

DOI:10.16410/j.issn1000-8365.2025.5127

基于改进型随机森林算法的 转炉终点成分实时预测模型开发

刘晓航^{1,2}, 潘佳^{1,3}, 刘畅^{1,2}, 贺铸^{1,2}, 李光强^{1,2}, 王强^{1,2}(1. 武汉科技大学 省部共建耐火材料与冶金国家重点实验室 湖北 武汉 430081 2. 武汉科技大学 钢铁冶金及资源利用
省部共建教育部重点实验室 湖北 武汉 430081 3. 阳春新钢铁有限责任公司炼钢厂 广东 阳江 529600)

摘要:在转炉炼钢过程中,钢液成分的准确判定是出钢的关键环节。目前主要是依靠生产经验判断是否到达冶炼终点,同时对钢液取样分析。这种方式不仅限制了生产效率,还受到了工人经验的影响。为减少人为经验的影响,提出了一种基于灰狼优化算法和重要特征改进的随机森林模型。以某钢厂 120 t 转炉为研究对象,选取铁液质量、废钢比例、吹炼时间、铁液中 Si、Mn、P 含量、铁液温度、转炉操作参数以及氧气、氩气、氮气消耗量等多维特征作为输入变量,实现了对终点钢液中 C、Si、Mn、P、S 等元素含量的实时预测。基于 1 783 组实际工艺数据对模型进行了训练与动态修正,通过超参数调优将预测时间缩短至 0.1~0.3 s,预测准确率超过了 90%。模型在提升泛化能力与预测稳定性的同时,实现了钢液成分的快速预报,有效降低了人为干预对终点判断的影响。

关键词:转炉炼钢;终点成分预测;随机森林;机器学习;智慧冶金

中图分类号:TF713

文献标识码:A

文章编号:1000-8365(2025)10-0954-10

Development of a Real-time Endpoint Composition Prediction Model for BOF Steelmaking Based on an Improved Random Forest Algorithm

LIU Xiaohang^{1,2}, PAN Jia^{1,3}, LIU Chang^{1,2}, HE Zhu^{1,2}, LI Guangqiang^{1,2}, WANG Qiang^{1,2}

(1. The State Key Laboratory of Refractories and Metallurgy, Wuhan University of Science and Technology, Wuhan 430081, China; 2. Key Laboratory for Ferrous Metallurgy and Resource Utilization of Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081, China; 3. Yangchun Xin Iron & Steel Co., Ltd. Steelmaking Plant, Yangjiang 529600, China)

Abstract: In the basic oxygen furnace (BOF) steelmaking process, accurate determination of the molten steel composition is a critical step in determining the tapping point. Currently, this decision relies primarily on operator experience, supplemented by manual sampling and laboratory analysis. However, such an approach not only limits production efficiency but is also subject to human error. To reduce the influence of subjective judgment, an improved random forest (RF) model optimized by the grey wolf optimization (GWO) algorithm was proposed. Using a 120-ton converter at a steel plant as the research object, multiple process parameters were selected as input features, including the hot metal weight, scrap ratio, blowing time, Si, Mn and P contents of the hot metal, hot metal temperature, the converter operation parameters, and the consumption of oxygen, argon, and nitrogen. The model enables real-time prediction of the endpoint concentrations of C, Si, Mn, P and S in molten steel. The model was trained and dynamically updated via 1 783 sets of actual industrial data. Through hyperparameter tuning, the prediction time is reduced to 0.1~0.3 s, with a prediction accuracy exceeding 90%. While improving generalizability and stability, the model achieves fast and reliable prediction of steel composition and significantly reduces dependence on manual decision-making.

Key words: basic oxygen furnace steelmaking; endpoint composition prediction; random forest; machine learning; intelligent metallurgy

收稿日期:2025-06-27

基金项目:国家自然科学基金重点资助项目(U22A20173)

作者简介:刘晓航,1998年生,博士生.研究方向为冶金工艺流程智能制造. Email: liuxiaohang@wust.edu.cn

通信作者:王强,1989年生,博士,教授.研究方向为发展金属材料绿色智能制备工艺. Email: wangqiangwust@wust.edu.cn

引用格式:刘晓航,潘佳,刘畅,贺铸,李光强,王强.基于改进型随机森林算法的转炉终点成分实时预测模型开发[J].铸造技术,2025,46(10):954-963.

