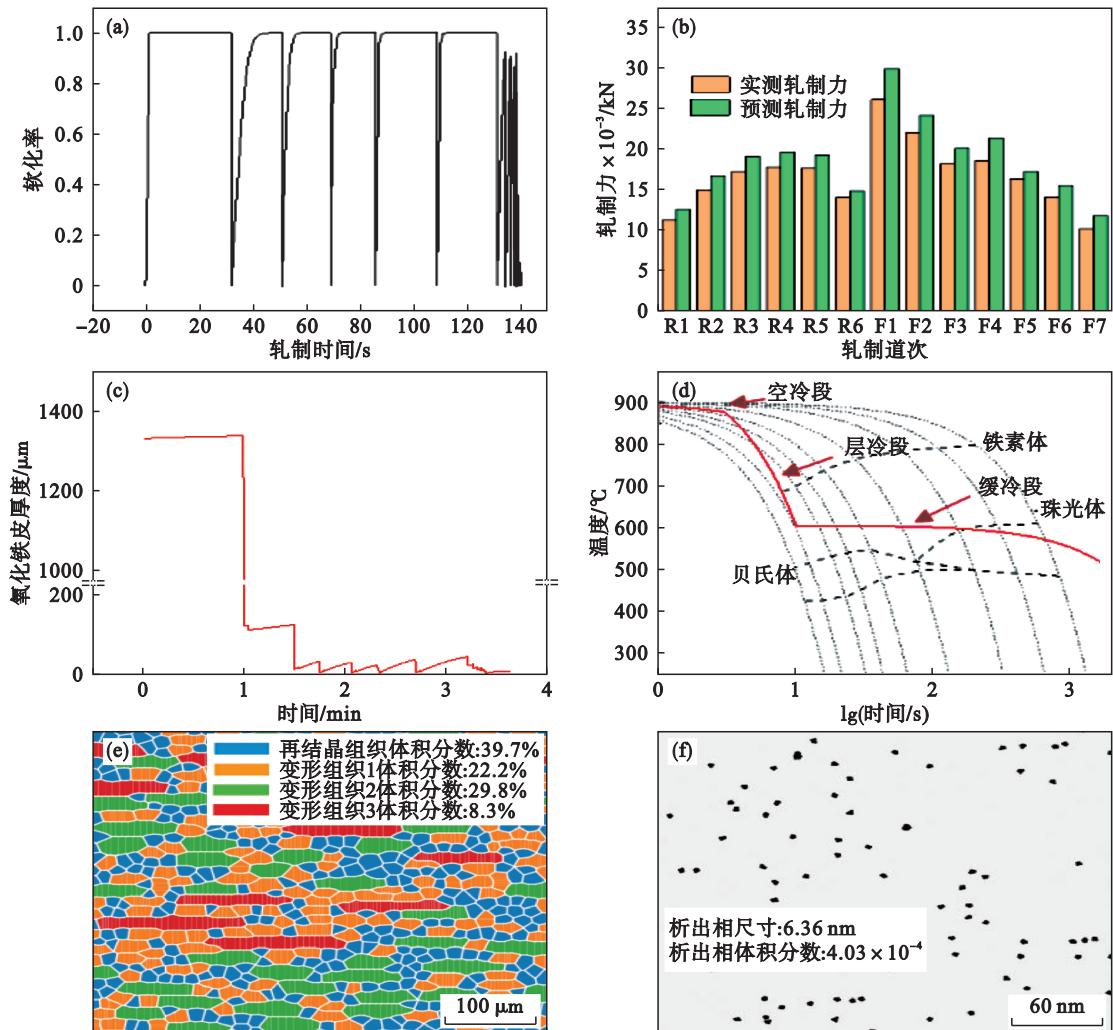
3 基于人机混合智能的热轧工业模型典型应用

3.1 热轧钢材显微组织在线可视化与力学性能高效预测

热轧钢材显微组织演变为强耦合过程,其组织演变不可见为产品综合质量控制带来了极大挑战.要想实现产品综合质量控制,必须解耦显微组织、轧制载荷、表面氧化行为,破解显微组织演变“黑箱”.

