

· XXXX ·



基于智能增强的轧后水冷模型研究与应用

杨东峰, 沈 斌, 王孝敏, 张 侃
(江阴兴澄特种钢铁有限公司厚板分厂, 江阴 214400)

摘 要: 轧后冷却控制是热轧钢材组织性能调控的关键环节, 其传统物理模型和数据驱动模型受限于机理假设简化、学习效率低、参数难以动态适配等问题, 无法精准应对轧制工况时变的复杂场景。提出一种基于智能增强(Intelligent Augmentation, IA)的轧后水冷控制模型, 实现算法与经验的深度融合, 其核心原理为“机理约束+数据校正+动态反馈”。生产实践表明, 该模型有效解决了传统模型鲁棒性差、学习慢的问题, 冷却误差控制在 $\pm 20^{\circ}\text{C}$ 以内, 学习调整速率相比传统模型提升30%以上, 为提升热轧钢材产品质量、推动钢铁工业智能化升级具有重要意义。

关键词: 轧后控冷; 智能增强; 机理约束; 数据校正; 动态反馈

DOI:10. 20057/j. 1003-8620. N260079 **中图分类号:** TG111. 5

Research and Application of an Intelligently Enhanced Post-Rolling Water Cooling Model

Yang Dongfeng, Shen Bin, Wang Xiaomin, Zhang Kan
(Heavy Plate Plant of Jiangyin Xingcheng Special Steel Co., Ltd., Jiangyin 214400, China)

Abstract : Post-rolling cooling control is a critical step in regulating the microstructure and properties of hot-rolled steel. Traditional physical models and data-driven models, constrained by simplified mechanistic assumptions, low learning efficiency, and difficulties in dynamic parameter adaptation, fail to accurately address the complex, time-varying conditions during rolling processes. Propose a post-rolling cooling control model based on Intelligent Augmentation (IA), achieving deep integration of algorithmic and empirical knowledge. Its core principle combines "mechanistic constraints, data correction, and dynamic feedback." Practical applications demonstrate that this model effectively overcomes the limitations of traditional models—poor robustness and slow learning—with cooling control errors maintained within $\pm 20^{\circ}\text{C}$ and a learning adjustment rate over 30% faster than conventional approaches. This advancement holds significant importance for improving the quality of hot-rolled steel products and advancing the intelligent transformation of the steel industry.

Key Words : Post-rolling Cooling Control; Intelligent Augmentation; Mechanism Constraint; Data Correction; Dynamic Feedback

热轧钢材是现代工业生产中应用最广泛的基础材料之一, 其组织性能直接决定了下游产品的使用可靠性、服役寿命与安全性能^[1]。轧后水冷是热轧生产流程中的关键环节, 也是调控钢材组织性能的核心手段^[2]。随着高端产品的市场需求日益增长, 对轧后冷却控制的精度、响应速度及鲁棒性提出了更高要求^[3]。当前, 轧后冷却控制模型主要分为两大类: 传统物理模型与数据驱动模型, 但两类模型均存在明显局限性, 难以满足复杂工况下的精准控制需求^[4-6]。

为此, 部分学者尝试将物理模型与数据驱动模型结合, 构建混合控制模型, 利用物理模型的机理约束保证模型的可靠性, 借助数据驱动模型的自适

应能力提升模型的适配性^[7-8]。张田等^[9]提出基于物理模型与深度学习耦合的轧后冷却控制模型, 通过物理模型提供初始参数, 利用神经网络修正模型误差, 但该模型缺乏动态反馈机制, 无法实现参数的实时调整; 居龙等^[10]采用遗传算法/随机森林优化物理模型参数, 提升了模型精度, 但模型学习效率较低, 且未整合专家经验, 在极端工况下的适配能力不足。

智能增强(Intelligent Augmentation, IA)技术作为一种融合机理建模、数据驱动与人机协同的新型智能化方法, 近年来在工业过程控制领域得到广泛关注^[11-12]。其核心逻辑是“机理约束定框架、数据校正补精度、动态反馈促优化”^[13]。基于此, 本文提出