LIU X H, PAN J, LIU C, HE Z, LI G Q, WANG Q. Development of a real-time endpoint composition prediction model for BOF steelmaking based on an improved random forest algorithm[J]. Foundry Technology, 2025, 46(10): 954-963.

转炉炼钢过程中,终点控制对钢液成分的精准调控、钢材质量的稳定性及整体生产效率具有关键作用^[1-2]。当前钢铁行业普遍依赖人工判定冶炼终点,并通过钢液取样结合直读光谱仪进行成分测定^[3-4]。流程涉及取样、送检与分析等多个环节,不仅延长了冶炼周期,也限制了生产效率的提升。实际生产中,由于原料成分波动及炉内复杂的物理化学反应耦合作用,熔池状态高度不稳定,单凭操作人员经验判断吹炼终点,难以实现成分的一次命中^[5-7]。一旦终点成分偏离目标,需返炉进行二次吹炼,不仅延长了冶炼时间、增加能耗与操作复杂度,还会导致合金元素进一步烧损、温度损失加剧及冶炼成本上升^[8-9]。因此,开发精准、高效、具备实时响应能力的转炉终点智能预测方法,不仅有助于提高成分命中率、减少返工次数、优化能耗控制,还能有效提升钢液质量稳定性、降低生产成本,对推动转炉炼钢向高质量、高效率与智能化方向发展具有重要意义^[10]。

为减少人为经验对转炉终点判断带来的不确定性,国内外学者逐步引入机器学习方法,对大量历史冶炼数据进行处理与挖掘^[11-14],以提取有效信息并构建钢液成分预测模型。研究表明,工艺参数如吹氧量、温度控制等对出钢过程有显著影响^[15],有学者据此提出了改进的高碳出钢方案,实现了高效、稳定的高碳钢生产。基于150 t转炉的1900炉次历史数据,有研究建立了完整数据库并采用轻量级梯度提升机(light gradient boosting machine, LightGBM)算法对转炉热损失率进行建模预测^[16],其决定系数 R^2 达0.93,热损失率在 ± 0.005 与 ± 0.01 的误差范围内预测准确率分别超过90%。在转炉终点成分预测方面,学者应用支持向量机(support vector machine, SVM)、LightGBM和梯度提升决策树(categorical boosting, CatBoost)模型对残余锰含量进行预测,并通过贝叶斯优化算法提升模型性能^[17],其中优化后的CatBoost模型在 ± 0.010 与 ± 0.008 范围内的命中率分别达到了83.2%和76.2%。另一项研究基于粒子群算法(particle swarm optimization, PSO)优化SVM模型,实现了转炉用氧量的高精度预测^[18],在预测误差小于100和200 m³的条件下,命中率分别达到了60%和80%,对提高一倒命中率和钢液质量具有实际指导意义。

针对钢液温度与成分的预测,已有研究结合主成分分析(principal component analysis, PCA)与BP神经网络(back propagation neural network, BPNN),显著提升了终点温度预测的精度与稳定性^[19]。尽管该模型相较于传统方法具备更强的拟合能力,但尚

未充分考虑炼钢过程中动态工况变化对预测性能的影响,且缺乏与其他先进算法的系统对比。为增强模型对动态过程的适应性,有研究引入多尺度特征提取与自注意力机制,提高了数据建模的准确性^[20],但该方法在不同数据源间的泛化能力及实时性能仍需进一步验证。此外,深度神经网络(deep neural network, DNN)在BOF吹氧时间预测中的应用也取得初步成效,结合氧平衡机制开发的混合模型显著提高了预测准确性^[21],展示了冶金知识与数据驱动方法融合的潜力。然而,该模型对输入数据质量要求较高,其在复杂工况下的鲁棒性和泛化能力仍需增强。数字孪生技术也逐步被引入炼钢过程建模与优化中^[22],通过构建虚拟工艺模型与实际生产数据的同步交互,实现了动态调整与智能决策支持,但其广泛应用仍受限于高质量数据采集系统和建模成本。卷积递归神经网络(convolutional recurrent neural network, CRNN)被用于转炉工况识别^[23],充分结合了CRNN的空间特征提取与循环神经网络(recurrent neural network, RNN)的时序建模能力,提升了过程状态识别的准确性和实时性。不过,该方法对大规模标注数据依赖较强,且对计算资源要求较高。有研究综合原始静态工艺数据与转换后的时间序列数据,建立了基于工艺参数的终点成分(C、P)与温度预测模型^[24],揭示了氧气流动模式、石灰石与白云石的添加方式对终点磷含量的主导影响因素。但该研究对高质量输入数据依赖性强,模型在复杂工况下的适用性仍有待验证^[25]。