人机混合智能驱动的热连轧工业模型可以对热轧钢材加热过程晶粒长大行为、轧制过程奥氏体再结晶行为、连续冷却过程相变行为、微合

金元素碳氮化物溶解析出行为、氧化铁皮厚度演变行为等进行计算,实现显微组织演变的定量描述^[47].图2为S420MC热轧过程显微组织、轧制力和氧化铁皮厚度的解耦计算结果.其中,图2b中R1~R6为粗轧第1道次至第6道次,F1~F7为精轧第1道次至第7道次.图2d为当前钢卷对应的动态CCT曲线,可为冷却工艺的制定提供参考.在此基础上,通过对轧制过程不同类型晶粒的尺寸、形状与体积分数的定量描述,实现了轧制过程显微组织的在线重构(图2e~图2g).图3为高强度钢力学性能批量预测结果,由图可见,模型能够对产品力学性能实现在线预测.在时间维度上,通过高精度的力学性能预测,实现产品性能异常预判,并结合智能优化方法对工艺进行实时动态调整,提升产品性能稳定性.为了评价产品显微组织和力学性能沿卷长方向分布情况,在空间维度上,基于过程工艺曲线,实现沿长度方向的显微组织和力学性能连续计算,为评价板卷通长性能建立量化准则,如图4所示.



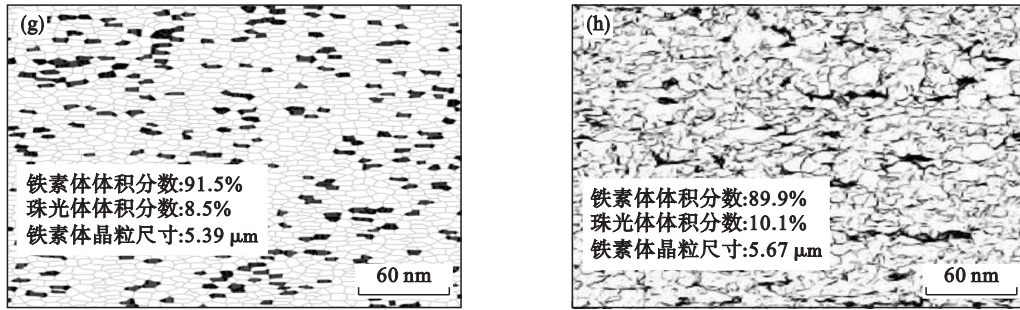


图2 S420MC热轧过程显微组织演变计算结果

Fig. 2 Calculation results of microstructure evolution during hot rolling process of S420MC
(a)—软化率; (b)—轧制力; (c)—氧化铁皮厚度; (d)—CCT曲线; (e)—奥氏体组织形态;
(f)—析出形貌; (g)—最终显微组织计算结果; (h)—最终显微组织实测结果.

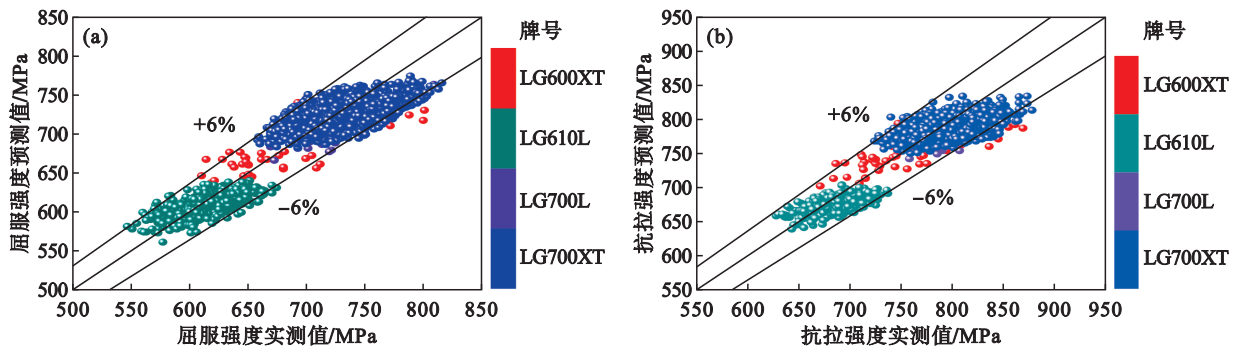


图3 高强度力学性能在线预测精度

Fig. 3 Online prediction accuracy of mechanical properties of high-strength steel

(a)—屈服强度; (b)—抗拉强度.

