

烧结矿 FeO 含量预测技术的探讨

唐佳润^{1,2}, 刘月明^{1,2}, 张福明³, 李 贺^{1,2}

(1. 北京首钢国际工程技术有限公司, 北京 100043; 2. 北京市冶金三维仿真设计工程研究中心, 北京 100043;
3. 首钢集团有限公司, 北京 100041)

摘要: 烧结矿 FeO 含量是衡量烧结矿还原性的重要指标。为了全面而系统地概述各种烧结矿 FeO 含量的预测方法, 本文从机理模型和机器学习算法(包括经典单一学习算法模型、协同优化算法模型、深度神经网络算法模型及集成学习算法模型)两大预测模型出发, 分别从基于工艺流程参数、机尾图像识别预测, 以及基于图像-参数协同预测进行三个方面探讨, 总结了烧结矿 FeO 含量预测方法的发展脉络; 并对近年来新兴的算法预测模型进行全面概括与深入分析, 阐述了每种算法在烧结矿 FeO 含量预测模型的优点和局限; 同时展望了未来烧结矿 FeO 含量预测领域的研究方向, 以期为该领域的研究与实践提供有益的参考。

关键词: 烧结矿; FeO; 大数据; 机器学习; 深度学习

中图分类号: TF56; TF813; X757

文献标志码: A

文章编号: 1000-8764(2025)01-0021-10

doi: 10.13403/j.sjqt.2025.01.003

Discussion on prediction technology of FeO content in sinter

TANG Jiarun^{1,2}, LIU Yueming^{1,2}, ZHANG Fuming³, LI He^{1,2}

(1. Beijing Shougang International Engineering Technology Co., Ltd., Beijing 100043, China;

2. Beijing Metallurgical 3-D Simulation Design Engineering Technology Research Center, Beijing 100043, China;

3. Shougang Group Co., Ltd., Beijing 100041, China)

Abstract: The FeO content of sinter is an important index to measure the reducibility of sinter. In order to comprehensively and systematically outline the prediction methods of FeO content in various sinters, two prediction models of mechanism model and machine learning algorithm (including classic single learning algorithm model, collaborative optimization algorithm model, deep neural network algorithm model and integrated learning algorithm model) are started to discuss from parameters based on the process, prediction recognition of the tail image, and prediction based on image-parameter collaborative prediction. The development of the method for predicting FeO content in sinter is summarized; the emerging algorithm prediction models in recent years are comprehensively summarized and analyzed and the advantages and limitations of each algorithm in the sinter FeO content prediction model are expounded. At the same time, the future research direction of sinter FeO content prediction is prospected, in order to provide a useful reference for the research and practice in this field.

Key words: sinter; FeO; big data; machine learning; deep learning

烧结矿 FeO 含量不仅是反映烧结矿质量的重要指标之一, 而且对高炉炉况的稳顺有着重要的意义^[1]。烧结矿 FeO 含量过高会降低烧结矿的还

原性, 使高炉的焦比升高。若是含量过低, 会使高炉炉内透气性变差, 从而影响高炉的顺行。FeO 含量的波动还会直接影响烧结工序能耗和高炉的

收稿日期: 2024-04-03; 修回日期: 2024-07-15

基金项目: 北京学者培养计划资助项目(2015-08)

作者简介: 唐佳润(1984—), 男, 高级工程师, 从事烧结球团研究设计工作。

通信作者: 刘月明(1991—), 男, 工程师, 从事烧结球团研究设计工作。

增铁节焦^[2]。因此, 烧结矿中的 FeO 含量是国内外钢铁企业非常重视的指标。一直以来, FeO 含量的判断都是依靠人工的经验, 因此不可避免会存在人为因素, 判断的精度也很难准确把握。由于烧结矿 FeO 含量的生成机理非常复杂, 通过计算难以得出准确的答案。利用实验室重铬酸钾滴定技术来精确测定烧结矿中的 FeO 含量, 这种化学成分分析法因其高准确度和直接性而被生产现场广泛采用^[3]。但由于烧结过程的连续性, 而人工采样和分析耗时较多, 这使得实时生产控制变得具有挑战性。然而, 与传统的化学成分分析法相比, 机器学习模型能够在短时间内提供预测结果, 无需耗费 4~6 h 进行人工采样和分析, 使得实时生产控制变得更为便捷和高效^[4-5]。同时, 机器学习模型能够基于大量历史数据进行训练, 从而可以更准确地预测烧结矿中 FeO 含量^[6]。这种预测能力有助于生产现场提前作出调整, 优化生产流程, 提高产品质量。此外, 机器学习模型还具有自适应性, 能够随着生产环境的变化而自动调整预测模型, 保持预测结果的准确性。因此, 为了让预测模型更好的服务于实际生产, 本文对目前烧结矿 FeO 含量使用的主流预测模型进行了系统的归纳与总结, 并重点阐述了各模型的优缺点, 并对预测模型的发展趋势进行了展望。

1 机理预测模型

传统的机理预测模型是建立系统所依赖的参数模型, 把辨识问题转化为参数的估计问题^[7]。其实质在于, 通过对烧结过程中物质结构、能量传递和反应动力学等关键要素的分析, 建立数学模型来模拟和预测烧结过程的行为。这些模型可以揭示烧结过程中的物理和化学变化, 以及各因素之间的相互作用和影响。它们通常基于烧结过程的基本原理, 结合实验数据和经验公式, 通过数学推导和计算, 得到能够描述烧结过程动态特性的数学模型。这些模型可以用于指导烧结工艺的设计和优化, 提高烧结产品的质量和性能。彭坤乾^[8]对烧结过程中的物化反应现象进行了全面研究。其利用传质和传热分析, 构建了料层温度的计算方程, 并通过模拟计算揭示了料层温度场

的分布情况, 成功预测了烧结矿的质量指标。YAMAOKA 等^[9]通过建立三维数学模型, 探讨了烧结床层中的中间参数与烧结矿质量指标之间的关系, 通过模拟分析, 成功得出了转鼓强度, 还原性指数等指标。