基金项目: 国家重点研发计划(2023YFB3709903、2023YFB3709904)

作者简介: 杨东峰(1984—), 男, 本科, 高级工程师; **E-mail:** yangdongfeng@citicsteel.com; **收稿日期:** 2026-05-27

Editorial Office of Special Steel. OA under CC BY-NC-ND 4.0

一种基于智能增强的轧后水冷模型,解决传统模型鲁棒性差、学习慢,以及数据驱动模型受数据质量影响大、极端工况适配能力不足的问题。

1 智能增强核心理论

智能增强(IA)技术的核心思想是“机理赋能+数据增值+经验补位”,其核心理论基础包括机理约束理论、数据驱动理论与人机协同理论,三者相互支撑、有机融合,构成智能增强模型的核心框架^[14-15],图1为IA冷却控制策略图。

机理约束理论是智能增强模型的基础,其核心是利用物理、化学、材料科学等基础理论构建模型的核心框架,明确过程的约束关系与影响因子,确保模型的可靠性与可解释性,避免数据驱动算法脱离实际工业场景,出现不合理的预测结果^[16]。

数据驱动理论是智能增强模型的核心支撑,通过机器学习、深度学习等算法挖掘工业数据中的非线性关联,弥补传统机理模型因简化假设导致的精度缺陷^[17]。

人机协同理论是智能增强模型的重要补充,通过整合领域专家的经验知识,构建动态反馈机制,解决数据驱动模型在极端工况、数据质量不佳场景下的局限性^[18]。

2 基于智能增强的轧后冷却控制模型构建

本文提出的基于智能增强的轧后冷却控制模型,以“机理约束+数据校正+动态反馈”为核心原理,构建“基础物理模型+改进神经网络模型+专家经验动态调整机制”的三层架构,如图2所示。实现物理机理、数据算法与专家经验的深度融合,解决传统模型与单一数据驱动模型的固有缺陷,提升轧

后冷却控制的精度、效率与鲁棒性。

2.1 数据预处理

数据预处理核心流程包括异常值剔除、标准化处理、数据插值、数据冗余剔除四个步骤:

异常值剔除:采用 3σ 准则剔除异常数据,避免极端值(如传感器故障导致的异常数据、人为记录错误)影响模型精度,如式(1)。

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i, \sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2} \quad (1)$$

式中, $X = \{x_1|x_2|\dots|x_n\}$ 为数据样本集, μ 为样本均值和 σ 为标准差,满足 $|x_i - \mu| > 3\sigma$ 的数据视为异常值并剔除,确保数据的合理性。

标准化处理:采用Z-score标准化法统一数据量纲,消除不同变量量级差异(如碳的质量分数为%、温度为℃、流量为 m^3/h)对模型的影响,使所有数据处于同一量级,加快神经网络的收敛速度,如式(2)。

$$x^* = \frac{x - \mu}{\sigma} \quad (2)$$

式中, x^* 为标准化后的数据, x 为原始数据, μ 为样本均值, σ 为样本标准差。标准化后的数据均值为0、标准差为1,避免了量级差异导致的权重分配不均问题。

数据插值:针对数据集中的缺失值(主要由传感器故障、数据传输中断导致),采用线性插值法补充,确保数据样本的完整性,保障模型训练的有效性。对于存在缺失值的样本 $(x_i|y_i)$,若其相邻样本为 $(x_{i-1}|y_{i-1})$ 和 $(x_{i+1}|y_{i+1})$,则缺失值 y_i 的计算公式如式(3)。

$$y_i = y_{i-1} + \frac{(x_i - x_{i-1})(y_{i+1} - y_{i-1})}{x_{i+1} - x_{i-1}} \quad (3)$$




图1 IA冷却控制策略图

Fig. 1 Diagram of IA cooling control strategy




图2 模型整体架构示意图

Fig. 2 Schematic diagram of the overall model architecture

数据冗余剔除:采用皮尔逊相关系数分析各输入参数之间的相关性,剔除冗余数据,减少模型计算量,提升模型训练效率。例如,皮尔逊相关系数 r 计算公式如式(4),当 $|r| > 0.8$ 时,认为两个参数高度相关,剔除其中一个对模型影响较小的参数。

$$r = \frac{\sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y)}{\sqrt{\sum_{i=1}^n (x_i - \mu_x)^2} \sqrt{\sum_{i=1}^n (y_i - \mu_y)^2}} \quad (4)$$