综上所述,尽管现有研究在成分或温度单一变量预测方面取得了较大进展,但针对转炉终点多元素集成预测的系统研究仍有不足。为此,本文开发了一套不等样出钢智能预测系统,基于转炉历史冶炼数据,综合考虑铁液重量、废钢比例、吹炼时间、铁液成分(Si、Mn、P)、温度、操作参数及氧气、氩气、氮气3种气体消耗量,构建集成预测模型,实现了对终点C、Si、Mn、P、S元素含量的实时在线预测。

本研究融合冶金机理知识与机器学习方法,识别影响终点成分波动的关键特征变量,通过特征重要性分析明确C、P等关键元素的主控因素。同时,集成并封装多种适用于不同场景的机器学习模型,构建了具有良好可扩展性与鲁棒性的不等样出钢预测系统。该系统推动转炉炼钢由经验驱动向数据驱动的模式转变,摒弃传统取样检测路径,提升了预测效率与过程可控性。研究成果有望实现炼钢过程的精准控制、节能降耗与质量提升,进一步增强钢铁制造的智能化水平与综合竞争力。

1 机器学习算法模型

1.1 模型搭建

图1为基于灰狼算法(grey wolf optimizer, GWO)优化的随机森林算法(random forest, RF)回归模型流程。数据来源于某钢铁厂,利用特征选择的方法来降低数据的维度,结合网格搜索和交叉验证的办法确定适应于数据库训练的模型最优参数,进而生成完整的随机森林回归算法。随机森林算法进行数据预测,与工业实际数据对比确定预测精度并进行模型评估。将优化好的训练模型应用于工业线上推广,进而推动工业智能化发展。

1.2 数据训练

从某钢铁厂 120 t 转炉中收集到 1 783 组数据

(表1),将数据进行划分,确定钢液基础属性参数为输入特征,包括铁液质量、废钢质量、吹炼时间、铁液C、Si、Mn、P和S的含量、铁液温度和氧气、氩气、氮气消耗量,输出特征为转炉终点钢液中的C、Si、Mn、P、S含量。同时对数据集进行预处理,去除重复值和缺失值,并将数据进行标准化和归一化等。

2 随机森林算法分析

2.1 热图分析

图2中的热图说明了各种数据特征之间的相互依存关系及其对预测结果的影响。研究发现,氧气消耗量和底吹时间受铁液和废钢质量的影响很大,呈正相关,这表明转炉冶炼过程中适当增加氧气注入量和注入时间有利于脱碳。同时,结合冶金热力学和




图1 机器学习算法流程

Fig.1 Flowchart of machine learning algorithms

表1 数据信息

Tab.1 Data information

	Count	Mean	Std	Min	25%	50%	75%	Max
Hot metal weight	783.0	125.3	22.44	42	98.5	140	145.4	162.8
Scrap weight	783.0	20.06	3.422	0	18.14	18.64	22.42	40.07
Si in hot metal	783.0	0.491	0.127	0	0.4	0.483	0.57	1.036
Mn in hot metal	783.0	0.192	0.039	0	0.16	0.19	0.22	0.42
P in hot metal	783.0	0.165	0.022	0	0.151	0.161	0.177	0.24
S in hot metal	783.0	0.022	0.01	0	0.018	0.023	0.029	0.078
Hot metal temperature	783.0	1 374	60.37	173	1 349	1 378	1 405	1 521
Oxygen consumption	783.0	6 076	946.2	0	5 084	6 443	6 871	7 937
Argon consumption	783.0	55.09	84.75	0	1	14	103	957
Nitrogen consumption	783.0	2017	554.9	0	1 629	1 894	2350	4239
Blowing time	783.0	734.7	63.16	0	688	733	780	929
C of steel output	783.0	0.067	0.058	0	0.049	0.057	0.069	0.079
P of steel output	783.0	0.018	0.007	0	0.015	0.018	0.021	0.086