机理预测模型以工艺机理为基础, 经过复杂的分析过程, 可以大体反映出系统的实际规律。但是过于依赖开发人员对实际生产的机理认知, 并且忽略了工况的波动使得机理模型不能够全面反映实际生产。随着我国逐步进入智能时代, 烧结工艺也在不断采用机器学习进行研究与应用。烧结机器学习预测模型基于大量实验数据训练而成, 能够捕捉烧结过程中的复杂关系和非线性行为。近年来我国报道了许多关于此类烧结矿 FeO 含量预测模型的研究成果。

2 机器学习算法预测模型

随着工业 4.0 和智能制造的快速发展, 现代钢铁工业面临着越来越复杂和多变的生环境, 对生产过程的实时监控和精确控制提出了更高的要求^[10]。FeO 含量作为烧结矿的关键指标, 对烧结过程的热力学和动力学特性有着直接影响, 进而决定烧结矿的质量和产量。FeO 含量的适宜控制对高炉炼铁的经济和环保具有显著影响, 能够优化还原反应, 降低能耗和减少排放, 提升炼铁效率。因此, 实现 FeO 含量的精确控制对于烧结和炼铁过程的高效、经济和环保至关重要。

近年来, 机器学习技术的快速发展, 尤其是在算法设计和计算能力方面的显著提升, 为 FeO 含量预测提供了更为精确和高效的方式。机器学习算法通过分析大量的历史数据, 能够识别和学习生产过程中的复杂模式和规律。与传统的预测方法相比, 机器学习技术能够更好地适应数据的非线性特性和动态变化, 从而提高预测的准确性和可靠性。尽管 FeO 含量预测的研究历史悠久, 但机器学习技术的引入无疑为这一领域带来了新的活力和可能性。机器学习技术并非取代传统方法, 而是在现有研究的基础上, 提供了一种更为先进的分析和预测手段。本文对目前包括经典单一机器学习算法、协同优化算法、深度神经网络

算法和集成学习算法等几类主要的机器学习算法在烧结矿 FeO 含量预测中应用的研究现状、优势及局限性进行了阐述,旨在为未来的研究和实际应用提供有益的参考和指导。

2.1 经典单一学习算法预测模型

单一机器学习算法预测模型以其简洁性和高效性,在特定场景下发挥着重要作用。这种模型通常基于大量的历史数据,通过挖掘数据中的内在规律和模式,对未来的趋势进行预测。由于只涉及一个算法,其结构相对简单,计算量较小,因此具有较高的运算效率。

2.1.1 基于工艺流程参数的预测模型

表 1 列举了一些主要的有关经典单一机器学习算法在烧结生产过程参数预测模型的应用情况及效果。

表 1 经典单一机器学习算法在烧结生产过程参数预测模型的应用情况及效果

Table 1 Application and effect of a classical single machine learning algorithm to in parameters prediction mode of sintering production process

文献	算法模型	预测效果
张舒等 ^[11]	BP 神经网络算法	决定系数为 0.67
宋强 ^[12]	BP 神经网络算法	命中率为 89.5%
陈伟等 ^[13]	BP 神经网络算法	命中率为 91.6%
龙红明等 ^[14]	BP 神经网络算法	命中率为 90% 以上
张帆等 ^[15]	RBF 神经网络算法	绝对误差为 0.003 5, 相对误差为 4.99, 平均相对误差为 2.33
蒋大军 ^[16]	ARIMA 算法	决定系数为 0.826 8

由表 1 所可知,此类模型应用最为广泛的是 BP 神经网络。BP 神经网络在烧结矿指标预测中展现出卓越性能^[17]。其优点主要体现在: ① BP 神经网络具有强大的自学习和自适应能力,能够通过不断调整网络参数来优化预测结果; ② 该网络能够处理复杂的非线性关系,可以更好地拟合实际数据。但 BP 神经网络也存在一些缺点,例如训练过程可能陷入局部最小值,导致预测结果不准确。此外,网络结构的选择和参数的设定对预测结果也有较大影响,需要进行充分的实验和调整。BP 神经网络算法因其鲁棒性、精确性和泛化能力而被广泛应用,命中率在 89.5% 至 91.6% 之

间,表明其在预测 FeO 含量方面具有一定的准确性。RBF 神经网络算法因其快速收敛和处理高维数据的能力,在预测 FeO 含量时表现出更低的误差率,其绝对误差为 0.003 5,相对误差为 4.99%,平均相对误差为 2.33%,显示出比 BP 神经网络更优的预测性能。ARIMA 算法的决定系数为 0.826 8,显示出较好的预测效果,但受限于其对平稳序列数据和线性关系的假设。尽管这些模型在工业化应用中实现了在线自学习和实时跟踪预测,但它们主要依赖单一的数据采集方式,忽略了从烧结矿图像中获取特征的可能性,这可能是未来研究的一个方向。

2.1.2 基于机尾图像识别的预测模型

许多有经验的看火工可以通过观察烧结矿机尾断面的图像迅速的判断烧结矿中 FeO 含量的高低,这需要看火工多年的经验积累才能够准确判断出 FeO 含量。图 1 展示了典型的烧结过程。在烧结机的尾部,当尾部星轮翻转时,块状烧结物会落下,这个过程会出现烧结床的横截面。这个横截面包括部分冷却的烧结物和仍处于高温状态的烧结物。通过观察烧结床表面,有经验的操作人员可以对烧结 FeO 含量进行初步的评估。由于烧结机尾部的高温 and 大量灰尘条件,可见光摄像机的成像精度较低,而红外热成像技术则非常适应这种情况。表 2 列举了一些主要的有关经典单一机器学习算法在烧结机尾图像识别预测模型的应用情况及效果。由表 2 可知,在烧结机尾断面图像预测 FeO 含量的研究中,BP 神经网络和 RBF 神经网络均显示出有效性。JIANG 等^[18]通过红外热成像仪采集图像并建立 BP 模型,均方根误差为 1.33。周志远^[19]的 BP 模型命中率为 91.83%,而周德玉^[20]和王翊^[21]的模型均达到 85% 以上的命中率,且绝对误差控制在 ± 0.3 以内。周后伟^[22]的 BP 模型命中率为 85.0%,张兆磊^[23]的 BP 模型平均绝对误差为 2.847 7。综合来看,BP 神经网络在烧结机尾图像识别预测 FeO 含量中具有较高的命中率,而 RBF 神经网络在误差控制方面表现良好。这些研究表明,结合图像特征的机器学习模型对于实时预测 FeO 含量是有效的,且有潜力进一步提高预测的准确性。