2.2 基础物理模型构建

结合轧后冷却过程的实际工况,对钢材进行合理简化:将轧后钢材视为二维切面(仅考虑厚度与宽度方向),冷却介质为水。基于热平衡方程,结合傅里叶传热定律,构建轧后冷却温度场的基础物理模型,其核心方程如式(5)。

$$\rho c \frac{\partial T}{\partial t} = \lambda \left(\frac{\partial^2 T}{\partial x^2} + \frac{\partial^2 T}{\partial y^2} \right) + Q \quad (5)$$

式中, x, y 分别为钢材厚度和宽度方向节点坐标, m , 根据该产线实际轧后规格确定;确定基础参数取值: $\rho = 7850 \text{ kg/m}^3$, $c = 455 \sim 480 \text{ J/(kg} \cdot ^\circ\text{C)}$, $\lambda = 40 \sim 55 \text{ W/(m} \cdot ^\circ\text{C)}$ 。

相变潜热 Q 采用等效比热容法处理,将相变潜热融入比热容中,避免单独计算相变潜热带来的复杂度,简化模型求解过程,等效比热容计算公式如式(6)。

$$c_{eq} = c + \frac{Q}{T_{s,end} - T_{s,start}} \quad (6)$$

式中, c_{eq} 为等效比热容, $\text{J/(kg} \cdot ^\circ\text{C)}$; $T_{s,start}$ 、 $T_{s,end}$ 分别为相变开始与结束温度, $^\circ\text{C}$, 初始取值分别为 750 、 650 $^\circ\text{C}$, 后续由智能增强模块动态校正。

2.3 改进神经网络算法

传统神经网络难以满足轧后冷却过程实时控

制的需求^[19],因此需要对其进行改进。本文考虑在损失函数中引入惩罚项并嵌入自适应权重系数,充分考虑专家经验,实现对训练误差的差异化惩罚与动态调控。动态损失函数的具体如式(7)、式(8)。

$$L_{dynamic} = L_{base} - P \quad (7)$$

$$P = \omega(y_i - y_i^{min}) + (1 - \omega)(y_i - y_i^{max}) \quad (8)$$

式中, $L_{dynamic}$ 为改进后的动态损失函数值; L_{base} 为基础损失项,采用均方误差(MSE),即 $L_{base} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$, n 为训练样本数量, y_i 为第 i 个样本的真实值, $\hat{y}_i$ 为模型预测值; P 为误差惩罚项, ω 为自适应权重系数, y_i^{min} 和 y_i^{max} 为反传热模型计算得出。

2.4 专家经验驱动的动态调整机制

专家经验驱动的动态调整机制是智能增强模块的核心策略,遵循“经验量化+工况判断+参数反馈+在线自学习”的核心逻辑,如图3所示。解决数据驱动模型在极端工况、异常场景下的局限性,实现模型参数与控制策略的动态优化,进一步提升模型的工业适用性。

2.4.1 专家经验规则化

通过与轧后冷却领域一线专家、工艺人员的深




图3 专家经验驱动的动态调整机制流程图

Fig. 3 Flowchart of the expert-driven dynamic adjustment mechanism

度交流,总结出不同钢种、不同工况下的冷却控制经验,包括正常工况参数阈值、异常工况判断规则、关键参数调整策略等,将定性经验转化为可量化的模型计算规则与阈值,为动态调整机制提供基础。

1) 工况判断阈值:针对终轧温度偏差、水量波动、钢材成分偏差等关键指标,设定量化阈值。例如,温度允许偏差范围为 $\pm 15^{\circ}\text{C}$,当偏差 $|\Delta T| > 15^{\circ}\text{C}$ 时需要调整冷却工艺;钢材碳含量偏差 $|\Delta C| > 0.02\%$ 时,需调整冷却强度。