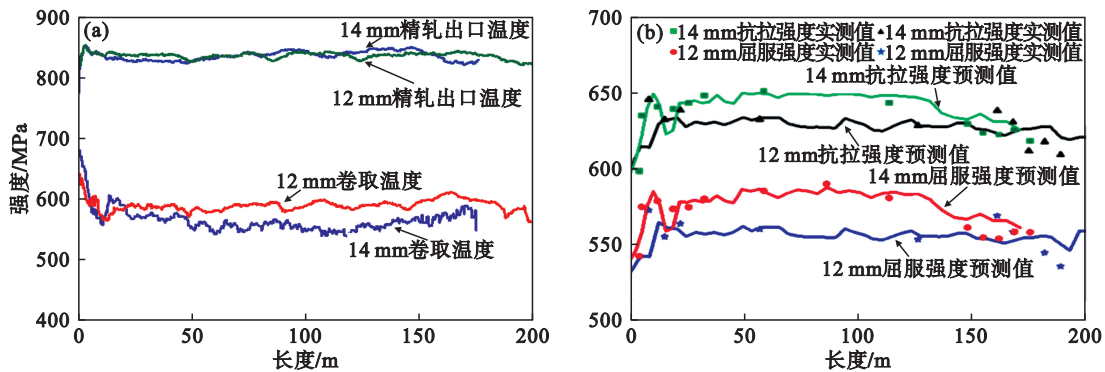


图4 Q460C沿长度方向工艺参数及力学性能

Fig. 4 Process parameters and mechanical properties of Q460C along length direction

(a)—终轧和卷取温度; (b)—力学性能预测值与实际值对比.

3.2 高强度成分合金减量化设计

在深海、地震及冻土等极端环境的重大工程中,高强度钢的力学性能直接决定了结构的可靠性与服役寿命.传统高强度钢生产依赖大量添加Cr, Ni, Cu等合金元素以调控贝氏体相变,从而提升强度与韧性.然而,这种以经验主导的成分设计模式耗时耗力,且难以精准平衡元素配比与工艺参数之间的关系,导致合金资源浪费.

为了解决这一问题, Cao等^[48]以X80M管线钢、550 MPa级桥梁钢及690 MPa级平台钢为对

象,通过分析现有合金成分对轧制过程显微组织的影响规律,研究轧制温度、冷却速率与相变产物的定量关系,开发了高强度钢组织性能预测模型,实现了合金成分的减量化设计,并逆向求解最优生产工艺.图5为高强度钢主要合金元素减量化的应用效果.针对X80M管线钢,传统成分体系需添加较高质量分数的Cr(0.25%), Ni(0.20%)和Cu(0.17%)以稳定贝氏体结构.通过模型分析可知,当冷却速率控制在25~35 °C/s范围内时,即使Cr和Ni的质量分数降低至0.2%和0.1%,仍可通

过适当降低加热温度和精轧温度细化奥氏体晶粒尺寸并提高位错密度,以在连续冷却过程中获得足够的针状铁素体和板条贝氏体,补偿合金元素降低导致的固溶强化贡献减小,并避免不利于韧性和变形性的粒状贝氏体生成.最终,Cr,Ni,Cu的添加量分别降低20%,50%和100%,降低了合金元素的同时,贝氏体相变产物的形态与含量

确保强度、韧性及延展性均达到标准要求.类似地,550 MPa级桥梁钢的Cr,Ni,Mo用量减少16%,100%和44%,690 MPa级海洋平台钢的Cu,Ni,Mo减量幅度达70%,64%和100%.这项研究打破了钢材成分设计中“高合金=高性能”的固有认知,为开发资源节约型高端钢材开辟了新方向.