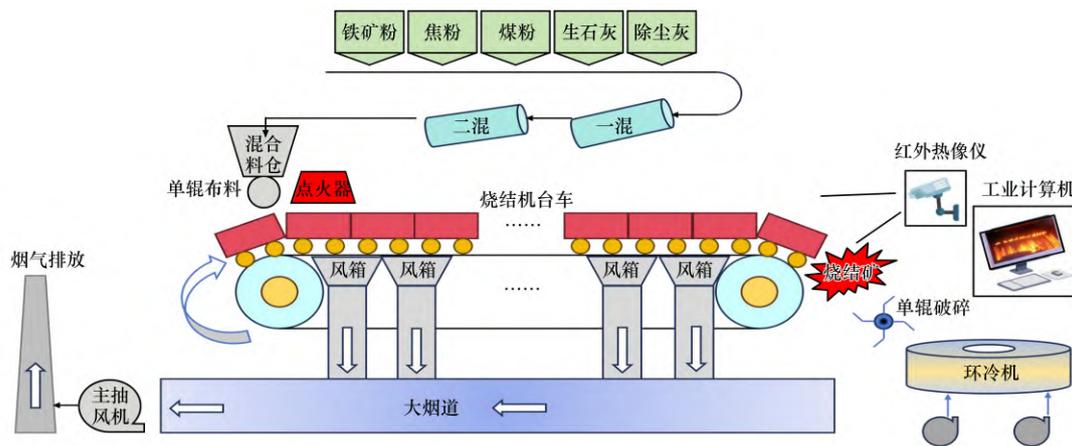


图 1 烧结工艺流程示意

Fig. 1 Schematic diagram of sintering process flow

表 2 经典单一机器学习算法在烧结机尾图像识别预测模型的应用情况及效果

Table 2 Application and effect of classical single machine learning algorithm in image recognition and prediction model of sintering machine tail

文献	算法模型	预测效果
JIANG 等 ^[18]	BP 神经网络算法	均方根误差为 1.33
周志远 ^[19]	BP 神经网络算法	命中率为 91.83%
周德玉 ^[20]	BP 神经网络算法	命中率不小于 85%，绝对误差不超过 ± 0.3
王翊 ^[21]	RBF 神经网络算法	命中率大于 85.0% 绝对误差控制在小于 ± 0.3
周后伟 ^[22]	BP 神经网络算法	命中率为 85.0%
张兆磊 ^[23]	BP 神经网络算法	平均绝对误差为 2.847 7

2.1.3 基于图像-参数协同的预测模型

鉴于单一图像或工艺参数预测模型的明显局限性，近几年，研究者陆续采用基于图像-参数协同的烧结矿 FeO 预测模型应用于冶金领域。该模型主要结合了烧结矿图像特征和工艺参数，通过机器学习算法进行预测。模型首先对烧结矿图像进行预处理，提取纹理、形状等关键特征；其次，收集与烧结过程相关的参数，如温度、时间、配料比例等。随后，将这些图像特征和工艺参数作为输入变量，采用机器学习算法进行建模和训练，并通过交叉验证等方法优化模型参数，提升预测精度。张乐文^[24]以烧结生产过程参数与机尾断面图像结合的方式进行多个参数的提取，使用加权支持向量机对 FeO 含量进行实时的判定，做到了准确实时的预测，命中率为 90% 以上。相比单一

的参数或图像特征模型，基于图像-参数协同的模型具有更高的准确性和稳定性。

以上模型虽做到了实时预测，但由于所用机器学习算法过于单一，预测精度即使达到了烧结厂的生产要求，模型的鲁棒性也比较差，有待于采用更为优秀的算法来优化提高预测的性能。

2.2 协同优化算法预测模型

经典单一机器学习算法预测模型存在一定的局限性。此外，如果所选算法不适用于当前数据集，那么预测结果可能会出现较大偏差。不同的算法可能对不同的数据特征或模式有不同的敏感度^[25]。协同优化算法通过结合多种单一机器学习算法，可以综合利用各种算法的优点，从而提高预测精度。

表 3 列举了一些主要的有关协同优化算法在烧结生产过程参数预测模型的应用情况及效果。由表 3 可知，协同优化算法在烧结矿 FeO 含量预测中取得了积极成果。方怡静等^[26]的 DK-AWESN 模型在复杂工况下表现出较高的命中率 (86.67%)，平均绝对误差为 0.251。史振杰等^[27]的 GWO-SVR 模型具有高的决定系数 (0.901 6) 和较低的均方误差 (0.015 6)。邵长江^[28]的 SSA-BP 模型均方根误差为 0.015 9，而张智峰等^[29]的 MIV-GA-BP 模型均方根误差为 0.238 6。惠佳豪等^[30]的 KPCA-Logistic-SSA-BP 模型均方误差为 0.013，均方根误差为 0.115。张军红等^[31]的 G-BP 算法平均绝对误差为 0.132，平均相对误差为 1.4%。吉训生等^[32]的 IFA-BP 算法命中率高

表 3 协同优化算法在烧结生产过程参数预测模型的应用情况及效果

Table 3 Application and effect of collaborative optimization algorithm in the parameter prediction model of sintering production process

文献	算法模型	预测效果
方怡静等 ^[26]	DK-AWESN	平均绝对误差为 0.251, 均方根误差为 0.301, 命中率为 86.67%
史振杰等 ^[27]	GWO-SVR 算法	决定系数为 0.901 6, 均方误差为 0.015 6, 平均绝对百分比误差为 3.545 1
邵长江 ^[28]	SSA-BP 算法	平均绝对百分比误差为 2.158 3, 均方根误差为 0.015 9
张智峰等 ^[29]	MIV-GA-BP 算法	均方根误差为 0.238 6
惠佳豪等 ^[30]	KPCA-Logistic-SSA-BP 算法	均方误差为 0.013, 均方根误差为 0.115, 平均绝对误差为 0.101
张军红等 ^[31]	G-BP 算法	平均绝对误差为 0.132, 平均相对误差为 1.4
吉训生等 ^[32]	IFA-BP 算法	平均绝对误差为 1.22, 平均相对误差为 1.46%, 命中率为 98%