2) 参数调整规则:将专家经验转化为参数调整系数,例如:温度每偏高 10°C ,换热系数校正系数 $k_h = 1.05$,以提高冷却强度。

3) 异常工况处理策略:针对冷却水压骤降、集管不出水等异常工况,制定量化处理流程。例如:某组集管不出水,将水量分配到其他集管,保证总冷却能力。

2.4.2 动态调整核心流程

动态调整机制基于实时工况监测-经验规则匹配-参数反馈优化-模型自学习的闭环流程,与智能增强模块形成双向交互,具体流程如下:

1) 实时工况监测

通过轧后冷却过程中的传感器网络,实时采集关键监测数据,包括终轧温度 T_r 、冷却水量 W 、钢材表面温度 T_s 、碳含量 C 等。将监测数据与预设阈值对比,判断当前工况状态,分为正常工况和异常工况。

2) 经验规则匹配

当监测到工况变化时,调用专家经验量化规则库,匹配对应的调整策略,如2.4.1所示。

3) 参数反馈与优化

将匹配得到的策略,通过物理模型得到关键模型参数(换热系数等),对改进神经网络的损失函数

进行模型训练。

4) 在线网络更新

动态调整机制将异常工况下的实时数据、调整策略及最终控制效果,作为新的训练样本补充至数据库中,同步网络权重完成下次模型迭代,实现模型的在线自学习。

3 现场应用

结合东北大学先进的辊压约束式超快冷,在江阴兴澄特种钢铁有限公司厚板分厂4 300 mm产线成功应用,具体设备工艺参数见表1。该产线生产的钢板品种主要包括:管线钢板、普通/高强船板、海洋平台钢板等。

针对中厚板轧后控制冷却系统,引入智能增强模型前,传统机理模型(老模型)自动投用率34%,返红温度($\pm 20^{\circ}\text{C}$)命中率67%,现场人工干预量大,命中率一般。新模型投用后,构建算法机理与现场工艺经验深度融合的建模框架,将数据驱动建模方法与老模型有机结合。基于实际生产数据统计,系统投运1个月内,控冷工艺自动投入率与返红温度命中率均实现大幅提升,其中控冷自动投入率达94%,返红温度($\pm 20^{\circ}\text{C}$)命中率稳定至97%,应用效果如图4所示。

统计100次换规格后,控冷返红温度至 $\pm 20^{\circ}\text{C}$ 以内所需的学习钢板块数,如图5所示,换规格后平均学习2.09块即可稳定控温至 $\pm 20^{\circ}\text{C}$ 以内,相比常规3块以上的学习块数,自学习率提高约30.3%。

4 结论

构建了基于智能增强的轧后冷却控制模型,以机理约束、数据校正与动态反馈为核心,融合物理模型、改进的神经网络模型与现场专家经验,实现多钢种、多规格板材冷却过程的精准建模与快速自适应优化。工业应用结果表明,模型投运后控冷自

表1 辊压约束形式超快冷主要参数

Table 1 Main parameters of ultra-fast cooling with roller pressure constraint

设备名称	工艺技术参数	设备名称	工艺技术参数
冷却区长度/m	30.4	冷却区宽度/mm	4300
钢板厚度/mm	8 ~ 300	钢板宽度/mm	900 ~ 4100
DQ段集管组数	17组高密集管	ACC段集管组数	23组高密集管
DQ段压力/MPa	0.5 / 0.2	ACC段压力/MPa	0.2
DQ段瞬时最大水量/($\text{m}^3 \cdot \text{h}^{-1}$)	12000	ACC段瞬时最大水量/($\text{m}^3 \cdot \text{h}^{-1}$)	6000
DQ段框架形式	伺服液压形式	ACC段框架形式	固定形式
冷却工艺	通过式、摆动式	横向控制方式	水凸度
封水形式	气吹、侧喷、中喷	冷速范围/($^{\circ}\text{C} \cdot \text{s}^{-1}$)	5 ~ 100