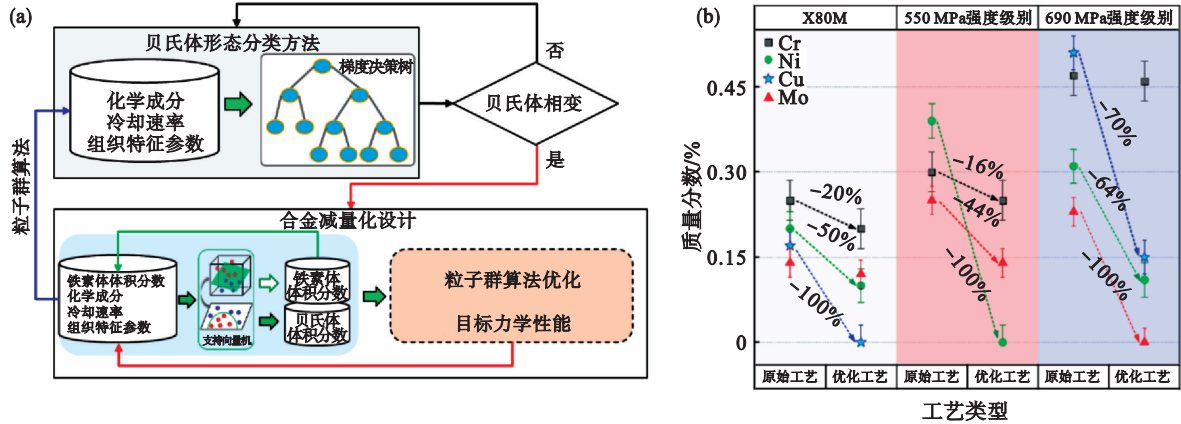


图 5 高强钢主要合金元素减量化的应用效果

Fig. 5 Application effect of reduction of main alloy elements in high-strength steel

(a)—合金元素减量化设计及工艺参数优化的集成模型架构; (b)—原始合金元素与机器学习模型优化后元素含量的对比.

3.3 高强船板钢高效轧制工艺设计

高强船板钢是船舶工业发展的重要基础,对保障国家海洋战略安全具有重要战略意义.其生产过程通常采用控制轧制工艺以保障强韧性,然而传统控制轧制会严重降低生产效率,影响生产节奏.例如,某单机架宽厚板生产线轧制高强船板钢的粗轧与精轧之间待温时间约4 min,成为提高生产效率的瓶颈.因此,如何快速设计最优工艺以提高生产效率,对企业降本增效具有重要的现实意义.

为此,以宽厚板热轧过程物理冶金原理为基础,融合人工智能方法建立宽厚板热轧工业模型.在此基础上,设计出将“高温出钢+控制轧制”调整为“低温出钢+不控轧”以缩短中间坯待温时间的工艺思路^[47].在加热阶段,通过将出钢温度由1 130 °C降低至1 050 °C,在保证充分奥氏体化的前提下实现低温出钢.在精轧阶段,通过适度提高精轧温度促使奥氏体发生再结晶细化晶粒,从而避免因部分再结晶造成的组织不均匀;同时结合轧后冷却路径优化设计,消除了钢板显微组织中的带状组织,提高了钢板力学性能均匀性.图6为高强船板钢工艺优化前后的温度场对比.由图可知,与原始工艺相比,所开发的高效轧制工艺在保证力学性能的前提下,每块钢减少轧制

时间约60 s.针对25 mm以下的船板钢,与采用控制轧制的船板钢相比,工艺优化后轧制效率由13.3块/h提升至15.3块/h,机时产量提高37 t,轧制效率提升15%.




图 6 高强船板钢工艺优化前后温度场对比 ($w(\text{C}): 0.17\%$; $w(\text{Si}): 0.28\%$; $w(\text{Mn}): 1.45\%$; 厚度: 20 mm)

Fig. 6 Comparison of temperature field before and after process optimization of high-strength ship plate steel ($w(\text{C}): 0.17\%$; $w(\text{Si}): 0.28\%$; $w(\text{Mn}): 1.45\%$; thickness: 20 mm)

4 结语与展望

目前,钢铁产品综合质量指标主要包括力学

性能、尺寸形状和表面质量等,通过融合物理冶金原理和工业数据分析,解耦热轧过程“组织演变-轧制载荷-界面状态”关系是实现破解“黑箱”的关键环节,也是实现显微组织定量描述的基础.本文介绍了钢材组织演变模型的研究进展,并重点阐述了人机混合驱动的热轧工业模型及其在组织演变及性能预测、高强钢合金减量化设计、高效轧制工艺设计中的典型应用.可以看出,人机混合智能驱动的热轧工艺设计将传统依赖于试错法进行材料研发的生产方式变革为理性设计过程,为钢材综合质量的提升提供了技术支撑.在未来的研究中,应进一步在丰富模型训练数据集、增大模型适用范围、开发适用于特殊钢的成分设计及工艺优化方法、引入模型可靠性评价等方向进行深入探索,提高模型的适用性,助力钢铁工业数字化转型.