98%, 平均绝对误差为 1.22。综上所述, 协同优化算法通过结合不同算法的优势, 有效提高了烧结矿 FeO 含量预测的精度和模型的鲁棒性。尽管模型复杂度增加可能带来参数调整的困难和可解释性的降低, 但这些模型在实际生产中的适应性和可靠性得到了提升, 对数据收集和提出更高要求。

近些年, 基于协同优化算法的图像识别预测模型的研究报道相对较少。仅见张学峰等^[33]针对烧结矿 FeO 含量难以直接预测的问题, 选取与烧结矿 FeO 含量强相关性的烧结机尾断面热成像关键帧的温度特征作为模型的参数输入, 利用 Dropout 算法改善四层 BP 神经网络结构, Adam 算法优化四层 BP 神经网络的训练过程, 进而提高模型的预测精度和泛化能力。报道研究少的原因可能是由于图像识别本身就是一个复杂的技术领域, 而将其与协同优化算法相结合进一步增加了技术难度。

2.3 深度神经网络算法预测模型

深度神经网络通过逐层学习数据的抽象表示, 能够自动提取数据的复杂特征和模式。这使得它能够处理复杂的数据类型, 并在预测任务中表现出色^[34]。深度神经网络与 BP 神经网络的主要区别在于层次深度和结构复杂性。深度神经网络具有更多的隐藏层, 能够学习更抽象的特征表示, 适合处理复杂的非线性问题。而 BP 神经网络结构相对简单, 通常用于解决线性或非线性分类问题。深度神经网络可以直接从原始数据学习到预测结果, 而无需进行繁琐的特征工程。通过学习数据中的统计规律, 能够捕捉到数据的内在结构。这

使得它在面对新数据时, 能够利用已学到的知识进行预测, 表现出良好的泛化能力。

2.3.1 基于工艺流程参数的预测模型

表 4 列举了一些主要的有关深度神经网络算法在烧结生产过程参数预测模型的应用情况及效果。

表 4 深度神经网络算法在烧结生产过程参数预测模型的应用情况及效果

Table 4 Application and effect of deep neural network algorithm in parameter prediction model of sintering production process

文献	算法模型	预测效果
LIU 等 ^[35]	LSTM 算法	决定系数为 0.92, 均方误差和平均绝对误差接近 0
LI 等 ^[36]	GRU 算法	均方误差为 0.206
閻光磊等 ^[37]	GMM 与 KNN 算法	命中率为 95.33%
YANG 等 ^[38]	GRU-PLS	均方误差为 0.002

表 4 展示了深度神经网络在烧结矿 FeO 含量预测中的应用及其效果。LIU 等^[35]的 LSTM 模型具有高决定系数(0.92), 均方误差和平均绝对误差接近 0, 显示了出色的预测性能。LI 等^[36]的 GRU 模型均方误差为 0.206, 表现良好。閻光磊等^[37]结合 GMM 与 KNN 算法的模型命中率达 95.33%, 而 YANG 等^[38]的 GRU-PLS 模型均方误差为 0.002, 运行非常稳定。这些结果表明, 深度神经网络能够有效地从原始数据中学习并预测 FeO 含量, 无需复杂的特征工程^[39], 同时具有较强的鲁棒性和自适应性。深度学习模型通过持续学习适应生产条件的变化, 维持高预测精度, 为烧结矿 FeO 含量的实时控制提供了强有力的技术

支持。

2.3.2 基于机尾图像识别的预测模型

生产过程参数虽然是影响 FeO 含量的重要因素，但它们可能不是最直接的指标。烧结机尾断面图像可能包含更直接和丰富的信息^[40]，如烧结矿的结构、颜色、气孔等，这些特征可能与 FeO 含量有更直接的关系。通过图像识别，模型可以同时考虑多个变量的影响，这有助于捕捉更复杂的关系，从而提高预测准确性。烧结机尾断面识别模型可以直接从图像中捕获生产环境的变化，如原料成分的变化、设备状态的变化等。这使得模型能够更快速地适应这些变化，保持预测的准确性。图像识别实时的自动化数据采集和处理，有助于在生产过程中进行实时的 FeO 含量预测，从而及时调整生产参数。

相比较生产过程参数预测，机尾图像识别预测文献报道较多。原因在于神经网络比较擅长处理图像类特征。表 5 列举了一些主要的有关神经网络算法在烧结机尾图像识别预测模型的应用情况及效果。

表 5 神经网络算法在烧结机尾图像识别预测模型的应用情况及效果

Table 5 Application and effect of deep neural network algorithm in image recognition and prediction model of sintering machine tail

文献	算法模型	预测效果
张宁 ^[41]	卷积神经网络算法	命中率大于 90% 均方根误差低于 0.003
张学峰等 ^[42]	BiLSTM 算法	平均绝对误差为 0.202，均方根误差为 0.258，平均相对误差为 10.6%
BAI 等 ^[43]	LSTM	均方误差小于 0.1
任玉辉等 ^[44]	Darknet-19 算法	命中率为 82.5%
张学锋等 ^[45]	BiLSTM 算法	命中率为 90.2% 以上
匡朝辉等 ^[46]	卷积神经网络	命中率为 90% 以上

张宁^[41]的卷积神经网络模型命中率超过 90%，均方根误差低于 0.003。张学峰等^[42]的 BiLSTM 模型平均绝对误差为 0.202，均方根误差为 0.258，平均相对误差为 10.6%。BAI 等^[43]的 LSTM 模型均方误差小于 0.1。任玉辉等^[44]的 Darknet-19 算法命中率为 82.5%，而张学锋等^[45]

的 BiLSTM 模型命中率超过 90.2%。匡朝辉等^[46]的卷积神经网络命中率也超过 90%。这些研究表明，神经网络能够有效地从烧结机尾图像中提取特征并预测 FeO 含量，具有较高的命中率和较低的误差率。尽管如此，这些模型也面临图像采集质量、预处理和特征提取复杂性的挑战。神经网络在烧结机尾图像识别预测 FeO 含量方面展现出潜力，但仍需解决图像处理相关的挑战以提高模型的实用性和准确性。