图2 出钢碳特征相关热图

Fig.2 Feature correlation heatmap of the C content at the end of the converter process

动力学原理,发现当温度较高时,放热的碳氧反应容易正向形成 CO 或 CO₂,高温加速分子运动,加速化学反应速率,从而有效去除碳。

图3为预测终点磷含量的热图。结果表明,废钢加入量与氧气消耗量对除磷有显著影响。其次,铁液的重量和铁液的温度对除磷效果存在较大影响。铁液中硫的含量和氩气消耗量对终点磷含量的影响相对较小。基于冶金热力学和动力学分析,在转炉炼钢除磷过程中,同步提高铁液温度和氧气注入量有助于降低钢液中的磷元素,进而提升除磷效果。

2.2 相关性分析

图4展示了转炉终点预测碳含量的输入特征相关效应。在转炉冶炼过程中,铁液重量、吹炼时间和耗氧量对除碳有着较大的影响。金属热温度和金属热中的S和P组分对除碳有一定影响,但影响较弱。此外,废钢添加量和氩气用量对除碳效果影响不大。通过特征重要性分析,结合冶金热力学与动力学,发现提高铁液温度和增加吹氧量可以促进转炉终点除碳。

图5呈现了转炉终点钢液中磷含量影响的特

征意义。数据对比分析表明,废钢重量和注入时间对除磷的影响最为显著,占比分别约为27.01%和19.06%。铁液重量、铁液温度和耗氧量对除磷的影响相对较小。根据冶金热力学分析,废钢中含有一定比例的铁和其他杂质元素,在吹氧炼钢过程中,这些成分被氧化,使炉渣中FeO含量增加。FeO作为脱磷反应的重要参与者,从而提高了脱磷效率。因此废钢重量在脱磷过程中表现出最高的特征重要性。

2.3 SHAP 值分析

SHAP 值图最大的优势是 SHAP 能反映出每一个样本中的特征影响力,并明确其影响的正负性,如图6分析铁液初始成分和工业参数对利用 SHAP 值预测转炉末端碳含量的影响。图6a是对模型输出图的影响,这表明从下到上对最终预测结果的影响变得越来越重要。红色表示对预测结果的积极影响,蓝色表示对预测效果的消极影响。分析可见,铁液的重量、吹炼时间和耗氧量对其影响较为显著。高 SHAP 值的铁液重量数据点分布在负区域,表明其对碳预测有着负影响。

在图6b的决策图中展现了随机森林算法在处




图3 出钢磷特征相关热图

Fig.3 Feature correlation heatmap of the P content at the end of the converter process




图4 出钢碳相关性分析

Fig.4 Correlation analysis graph of the converter furnace endpoint prediction of C

理 1 783 组样本时的每一步决策流程, 揭示了各重要因素的作用强度和方向, 从下到上的每行依次表明, 在单个预测中, 因素对预测结果决策的影响程度逐渐增强。分析可见, 吹炼时间增加对决策过程有着促进作用, 而铁液质量增加则对决策过程有抑制作用。耗氧量的变化趋势与铁液的质量一致, 但预测的程度小于吹炼时间。铁液质量和吹气时间的




图5 出钢磷相关性分析

Fig.5 Correlation analysis graph of the converter furnace endpoint prediction of P

参数对出钢终点钢液中含碳量影响程度最大, 铁液中的磷、锰元素和加入的废钢对出钢终点钢液中除碳影响程度最小, 改善铁液温度和吹氧量对改善钢液中的碳元素影响更为显著。