参考文献:

- [1] 丁敬国,金利,孙丽荣,等.板带热轧过程智能化建模方法的研究现状与展望[J].冶金自动化,2022,46(6):25-37.
(Ding Jing-guo, Jin Li, Sun Li-rong, et al. Research status and prospect of intelligent modeling method for hot strip rolling process [J]. *Metallurgical Industry Automation*, 2022, 46(6): 25-37.)
- [2] 孙一康.带钢热连轧的模型与控制[M].北京:冶金工业出版社,2002.
(Sun Yi-kang. Model and control of hot strip rolling [M]. Beijing: Metallurgical Industry Press, 2002.)
- [3] 刘玠,孙一康.带钢热连轧计算机控制[M].北京:机械工业出版社,1997.
(Liu Jie, Sun Yi-kang. Computer control of hot strip rolling [M]. Beijing: China Machine Press, 1997.)
- [4] 刘振宇,曹光明,周晓光,等.组织性能预测技术及其在智能热轧中的核心作用[J].轧钢,2019,36(2):1-7.
(Liu Zhen-yu, Cao Guang-ming, Zhou Xiao-guang, et al. The predicting technologies for microstructure and properties and their core roles in smart hot rolling processes [J]. *Steel Rolling*, 2019, 36(2): 1-7.)
- [5] Ma L Q, Yuan X Q, Jiao S H, et al. Modeling of dynamic recrystallization and flow stress of Nb-bearing steels [J]. *Multidiscipline Modeling in Materials and Structures*, 2007, 3(1): 27-41.
- [6] Siciliano F J, Minami K, Maccagno T M, et al. Mathematical modeling of the mean flow stress, fractional softening and grain size during the hot strip rolling of C-Mn steels [J]. *ISIJ International*, 1996, 36(12): 1500-1506.
- [7] Martin H, Amoako-Yirenykyi P, Pohjonen A, et al. Statistical modeling for prediction of CCT diagrams of steels involving interaction of alloying elements [J]. *Metallurgical and Materials Transactions B*, 2021, 52(1): 223-235.
- [8] Van Bohemen S M C, Sietsma J. Modeling of isothermal bainite formation based on the nucleation kinetics [J]. *International Journal of Materials Research*, 2008, 99(7): 739-747.
- [9] Sellars C M, Whiteman J A. Recrystallization and grain growth in hot rolling [J]. *Metal Science*, 1979, 13(3/4): 187-194.
- [10] Sellars C M. The kinetics of softening processes during hot working of austenite [J]. *Czechoslovak Journal of Physics B*, 1985, 35(3): 239-248.
- [11] Wang L, Ji L K, Yang K, et al. The flow stress-strain and dynamic recrystallization kinetics behavior of high-grade pipeline steels [J]. *Materials*, 2022, 15(20): 7356.
- [12] Zurob H S, Hutchinson C R, Brechet Y, et al. Rationalization of the softening and recrystallization behaviour of microalloyed austenite using mechanism maps [J]. *Materials Science and Engineering: A*, 2004, 382(1/2): 64-81.
- [13] Zurob H S, Hutchinson C R, Brechet Y, et al. Modeling recrystallization of microalloyed austenite: effect of coupling recovery, precipitation and recrystallization [J]. *Acta Materialia*, 2002, 50(12): 3077-3094.
- [14] Collins J, Piemonte M, Taylor M, et al. A rapid, open-source CCT predictor for low-alloy steels, and its application to compositionally heterogeneous material [J]. *Metals*, 2023, 13(7): 1168.
- [15] Zhang S H, Deng L, Che L Z. An integrated model of rolling force for extra-thick plate by combining theoretical model and neural network model [J]. *Journal of Manufacturing Processes*, 2022, 75: 100-109.
- [16] Shen S H, Guye D, Ma X P, et al. Multistep networks for roll force prediction in hot strip rolling mill [J]. *Machine Learning with Applications*, 2022, 7: 100245.
- [17] 李元,刘文仲,孙一康.神经网络在热连轧精轧机组轧制力预报的应用[J].钢铁,1996(1):54-57,39.
(Li Yuan, Liu Wen-zhong, Sun Yi-kang. Application of neural network to predicting rolling force for the finisher [J]. *Iron and Steel*, 1996(1): 54-57, 39.)