2.3.3 基于图像-参数协同的预测模型

采用神经网络算法的基于图像-参数协同的烧结矿 FeO 预测模型通过神经网络提取烧结矿图像的高层次特征，并结合烧结过程的工艺参数（如温度、时间、配料比例等），可实现多模态数据的融合与协同预测。该模型利用神经网络提取纹理、形状等特征，然后将这些图像特征与工艺参数输入到多层感知器或其他神经网络中进行联合训练。通过反向传播算法优化模型权重，提升预测精度，并获得了良好的应用效果。丁谦^[47]利用深度学习模型对图像进行特征提取，为了提升预测模型的精确度和稳定性，融合了生产参数特征与图像特征，构建了以神经因子分解机为框架的预测模型，平均绝对误差为 0.092 6，平均相对误差为 1.139%。基于神经网络的协同预测模型在预测烧结矿 FeO 含量方面表现出色，较传统算法具有更高的准确性和鲁棒性。此外，模型在处理非线性和复杂数据关系方面表现优越，能够更有效地应对实际生产中的多变工况。ZHOU 等^[48]提出了融合图像特征和烧结过程变量，建立了基于深度学习算法的预测模型，实现了实时准确测量铁矿石中 FeO 含量，实验结果表明该方法具有 98.35% 的高准确率。YANG 等^[49]将烧结数值数据和图像数据集成，实现数据级信息融合，为 Autoformer 深度学习算法提供了相对全面的烧结工艺信息而且还带来了成品烧结矿中 FeO 含量水平的先验信息，在实际工业数据的应用中表现出比现有模型更高的预测精度和稳定性。

2.4 集成学习算法预测模型

集成学习是一种新的机器学习模式，即通过

集成多个子模型来解决一个问题能够有效提高学习的泛化能力^[50]。近几年集成学习算法一直是机器学习领域最关注的研究方向之一,并且发展非常迅速。集成学习算法与协同优化算法的主要区别在于它们的实现方式和目标。集成学习算法是一种通过结合多个单一学习器的预测结果来做出最终决策的机器学习技术。

烧结矿 FeO 含量预测模型可以借鉴集成学习算法来优化预测的性能。吕庆等^[51]为了克服烧结矿中 FeO 含量检验滞后的问题,基于烧结生产各个环节所积累的大量数据,采用 XGBoost 算法建立 FeO 含量预测模型,以指导生产工作人员及时调整配料方案和设备参数。李一帆等^[52]对烧结矿与混合矿的化学成分进行了细致的相关性分析。选取了具有显著相关性的化学成分作为预测模型的关键输入变量,构建了随机森林预测模型,专门用于预测烧结矿中的 FeO 含量。预测准确率为 90% 以上,为烧结矿化学成分的精准控制提供了强有力的技术支持。NIU 等^[53]使用了随机森林和 XGBoost 两种集成算法,对烧结矿的化学成分进行了建模和预测,预测结果表明,以原料的化学成分作为训练参数,两种集成算法均能实现较小的均方误差(MSE)和平均绝对误差(MAE)值,在加入烧结工艺参数和燃料参数作为训练参数后,每种化学成分的 MAE 和 MSE 均有所降低,预测命中率也有所提高。LI 等^[54]应用多模型集成预测模型对烧结过程中 FeO 含量进行预测,使用实际烧结生产数据进行的验证强调了 FeO 模型预测的可靠性、精确性和有效性。

关于基于集成学习烧结机尾图像识别 FeO 含量预测模型没有相关的文献报道。随着图像数据维度的增加,集成学习算法因其在处理复杂数据集方面的优势,有望在烧结矿 FeO 含量预测方面提供突破性的成果。随着计算能力的显著提升,这些算法的应用前景广阔,值得进一步探索。

3 结论与展望

本研究综述了烧结矿 FeO 含量预测的多种算法模型,包括经典机器学习、协同优化算法、深度学习以及集成算法。通过对工艺流程参数、机

尾图像识别和图像-参数协同三个维度的分析,发现:

(1) 经典机器学习算法在预测烧结矿 FeO 含量方面具有一定的准确性,但可能在处理复杂数据集时遇到性能瓶颈。

(2) 协同优化算法通过结合多种优化技术,提高了模型的泛化能力和预测精度。

(3) 深度学习模型,尤其是基于图像识别的算法,展现出处理高维数据和捕捉复杂特征的强大能力,但对数据量和计算资源有较高要求。

(4) 集成算法通过融合多个模型的优势,提高了预测的鲁棒性和准确性。

尽管已有大量研究,但烧结矿 FeO 含量预测领域仍存在进步空间:

(1) 数据样本的扩展与优化: 现有研究中数据样本数量有限,限制了模型的泛化能力。未来的研究应利用大数据分析技术,实时处理和分析大量数据流,以提高模型的自适应性和在线学习能力。这将为快速响应的烧结矿 FeO 含量预测提供有力支持。

(2) 集成学习算法的应用: 集成学习技术已被证明能显著提升预测性能。建议将集成学习技术应用于烧结矿 FeO 含量预测,以增强模型的鲁棒性和准确性。随着深度学习技术的不断进步,预计未来将开发出更加复杂的神经网络模型,这些模型将整合图像、声音、温度等多模态数据特征,以实现更精准的预测。将深度神经网络与集成学习相结合,有望充分利用深度学习在特征提取方面的优势,并通过集成多个模型的预测结果来提高整体性能。这种策略不仅可以增强模型的鲁棒性,减少过拟合风险,还能解决单一深度神经网络可能遇到的难题。

参考文献:

- [1] 石烟翠. 烧结矿 FeO 含量的研究[J]. 烧结球团, 2004 29(3): 19-22.
SHI Yanhui. Study on the sinter FeO content[J]. Sintering and Pelletizing 2004 29(3): 19-22.
- [2] 尹德,李秋梅. 烧结矿 FeO 影响因素的研究和生产实践[J]. 烧结球团,1999 24(3): 33-35.
YIN De,LI Qiumei. Research on the influencing factors