通过 SHAP 值分析了输入特性对预测转炉终点磷含量的影响。图 7a 可以发现, 添加的废钢重量和氧气消耗量对预测终点 P 的影响最大, 其次是铁液




图6 SHAP 值之间的转炉末端预测 C 含量:(a) 对模型输出的影响;(b) 决策图

Fig.6 Prediction of the end-point C content in the converter on the basis of the SHAP values: (a) impact on the model output; (b) decision tree diagram

温度和注入时间的影响。铁液温度降低了预测结果,表明随着铁液温度的升高,有利于脱磷。同样,增加废钢的质量和氧气的消耗也有利于脱磷。图 7b 数据分析发现,在转炉终点磷含量的预测中,氧气的消耗量对结果的决定影响最大,其次是废钢的质量。氮的消耗对铁液温度的影响几乎相同,在一定程度上有积极的影响。因此,在冶炼过程中适当增加这些条件值有利于脱磷。

随机森林算法进行结果分析总结出基础属性对出钢终点碳、出钢磷元素含量的影响及各个属性之间的相互影响。热图、相关性分析和 SHAP 分析图得到的重要性基本一致,但存在细微差别,结合现场经验综合判断,相关性分析更为可靠。

3 工业应用

3.1 数据预测

采用 BPNN、RF 和 GBDT 算法对转炉终点碳含量进行预测,预测值与实验值的对比如图 8 所示。通过网格搜索和交叉验证,发现 RF 算法的预测效果最好,MAE 和 RMSE 分别达到了 4.51%和 6.03%。




图7 SHAP 值之间的转炉末端预测 P 含量:(a) 对模型输出的影响;(b) 决策图

Fig.7 Prediction of the end-point P content in the converter on the basis of the SHAP values: (a) impact on the model output; (b) decision tree diagram

与 BPNN 算法的 $R^2=82.493\%$ 和 GBDT 算法的 $R^2=80.376\%$ 相比,RF 算法的 $R^2=85.367\%$ 更高。对比 3 种算法的绝对误差发现,在 160 组测试数据中,RF 算法的最大误差小于 0.02%,而 BPNN 和 GBDT 算法分别有 5 组和 6 组数据的误差分别大于 0.02%。综上所述,RF 算法的性能优于 BPNN 算法和 GBDT 算法,因此考虑采用 GWO 算法对 RF 算法进行优化,进一步提升其性能。

GWO 算法和 RF 算法超参数设置如表 2 所示。由图 9 可以看出,基于 GWO 算法改进的 RF 算法的预测精度有所提高,决定系数 R^2 由 85.367%提高至 91.662%,说明 GWO 算法促进了 RF 算法的优化。

图 10 展示了 3 种算法对钢磷含量的预测值与实际值的对比结果,数据分析表明,RF 算法的预测结果更优, R^2 达到 80.464%。由于取样环境的影响,数据往往波动较大,规律性较弱,因此预测终点磷的效果比预测终点碳的效果差。在 BPNN 和 GBDT 两种算法的预测中, R^2 的值分别达到 72.343%和 75.158%,低于 RF 算法。通过比较绝对误差,BPNN 算法预测的最大误差达到 0.008%,大多数误差超过




图 8 不同算法下预测出钢碳准确率:(a) BPNN 算法;(b) RF 算法;(c) GBDT 算法

Fig.8 Predicted accuracy of C content at the end of the converter process under different algorithms: (a) BPNN algorithm, (b) RF algorithm, (c) GBDT algorithm

表2 优化的超参数类型
Tab.2 Optimized hyperparameter types

Algorithm	Hyper-parameter	Range
GWO	Num_wolves	10
	Max_iter	50
	Convergence factor	2
RF	Max depth	3~20
	Min samples split	2~10
	Min samples leaf	1~10
	Learning rate	0.01~0.50




图 9 在 GWO-RF 算法中预测转炉终点 C 含量

Fig.9 Predicting the C content at the end point of the converter in the GWO-RF algorithm

0.004%。在 GBDT 算法预测的误差中,大多数数据的误差接近 0.004%,而在 RF 算法中,误差接近 0% 的数据更多。综合而言,RF 算法的预测性能优于 BPNN 算法和 GBDT 算法。