图4 自动投用率及温度命中率统计

Fig. 4 Statistics on automatic activation rate and temperature attainment rate

动投入率达 94%, $\pm 20^{\circ}\text{C}$ 范围内返红温度命中率提升至 97%, 自学习调整速率较传统模型提升 30% 以




图5 换规格控冷自学习效率统计

Fig. 5 Statistical analysis of self-learning efficiency for specification-switching controlled cooling

上。该方法有效弥补了传统控冷模型的短板, 为中厚板轧后冷却智能化精准控制提供可靠理论依据与工程应用参考。

参考文献

- [1] 沙孝春, 兰勇军, 李殿中, 等. 带钢热轧组织性能预测与控制技术应用与发展[J]. 轧钢, 2003, 20(3): 23-26.
- [2] 卢永康, 赵宪明, 吴保桥, 等. 轧后控冷对重型H型钢组织和性能的影响[J]. 热加工工艺, 2023, 52(13): 85-88+92.
- [3] 王志军. 中厚板轧后控制冷却控制系统研究[D]. 武汉: 武汉科技大学, 2010.
- [4] 彭良贵, 刘相华, 王国栋. 超快冷却条件下温度场数值模拟[J]. 东北大学学报, 2004, (4): 360-362.
- [5] 王海玉, 方 坤, 董立杰, 等. 机理和数据融合的热轧带钢终轧温度预测模型[J]. 轧钢, 2026, 43(1): 7-13+30.
- [6] Zhao J, Chen S F, Liu X J, et al. Outlier screening for ironmaking data on blast furnaces[J]. International Journal of Minerals, Metallurgy and Materials, 2021, 28(6): 1001-1010.
- [7] 片锦香, 柴天佑, 李界家. 案例推理及迭代学习在层流冷却控制中的应用[J]. 自动化学报, 2012, 38(12): 2032-2037.
- [8] 彭良贵, 王登刚, 李 杰, 等. 数据驱动的卷取温度模型参数即时自适应设定算法[J]. 工程科学学报, 2020, 42(6): 778-786.
- [9] 张 田, 张子豪, 田 勇, 等. 深度学习在中厚板轧后超快速冷却系统中的研究与应用[J]. 东北大学学报(自然科学版), 2019, 40(5): 635-640.
- [10] 居 龙, 李洪波, 张 杰, 等. 基于多目标遗传算法的工作辊温度场计算与分析[J]. 北京科技大学学报, 2014, 36(9): 1255-1259.
- [11] Engelbart D C. Augmenting human intellect: A conceptual framework (1962) [M]. Ideas That Created the Future. Cambridge, MA, USA: The MIT Press, 2021: 225-236.
- [12] 王国栋. 数字钢铁全国重点实验室在“AI+轧钢”领域的应用探索[J]. 轧钢, 2026, 43(1): 1-6.
- [13] Hewing L, Wabersich K P, Menner M, et al. Learning-based model predictive control: Toward safe learning in control[J]. Annual Review of Control, Robotics, and Autonomous Systems, 2020, 3: 269-296.
- [14] [美] 布雷特·金. 刘林德, 冯斌等译. 智能浪潮: 增强时代来临 [M]. 北京: 中信出版社, 2017. 12-26
- [15] 张 田. 基于超快冷的中厚板温控形变耦合工艺及控冷模型的研究与工业应用[D]. 沈阳: 东北大学, 2017.
- [16] 崔晨耕. 神经网络算法与机理模型融合的冷连轧轧制力智能预报模型[J]. 计算机与现代化, 2019(8): 74-78+91.
- [17] Zheng J H, Yang Z Y, Ge Z Q. Deep extraction and augmentation of non-Gaussian data features for multimode industrial process monitoring[J]. Chemical Engineering Science, 2025, 311: 121652.
- [18] Nguyen H T, Haugen Ø, Johnsen E B. Augmentor: A cognitive-inspired approach for context-aware adaptive learning with human guidance[J]. Journal of Intelligent Manufacturing, 2025: 1-22.
- [19] 邱碧涛, 但斌斌, 肖 涵, 等. 基于BP神经网络的轧机刚度预测模型[J]. 轧钢, 2024, 41(2): 120-125.