- of FeO in sintered ore and production practice[J]. Sintering and Pelletizing ,1999 ,24(3) :33 - 35.
- [3] 张明 ,刘子瑜 . 重铬酸钾滴定法测定铁矿石中亚铁含量[J]. 理化检验:化学分册 ,2013 ,49(12) :1514.
ZHANG Ming ,LIU Ziyu. Determination of ferrous content in iron ore by potassium dichromate titration method[J]. Physical Testing and Chemical Analysis (Part B: Chemical Analysis) ,2013 ,49(12) :1514.
- [4] ROBERTS J ,BURSTEN J R S ,RISKO C. Genetic algorithms and machine learning for predicting surface composition , structure , and chemistry: A historical perspective and assessment [J]. Chemistry of Materials , 2021 ,33(17) :6589 - 6615.
- [5] DI LASCIO E ,GEREBTZOFF G ,RODRÍGUEZ-PÉREZ R. Systematic evaluation of local and global machine learning models for the prediction of ADME properties [J]. Molecular Pharmaceutics ,2023 ,20(3) :1758 - 1767.
- [6] LI X ,LIU X J ,LI H Y ,et al. Research on sinter quality prediction system based on granger causality analysis and stacking integration algorithm [J]. Metals ,2023 ,13(2) :419.
- [7] 张军红 ,谢安国 ,沈峰满 . 烧结矿质量预测的 BP 网络模型[J]. 鞍山钢铁学院学报 ,2001 ,24(6) :406 - 408.
ZHANG Junhong ,XIE Anguo ,SHEN Fengman. BP network model for forecasting sinter quality [J]. Journal of Anshan Institute of Iron and Steel Technology ,2001 ,24(6) :406 - 408.
- [8] 彭坤乾 . 烧结料层温度场模拟模型和烧结矿质量优化专家系统的研究[D]. 长沙:中南大学 ,2011.
PENG Kunqian. Simulation model of sinter bed temperature field and experts system of sinter quality optimization [D]. Changsha: Central South University , 2011.
- [9] YAMAOKA H ,KAWAGUCHI T. Development of a 3-D sinter process mathematical simulation model [J]. ISIJ International ,2005 ,45(4) :522 - 531.
- [10] OOI B Y ,LEE W K ,SHUBERT M J W ,et al. A flexible and reliable Internet-of-things solution for real-time production tracking with high performance and secure communication [J]. IEEE Transactions on Industry Applications ,2023 ,59(3) :3121 - 3132.
- [11] 张舒 ,高为民 . 人工神经网络在烧结矿指标预测中的应用[J]. 烧结球团 ,2001 ,26(4) :6 - 10.
ZHANG Shu ,GAO Weimin. Application of neural networks in the prediction of sinter quality [J]. Sintering and Pelletizing ,2001 ,26(4) :6 - 10.
- [12] 宋强 . 基于 BP 神经网络和灰色神经网络的烧结矿化学成分预测模型研究[D]. 昆明:昆明理工大学 ,2006.
SONG Qiang. Research on the chemical composition prediction model of sintered ore based on BP neural network and grey neural network [D]. Kunming: Kunming University of Science and Technology ,2006.
- [13] 陈伟 ,张惠娟 ,王宝祥 ,等 . 基于神经网络的烧结矿综合性能预测[J]. 河北联合大学学报(自然科学版) , 2014 ,36(3) :23 - 26.
CHEN Wei ,ZHANG Huijuan ,WANG Baoxiang ,et al. Predictive model of the sinter comprehensive performance base on neural network [J]. Journal of Hebei United University(Natural Science Edition) ,2014 ,36(3) :23 - 26.
- [14] 龙红明 ,范晓慧 ,陈许玲 ,等 . 基于神经网络预报的烧结矿化学成分控制专家系统[J]. 北京科技大学学报 ,2006 ,28(9) :867 - 870.
LONG Hongming ,FAN Xiaohui ,CHEN Xuling ,et al. Expert system for controlling sinter chemistry based on neural network prediction [J]. Chinese Journal of Engineering ,2006 ,28(9) :867 - 870.
- [15] 张帆 ,魏国 ,庞巍 ,等 . 对烧结矿 FeO 含量预测的数学模型研究[J]. 材料与冶金学报 ,2013 ,12(3) :159 - 162.
ZHANG Fan ,WEI Guo ,PANG Wei ,et al. A study on mathematical model of prediction of FeO content in the sintering ore [J]. Journal of Materials and Metallurgy , 2013 ,12(3) :159 - 162.
- [16] 蒋大军 . 运用 ARIMA 模型预测烧结矿成分[J]. 烧结球团 ,2007 ,32(4) :24 - 30.
JIANG Dajun. Forecasting sinter component with ARIMA model [J]. Sintering and Pelletizing ,2007 ,32(4) :24 - 30.
- [17] LI Z P ,ZHU J ,YI L Z ,et al. Data mining based IBBOA-BP sintering endpoint prediction model [C]//2022 IEEE 10th International Conference on Computer Science and Network Technology. Piscataway: IEEE ,2022: 80 - 84.
- [18] JIANG Z H ,GUO Y H ,PAN D ,et al. Polymorphic measurement method of FeO content of sinter based on