通过比较 BPNN、RF 和 GBDT 3 种算法,发现

RF 算法的预测效果最好。利用 GWO 算法对 RF 算法进行优化,得到的预测结果如图 11a 所示。可以发现,优化后的 GWO-RF 算法的 R^2 从 80.464% 提高到 82.185%,但性能改善效果不明显。这是由于训练数据库中数据的规律性不强,导致预测结果的拟合程度较低。由于废钢质量在特征重要性方面对预测结果的影响最大,所以结合废钢质量特征对 GWO-RF 的预测结果进行校正。所获得的预测结果如图 11b 所示。通过数据运算,发现校正后的 GWO-RF 算法的 R^2 达到了 86.418%。结合对绝对误差的分析,发现预测误差在一定程度上得到了减小。因此,证明改进的 GWO-RF 算法的性能与 RF 算法相比有了明显的提高。

3.2 在线软件开发

基于 Python 3.9 的运行环境,将 GWO 算法改进的 RF 算法代码进行封装,形成实时在线预测软件,实现转炉终点碳硅锰磷硫等元素的预测,并通过工厂测试后投入应用。图 12 为软件主界面,主要包括 4 大功能模块:数据读入、算法参数、数据训练和数据预测。

图 13 数据输入模块主要是添加用于预测系统训练的数据集。将数据库中数据进行预处理,删除误差较大和有缺失值的数据后将数据加载到算法中,将数据集按照训练集:测试集=8:2 的比例进行划分,数值输入主要包括铁液基础属性、工业冶炼参数和吹入转炉系统的气氛,输出主要是转炉终点的钢液




图 10 不同算法下预测出钢磷准确率:(a) BPNN 算法;(b) RF 算法;(c) GBDT 算法

Fig.10 Predicted accuracy of P content at the end of the converter process under different algorithms: (a) BPNN algorithm; (b) RF algorithm; (c) GBDT algorithm




图 11 GWO-RF 算法预测转炉终点 P 含量:(a) 参数校正前;(b) 参数校正后

Fig.11 Prediction of the P content at the end of the converter in the GWO-RF algorithm: (a) before parameter correction; (b) after parameter correction



图 12 在线预测软件主界面模块

Fig.12 Main interface module for the online prediction software

中的碳硅锰磷硫含量。算法参数设置模块实现的是算法参数的调节,通过网格搜索和交叉验证的方式搜索得到模式匹配参数和通过代码测试后输入适应预测转炉终点元素的最佳参数,通过自动获取最佳

超参数。数据训练模块中输入数据集的基础属性和预测值名称,确定预测系统输入特征与输出特征,以完成预测系统的特征构建。

图 14 实现的是转炉终点钢液内碳硅锰磷硫元素含量的预测。输入铁液成分、工业参数、气体耗量等基础属性数值,点击“预测”即可实现转炉终点碳硅锰磷硫数值预测。通过软件的实时预测和工厂测试,预测精度达到了 90% 以上,预测软件的运行时间缩短至 0.1~0.3 s 之间,实现了转炉生产过程中不等样出钢。避免取样、检测环节,节省了转炉钢液终点等待时间,提高了生产效率。

4 结论

(1)BPNN、RF 和 GBDT 3 种算法实现了转炉终




图 13 在线预测软件数据读入模块

Fig.13 Data input module for the online prediction software




图 14 在线预测软件数据预测模块

Fig.14 Data prediction module for the online prediction software

点 C 含量的预测,发现评价指标 R^2 分别达到了 82.493%、85.367%和 80.376%。为了进一步提高命中率,利用 GWO 算法优化了 RF 算法的超参数。通过对比,优化后的 GWO-RF 的 R^2 指标达到了 91.662%。

(2)在转炉终点 P 含量的预测中,BPNN、RF 和 GBDT 3 种算法评价指标 R^2 分别达到了 72.343%、80.464%和 75.158%。利用 GWO 算法优化 RF 算法后, R^2 达到了 82.185%。利用重要特征对 GWO-RF 预测结果进行校正,评价指标 R^2 得到了提升,达到了 86.418%。

(3)基于优化后的 GWO-RF 算法,实现了转炉终点 C、Si、Mn、P、S 5 种元素的预测,开发了现场使用的转炉终点不等样出钢实时预测系统,命中率达到 90%以上,预测时间控制在 0.1~0.3 s 之间,每炉冶炼时间缩短约 3~5 min,从而提高了生产效率。

参考文献:

[1] ZHU R, HAN B C, DONG K, WEI G S. A review of carbon diox-

ide disposal technology in the converter steelmaking process[J]. International Journal of Minerals, Metallurgy and Materials, 2020, 27: 1421-1429.