- [18] Dong Z S, Li X, Luan F, et al. Fusion of theory and data-driven model in hot plate rolling: a case study of rolling force prediction [J]. *Expert Systems with Applications*, 2024, 245: 123047.
- [19] Wang Q N, Song L B, Zhao J W, et al. Application of the gradient boosting decision tree in the online prediction of rolling force in hot rolling [J]. *The International Journal of Advanced Manufacturing Technology*, 2023, 125(1/2): 387-397.
- [20] Rahaman M, Mu W Z, Odqvist J, et al. Machine learning to predict the martensite start temperature in steels [J]. *Metallurgical and Materials Transactions A*, 2019, 50(5): 2081-2091.
- [21] Pattanayak S, Dey S, Chatterjee S, et al. Computational intelligence based designing of microalloyed pipeline steel [J]. *Computational Materials Science*, 2015, 104: 60-68.
- [22] Hu X B, Li H, Liu C, et al. Multi-objective design of Ni-B-Al master alloy by adaptive machine learning-driven aluminothermic reduction experiment [J]. *Journal of Alloys and Compounds*, 2025, 1010: 177403.
- [23] Conrad F, Stöcker J P, Signorini C, et al. Exploring design space: machine learning for multi-objective materials design optimization with enhanced evaluation strategies [J]. *Computational Materials Science*, 2025, 246: 113432.
- [24] Wu S W, Zhou X G, Ren J K, et al. Optimal design of hot rolling process for C-Mn steel by combining industrial data-driven model and multi-objective optimization algorithm [J]. *Journal of Iron and Steel Research International*, 2018, 25(7): 700-705.
- [25] Pan G F, Wang F Y, Shang C L, 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.
- [26] Wang X J, Li X, Yuan H, et al. Prediction and analysis of mechanical properties of hot-rolled strip steel based on an interpretable machine learning [J]. *Materials Today Communications*, 2024, 40: 109997.
- [27] Song K, Yan F, Ding T, et al. A steel property optimization model based on the XGBoost algorithm and improved PSO [J]. *Computational Materials Science*, 2020, 174: 109472.
- [28] Diao Y P, Yan L C, Gao K W. A strategy assisted machine learning to process multi-objective optimization for improving mechanical properties of carbon steels [J]. *Journal of Materials Science & Technology*, 2022, 109: 86-93.
- [29] Jiang X, Jia B R, Zhang G F, et al. A strategy combining machine learning and multiscale calculation to predict tensile strength for pearlitic steel wires with industrial data [J]. *Scripta Materialia*, 2020, 186: 272-277.
- [30] Li H W, Li Y, Huang J, et al. Physical metallurgy guided industrial big data analysis system with data classification and property prediction [J]. *Steel Research International*, 2022, 93(8): 2100820.
- [31] 任鹏帆, 王振华, 贾焱, 等. 机理和数据融合的304不锈钢极薄带轧制力模型[J]. 钢铁, 2024, 59(10): 64-76. (Ren Peng-fan, Wang Zhen-hua, Jia Yi, et al. Rolling force model for 304 stainless steel ultra-thin strip based on mechanism and data fusion [J]. *Iron & Steel*, 2024, 59(10): 64-76.)
- [32] 李鑫, 周晓光, 曹光明, 等. 融合物理冶金学与机器学习的组织性能预测及热轧工艺优化[J]. 冶金自动化, 2023, 47(2): 16-26. (Li Xin, Zhou Xiao-guang, Cao Guang-ming, et al. Microstructure and properties prediction and optimization of hot rolling process based on physical metallurgy and machine learning [J]. *Metallurgical Industry Automation*, 2023, 47(2): 16-26.)