- heterogeneous features of infrared thermal images [J]. IEEE Sensors Journal 2021 21(10):12036-12047.
- [19] 周志远. 基于 BP 神经网络的烧结矿 FeO 含量预测系统的设计与研究 [D]. 马鞍山: 安徽工业大学 2021. ZHOU Zhiyuan. Design and research of FeO content prediction system of sinter based on BP neural network [D]. Maanshan: Anhui University of Technology 2021.
- [20] 周德玉. 基于 RBFNN 的烧结矿氧化亚铁含量实时检测系统的研究 [D]. 合肥: 安徽大学 2011. ZHOU Deyu. The research on sinter iron protoxide content of real-time detection system based on RBFNN [D]. Hefei: Anhui University 2011.
- [21] 王翊. 烧结矿 FeO 含量实时预测系统的关键技术研究 [D]. 重庆: 重庆大学 2007. WANG Yi. The key technology study on FeO content of sinter [D]. Chongqing: Chongqing University 2007.
- [22] 周后伟. 基于图像处理及模糊 C 均值聚类的烧结矿 FeO 含量实时检测系统的研究 [D]. 合肥: 安徽大学, 2012. ZHOU Houwei. The research of sinter FeO real-time content detection system based on image processing and fuzzy C-means clustering [D]. Hefei: Anhui University 2012.
- [23] 张兆磊. 基于机器视觉的烧结矿 FeO 含量判断方法研究 [D]. 沈阳: 东北大学 2015. ZHANG Zhaolei. Research on judging method for FeO content in sinter based on machine vision [D]. Shenyang: Northeastern University 2015.
- [24] 张乐文. 基于机尾断面形态及过程参数多参量分析的烧结矿质量在线判定系统的研发 [D]. 合肥: 安徽大学 2017. ZHANG LeWen. The research of online judgment system for sinter quality based on multi-parameter analysis of tail section form and process [D]. Hefei: Anhui University, 2017.
- [25] OREŠKI D, PIHIR I, VIŠNJIĆ D. Comparative analysis of machine learning algorithms on data sets of different characteristics for digital transformation [C]//2023 46th MIPRO ICT and Electronics Convention. Piscataway: IEEE 2023:1428-1433.
- [26] 方怡静, 蒋朝辉, 黄良, 等. 基于知识与 AW-ESN 融合的烧结过程 FeO 含量预测 [J]. 自动化学报, 2024, 50(2):282-294. FANG Yijing, JIANG Zhaohui, HUANG Liang, et al. FeO content prediction in sintering process based on fusion of data-knowledge and AW-ESN [J]. Acta Automatica Sinica 2024 50(2):282-294.
- [27] 史振杰, 董兆伟, 孙立辉, 等. 基于灰狼算法 SVR 的烧结矿 FeO 含量预测 [J]. 河北省科学院学报, 2019, 36(4):1-6. SHI Zhenjie, DONG Zhaowei, SUN Lihui, et al. Prediction of FeO content in sintered ore based on grey wolf algorithm SVR [J]. Journal of the Hebei Academy of Sciences 2019 36(4):1-6.
- [28] 邵长江. 基于磁力法和 SSA-BP 的烧结矿 FeO 含量在线检测系统研究 [D]. 武汉: 武汉工程大学 2023. SHAO Changjiang. Research on online detection system of FeO content in sinter based on magnetic force method and SSA-BP [D]. Wuhan: Wuhan Institute of Technology, 2023.
- [29] 张智峰, 刘小杰, 李欣, 等. 基于 MIV-GA-BP 模型预测烧结矿 FeO 含量 [J]. 中国冶金, 2022, 32(10):75-81. ZHANG Zhifeng, LIU Xiaojie, LI Xin, et al. Prediction of FeO content in sinter based on MIV-GA-BP model [J]. China Metallurgy 2022 32(10):75-81.
- [30] 惠佳豪, 邢相栋, 郑兆颖, 等. 基于 KPCA 和 Logistic-SSA-BP 的烧结矿 FeO 含量预测 [J]. 钢铁研究学报, 2024, 36(6):717-726. HUI Jiahao, XING Xiangdong, ZHENG Zhaoying, et al. Prediction of FeO content in sinter based on KPCA and logistics-SSA-BP [J]. Journal of Iron and Steel Research, 2024 36(6):717-726.
- [31] 张军红, 沈峰满, 谢安国. G-BP 算法在烧结矿 FeO 指标预测中的应用 [J]. 东北大学学报, 2002, 23(11):1073-1075. ZHANG Junhong, SHEN Fengman, XIE Anguo. The application of G-BP in FeO content prediction during sintering [J]. Journal of Northeastern University, 2002, 23(11):1073-1075.
- [32] 吉训生, 荆田田, 熊年昀. 烧结矿 FeO 含量预测研究 [J]. 计算机仿真, 2015, 32(10):318-322. JI Xunsheng, JING Tiantian, XIONG Nianyun. Study on FeO content of sinter prediction [J]. Computer Simulation, 2015 32(10):318-322.
- [33] 张学锋, 张功辉, 周志远, 等. 基于改进 BP 神经网络的烧结矿 FeO 含量预测 [J]. 冶金自动化, 2023, 47(3):100-108. ZHANG Xuefeng, ZHANG Gonghui, ZHOU Zhiyuan,