[2] 陈均,王二军,李小勇,曾建华,梁新腾.半钢冶炼提高转炉终点碳出钢试验研究[J].铸造技术,2019,40(10): 1054-1059.

CHEN J, WANG E J, LI X Y, ZENG J H, LIANG X T. Study on improving tapping-carbon of semi-steel steelmaking converter[J]. Foundry Technology, 2019, 40(10): 1054-1059.

[3] ZHOU C G, CHEN Q G, JI Y, AI L Q, WANG S H, CHEN Q Y, YUAN T X. Effect of highly oxidizing converter dephosphorization slag on dephosphorization behaviour of molten steel[J]. Iron-making & Steelmaking, 2023, 50(8): 958-968.

[4] CHEN Z Q, HAO H B, SALAS-AVILA J R, FAN M Y, XIE Y D, WANG S P, LI J Y, XU J X, WANG H, YIN W L. Estimation of metal state in molten production processes using electromagnetic tomography with fast integrated processing[J]. Measurement Science and Technology, 2022, 33(7): 074003.

[5] HAN M, ZHAO Y. Dynamic control model of BOF steelmaking process based on ANFIS and robust relevance vector machine[J]. Expert Systems with Applications, 2011, 38(12): 14786-14798.

[6] 冯士超,王艳红,丁瑞锋.转炉炼钢终点控制技术应用现状[J].冶

- 金自动化, 2016, 40(2): 1-6.
- FENG S C, WANG Y H, DING R F. Application status of end-point control technology in converter steelmaking[J]. Metallurgical Industry Automation, 2016, 40(2): 1-6.
- [7] 赵多祯. 基于图像处理的转炉终点预测研究[D]. 包头: 内蒙古科技大学, 2020.
- ZHAO D Z. Research on prediction of converter endpoint based on image processing[D]. Baotou: Inner Mongolia University of Science and Technology, 2020.
- [8] 杨文远, 蒋晓放, 王明林, 吴文东, 刘路长. 转炉炼钢节能的技术问题[J]. 钢铁研究学报, 2010, 22(8): 22-26.
- YANG W Y, JIANG X F, WANG M L, WU W D, LIU L C. Technical problems of energy-saving in BOF steelmaking[J]. Journal of Iron and Steel Research, 2010, 22(8): 22-26.
- [9] 姚同路, 吴伟, 杨勇, 贺庆, 孟华栋, 林腾昌. “双碳”目标下中国钢铁工业的低碳发展分析[J]. 钢铁研究学报, 2022, 34(6): 505-513.
- YAO T L, WU W, YANG Y, HE Q, MENG H D, LIN T C. Analysis of low-carbon development of China's steel industry under "dual carbon" goals[J]. Journal of Iron and Steel Research, 2022, 34(6): 505-513.
- [10] 刘建勋, 刘辉. 面向转炉炼钢终点碳含量预测的多方向加权复杂网络火焰图像纹理特征提取模型[J]. 钢铁研究学报, 2025, 37(2): 151-163.
- LIU J X, LIU H. A multi-dimensional weighted complex network model for flame Image texture feature extraction aiming at predicting endpoint carbon content in converter steelmaking[J]. Journal of Iron and Steel Research, 2025, 37(2): 151-163.
- [11] PAN G F, WANG F Y, SHANG C L, WU H H, WU G L, GAO J H, WANG S Z, GAO Z J, ZHOU X Y, MAO X P. 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.
- [12] JIN B Z, XU X J. Machine learning predictions of regional steel price indices for east China[J]. Ironmaking & Steelmaking, 2025, 52(3): 368-381.
- [13] WANG Z X, XIE Y, WANG L, LIU X, HU S W, ZHANG L Q, ZHANG C J. Applications and progress of machine learning techniques in the ladle furnace refining process: A review[J]. Steel Research International, 2024, 96(7): 2400551.
- [14] 朱航宇, 董清源, 薛正良, 王炜, 余岳. 基于钢铁大学网站转炉虚拟炼钢成本影响因素[J]. 铸造技术, 2017, 38(5): 1099-1102.