- [33] 吴思炜. 基于工业大数据的热轧带钢组织性能预测与优化技术研究[D]. 沈阳: 东北大学, 2018. (Wu Si-wei. Research on microstructure and property prediction and optimization technology of hot rolled strips based on industrial big data [D]. Shenyang: Northeastern University, 2018.)
- [34] Li X, Zhou X G, Cao G M, et al. Machine learning hot deformation behavior of Nb micro-alloyed steels and its extrapolation to dynamic recrystallization kinetics [J]. *Metallurgical and Materials Transactions A*, 2021, 52(7): 3171-3181.
- [35] Jiang L, Fu H D, Zhang H T, et al. Physical mechanism interpretation of polycrystalline metals' yield strength via a data-driven method: a novel Hall-Petch relationship [J]. *Acta Materialia*, 2022, 231: 117868.
- [36] Zhang X C, Gong J G, Xuan F Z. A physics-informed neural network for creep-fatigue life prediction of components at elevated temperatures [J]. *Engineering Fracture Mechanics*, 2021, 258: 108130.
- [37] 王毅, 李高楠, 刘哲, 等. 材料基因工程与智能科学: AI+时代无尽前沿[J]. 科技导报, 2025, 43(12): 93-109. (Wang Yi, Li Gao-nan, Liu Zhe, et al. Materials genome engineering and intelligent science: the endless frontier in AI+ era [J]. *Science & Technology Review*, 2025, 43(12): 93-109.)
- [38] Li Y F, Wang Z H, Zhang L Y, et al. Arrhenius-type constitutive model and dynamic recrystallization behavior of V-5Cr-5Ti alloy during hot compression [J]. *Transactions of Nonferrous Metals Society of China*, 2015, 25(6): 1889-1900.
- [39] Maccagno T M, Jonas J J, Hodgson P D. Spreadsheet modelling of grain size evolution during rod rolling [J]. *ISIJ International*, 1996, 36(6): 720-728.
- [40] Gao Z W, Wu S W, Li X, et al. Modelling strain-induced precipitation kinetics of Nb (C, N) by symbolic regression machine learning [J]. *Journal of Materials Research and Technology*, 2025, 35: 1712-1721.
- [41] Cui C Y, Wang H, Gao X Y, et al. Machine learning model for thickness evolution of oxide scale during hot strip rolling of steels [J]. *Metallurgical and Materials Transactions A*, 2021, 52(9): 4112-4124.
- [42] Cao Y, Cao G M, Cui C Y, et al. Modeling continuous cooling transformations for HSLA steels with physical metallurgy guided hereditary machine learning [J]. *Metallurgical and Materials Transactions A*, 2023, 54(12): 4891-4904.
- [43] Cao Y, Wu S W, Tang S, et al. Dynamic deep learning to predict mechanical properties of high-strength low-alloy steels [J]. *Metallurgical and Materials Transactions A*, 2025, 56(1): 168-179.
- [44] Choudhary A, Kumar M, Unune D R. Experimental investigation and optimization of weld bead characteristics during submerged arc welding of AISI 1023 steel [J]. *Defence Technology*, 2019, 15(1): 72-82.
- [45] Rao V D P, Ali S R S M, Ali S M Z M S, et al. Multi-objective optimization of cutting parameters in CNC turning of stainless steel 304 with TiAlN nano coated tool [J]. *Materials Today: Proceedings*, 2018, 5(12): 25789-25797.
- [46] Wu S W, Cao G M, Zhou X G, et al. High dimensional data-driven optimal design for hot strip rolling of C-Mn steels [J]. *ISIJ International*, 2017, 57(7): 1213-1220.
- [47] 崔春圆. 热轧板带材集成机器学习模型开发与应用[D]. 沈阳: 东北大学, 2023. (Cui Chun-yuan. The development and application of integrated machine learning models for hot rolled plate and strip [D]. Shenyang: Northeastern University, 2023.)
- [48] Cao Y, Zhang C D, Tang S, et al. Machine learning to predict phase transformation products and their morphologies-application in design of lean high strength steel [J]. *Materials & Design*, 2025, 258: 114642.