- et al. Prediction of FeO content in sinter based on improved BP neural network [J]. *Metallurgical Industry Automation* 2023 47(3): 100–108.
- [34] SHRESTHA A, MAHMOOD A. Review of deep learning algorithms and architectures [J]. *IEEE Access* 2019 7: 53040–53065.
- [35] LIU S, LIU X J, LYU Q, et al. Comprehensive system based on a DNN and LSTM for predicting sinter composition [J]. *Applied Soft Computing*, 2020, 95: 106574.
- [36] LI Y X, YANG C J, SUN Y X. Dynamic time features expanding and extracting method for prediction model of sintering process quality index [J]. *IEEE Transactions on Industrial Informatics* 2022 18(3): 1737–1745.
- [37] 閻光磊, 吴朝霞, 刘梦园, 等. 基于 GMM-KNN-LSTM 的烧结矿化学指标预测 [J]. *东北大学学报(自然科学版)* 2024 45(3): 314–322.
- XIA Guanglei, WU Zhaoxia, LIU Mengyuan, et al. Prediction of sinter chemical indexes based on GMM-KNN-LSTM [J]. *Journal of Northeastern University (Natural Science)* 2024 45(3): 314–322.
- [38] YANG C, YANG C J, LI J F, et al. Forecasting of iron ore sintering quality index: A latent variable method with deep inner structure [J]. *Computers in Industry*, 2022, 141: 103713.
- [39] GALLAGHER L, MALLIA A, CULPEPPER J S, et al. Feature extraction for large-scale text collections [C]// *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. New York: ACM, 2020: 3015–3022.
- [40] WANG F B, LIU H F, HE J H. Fast adaptive fuzzy enhancement and correlation features analysis of flame image of sintering section [J]. *Signal, Image and Video Processing* 2021 15(3): 539–546.
- [41] 张宁. 基于机尾红外图像的烧结矿 FeO 含量预测模型研究 [D]. 中南大学 2022.
- ZHANG Ning. Study on the prediction model of FeO content in sinter based on infrared image of machine tail [D]. Changsha: Central South University 2022.
- [42] 张学锋, 闻亦昕, 熊大林, 等. 基于双向长短时记忆网络模型预测烧结矿 FeO 含量 [J]. *冶金自动化* 2023, 47(6): 85–92.
- ZHANG Xuefeng, WEN Yixin, XIONG Dalin, et al. Prediction of FeO content in sinter based on BiLSTM model [J]. *Metallurgical Industry Automation*, 2023, 47(6): 85–92.
- [43] BAI X H, CHEN C L, LIU W, et al. Data-driven prediction of sinter composition based on multi-source information and LSTM network [C]// *2021 40th Chinese Control Conference*. Piscataway: IEEE, 2021: 3311–3316.
- [44] 任玉辉, 曾小信, 李旭东. 基于机器视觉的烧结矿 FeO 含量在线感知 [J]. *烧结球团* 2024 49(3): 53–59.
- REN Yuhui, ZENG Xiaoxin, LI Xudong. Online perception on FeO content in sinter based on machine vision [J]. *Sintering and Pelletizing* 2024 49(3): 53–59.
- [45] 张学锋, 闻亦昕, 熊大林, 等. 面向智能烧结的机尾断面烧结矿 FeO 预测研究 [J]. *钢铁研究学报*, 2024, 36(5): 580–588.
- ZHANG Xuefeng, WEN Yixin, XIONG Dalin, et al. Research on FeO prediction of sintered ore in machine tail section for intelligent sintering [J]. *Journal of Iron and Steel Research* 2024 36(5): 580–588.
- [46] 匡朝辉, 范晓慧, 赵利明, 等. 烧结矿 FeO 含量在线智能检测系统开发与应用 [J]. *烧结球团* 2023 48(6): 157–163.
- KUANG Zhaohui, FAN Xiaohui, ZHAO Liming, et al. Development and application of online intelligent detection system for FeO content of sinter [J]. *Sintering and Pelletizing* 2023 48(6): 157–163.
- [47] 丁谦. 基于深度学习的烧结矿 FeO 含量预测方法研究 [D]. 中南大学 2022.
- DING Qian. Research on prediction method of FeO content in sinter based on deep learning [D]. Changsha: Central South University 2022.
- [48] ZHOU P, GAO B H, ZHAO C H, et al. Heterogeneous data-driven measurement method for FeO content of sinter based on deep learning and tensor decomposition [J]. *Control Engineering Practice* 2023 134: 105479.
- [49] YANG C, YANG C J, ZHANG X M, et al. Multisource information fusion for autoformer: Soft sensor modeling of FeO content in iron ore sintering process [J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(12): 11584–11595.
- [50] DIETTERICH T G. Machine-learning research four current directions [J]. *Ai Magazine*, 1997, 18: 97–136.

(下转第 37 页)

8 - 15.

XIAO Chengyong , LI Qing , WANG Li , et al. Edge segmentation experimental method of iron ore pellets based on CBAM-U-net[J]. Sintering and Pelletizing , 2022 ,47(2) : 8 - 15.

- [11] 李江昀 杨志方 郑俊锋, 等. 深度学习技术在钢铁工业中的应用[J]. 钢铁 2021 ,56(9) : 43 - 49.

LI Jiangyun , YANG Zhifang , ZHENG Junfeng , et al. Applications of iron and steel industry with deep learning technologies [J]. Iron & Steel 2021 ,56(9) : 43 - 49.

- [12] 李腾宇 寇子明 吴娟, 等. 超千米深井提升机可视化监测系统应用[J]. 煤炭学报 ,2020 ,45(S2) : 1069 - 1078.

LI Tengyu , KOU Ziming , WU Juan , et al. Monitoring system of the hoist in the over kilometer deep shaft [J]. Journal of China Coal Society ,2020 ,45(S2) : 1069 - 1078.

- [13] 袁志龙 陈波 王月明. 烧结机台车车轮踏面缺陷检

测系统设计与实现[J]. 烧结球团 2023 ,48(3) : 70 - 75.

YUAN Zhilong , CHEN Bo , WANG Yueming. Design and implementation of defect detection system for tire tread of sintering machine trolley [J]. Sintering and Pelletizing , 2023 ,48(3) : 70 - 75.

- [14] 孙耀泽 高军伟. 基于 DeepLabv3 + 的轮对踏面损伤分割算法[J]. 电子测量技术 ,2022 ,45(23) : 113 - 118.

SUN Yaoze , GAO Junwei. Image segmentation of wheel set tread damage based on DeepLabv3 + [J]. Electronic Measurement Technology 2022 ,45(23) : 113 - 118.

- [15] YE J Q , STEWART E , CHEN Q Y , et al. A vision-based method for line-side switch rail condition monitoring and inspection [J]. Proceedings of the Institution of Mechanical Engineers Part F: Journal of Rail and Rapid Transit 2022 ,236(8) : 986 - 996.

(上接第 30 页)

- [51] 吕庆 刘月明 张振峰, 等. 基于承钢生产数据预测烧结矿 FeO 含量[J]. 钢铁研究学报 ,2018 ,30(12) : 957 - 962.

LÜ Qing , LIU Yueming , ZHANG Zhenfeng , et al. Prediction of FeO content in sinter based on production data of Chengde Steel Mill [J]. Journal of Iron and Steel Research 2018 ,30(12) : 957 - 962.

- [52] 李一帆 李锦祥 杨锦堂, 等. 基于 BO-RF 的烧结矿化学成分预测模型研究[J]. 烧结球团 2023 ,48(6) : 109 - 115.

LI Yifan , LI Jinxiang , YANG Jintang , et al. Research on

chemical composition prediction model of sinter based on BO-RF [J]. Sintering and Pelletizing ,2023 ,48(6) : 109 - 115.

- [53] NIU L L , LIU Z J , ZHANG J L , et al. Prediction of sinter chemical composition based on ensemble learning algorithms [J]. Journal of Sustainable Metallurgy ,2023 ,9(3) : 1168 - 1179.

- [54] LI X M , WANG B R , YU Z H , et al. Identification of working conditions and prediction of FeO content in sintering process of iron ore fines [J]. Journal of Iron and Steel Research International 2024 ,31(9) : 2090 - 2100.