- ZHU H Y, DONG X Y, XUE Z L, WANG W, YU Y. Analysis on cost influence factors of basic oxygen virtual steelmaking based on steel university website[J]. Foundry Technology, 2017, 38(5): 1099-1102.
- [15] 管挺, 叶磊, 万文华. 120 t 转炉高碳出钢工艺研究和应用[J]. 特殊钢, 2021, 42(2): 31-34.
- GUAN T, YE L, WAN W H. Technical study and application of high carbon liquid tapping of 120 t converter [J]. Special Steel, 2021, 42(2): 31-34.
- [16] 景林, 闵义, 元捷, 刘承军, 范佳. 基于机器学习的转炉热损失率预测[J]. 冶金自动化, 2023, 47(6): 21-27.
- JING L, MIN Y, QI J, LIU C J, FAN J. Prediction of converter heat loss rate based on machine learning [J]. Metallurgical Industry Automation, 2023, 47(6): 21-27.
- [17] 张龙强, 闵义, 刘承军, 黄健, 郑传新, 马威. 基于机器学习的转炉冶炼终点残锰含量预测[J]. 炼钢, 2024, 40(5): 38-43.
- ZHANG L Q, MIN Y, LIU C J, HUANG J, ZHENG C X, MA W. Prediction of residual manganese content at the end point of converter smelting based on machine learning [J]. Steelmaking, 2024, 40(5): 38-43.
- [18] 王建国, 吴庆朝, 秦波, 张娟娟, 张文兴, 陈林. 粒子群优化支持向量机的 BOF 用氧量预报研究[J]. 铸造技术, 2014, 35(8): 1806-1809.
- WANG J G, WU Q Z, QIN B, ZHANG J J, ZHANG W X, CHEN L. Study on blowing oxygen volume prediction of BOF steelmaking based on PSO-SVM[J]. Foundry Technology, 2014, 35(8): 1806-1809.
- [19] XIE X X, WANG H J, LI W M, ZHAN D P, LI X Y, ZANG X M. Prediction model of endpoint temperature of converter steelmaking based on PCA-BP neural network[J]. Transactions of the Indian Institute of Metals, 2025, 78(4): 90.
- [20] HU Y, TANG J, HUANG B S, XU R Y. Research on prediction model of converter steelmaking process based on multi-scale feature extraction and self-attention mechanism for multi-source domain asynchronous data[J]. Measurement, 2025, 250: 117060.
- [21] SHAO X, LIU Q, XIN Z C, ZHANG J S, ZHOU T, LI S S. Hybrid model for BOF oxygen blowing time prediction based on oxygen balance mechanism and deep neural network[J]. International Journal of Minerals, Metallurgy and Materials, 2024, 31: 106-117.
- [22] FU T J, LIU S M, LI P Y. Digital twin-driven smelting process management method for converter steelmaking[J]. Journal of Intelligent Manufacturing, 2024, 36: 2749-2765.
- [23] HUANG C Y, DAI Z J, SUN Y, WANG Z J, LIU W, YANG S F, LI J S. Recognition of converter steelmaking state based on convolutional recurrent neural networks[J]. Metallurgical and Materials Transactions B, 2024, 55(3): 1856-1868.
- [24] KANG Y, ZHAO J X, LI B, REN M M, CAO G, YUE S, AN B Q. End-Point prediction of converter steelmaking based on main process data[J]. Steel Research International, 2024, 95(8): 2400151.
- [25] FANG W, HUANG J X, PENG T X, LONG Y, YIN F X. Machine learning-based performance predictions for steels considering manufacturing process parameters: A review[J]. Journal of Iron and Steel Research International, 2024, 31(7): 1555-1581.

(责任编辑: 宫文婧)