

DOI:10.13228/j.boyuan.issn1001-0963.20220289

基于工业大数据的智能化高炉炼铁技术研究进展

石 泉, 唐 珏, 储满生
(东北大学冶金学院, 辽宁 沈阳 110819)

摘 要:高炉冶炼过程是最典型的“黑箱”过程,其复杂性和不确定性为高炉稳定顺行带来了巨大挑战。但高炉炼铁拥有丰富的数据资源,数据科学、智能技术的快速发展,为解决高炉炼铁过程中不确定性问题提供了有效手段。围绕大数据技术在高炉炼铁中的应用,从高炉数据预处理、高炉关键指标预测、高炉炉况评价和高炉指标优化 4 个方面对现阶段智能化高炉炼铁技术进行总结与分析。在高炉数据预处理方面,应综合考虑数据问题和算法特性,科学选择数据处理方法,才能使高炉数据质量得到有效改善。在高炉关键指标预测方面,需要先消除高炉参数间时滞性的影响,并筛选出有效的输入特征,才能保证预测模型的准确率。在高炉炉况评价方面,需要构建数据信息与工艺机制融合的高炉智慧模型,才能够实现高炉炉况的科学评价。在高炉参数优化控制方面,应该以低风险、低经济、高回报作为优化目标,在追求优化效果的同时还应综合考虑现场操作的可行度和操作成本。要实现高炉智能化生产,还需要研究者们继续探索和完善。

关键词:工业大数据; 数据治理; 机器学习; 高炉炼铁

中图分类号:TF5,TF3 **文献标志码:**A **文章编号:**1001-0963(2022)12-1314-11

Research progress of intelligent blast furnace ironmaking technology based on industrial big data

SHI Quan, TANG Jue, CHU Mansheng
(College of Metallurgical Engineering, Northeastern University, Shenyang 110819, Liaoning, China)

Abstract: Blast furnace ironmaking was the most typical "black box" process, its complexity and uncertainty would bring the great challenges. However, blast furnace ironmaking is rich in data resources, and the rapid development of data science and intelligent technologies provides an effective means to address the uncertainty in the blast furnace ironmaking process. This work focused on the application of artificial intelligence technology in blast furnace ironmaking. And the current intelligent blast furnace ironmaking technology from four aspects were summarized and analyzed, including the data governance, the key indicator forecast, furnace status evaluation and parameter optimization of blast furnace. In order to effectively improve the quality of blast furnace data, data problems and algorithmic characteristics should be fully considered in the scientific selection of data processing methods. In the prediction of blast furnace key indicators, the effect of time delay among blast furnace parameters should be eliminated and effective input features should be screened out to improve the accuracy of the prediction model. In the evaluation of blast furnace status, data information and process theory are deeply integrated to achieve scientific evaluation of blast furnace condition. In the aspect of blast furnace parameter optimization, low risk, low economy and high return should be taken as the optimization objectives, and the feasibility of field operation and operation cost should be considered comprehensively while pursuing the optimization effect. To achieve intelligent blast furnace production, a lot of research work need to be explored and perfected by scholars.

Key words: big industrial data; data governance; machine learning; BF ironmaking

钢铁工业是典型的资源能源密集型流程工业，是国民经济支柱产业。高炉炼铁作为主流钢铁生产

流程的核心工序,高炉稳定、顺行、高效、低耗关系到整个钢铁企业的经济效益,是钢铁生产节能减排、降本增效的关键环节。目前,高炉炼铁工艺技术水平已发展到瓶颈,难以有较大的突破;随着数据科学和信息技术的蓬勃发展,将大数据技术逐步应用于高炉炼铁过程中,充分利用炼铁系统积累的数据深度解析生产过程,研发基于大数据的智能化高炉炼铁技术,挖掘原燃料条件、工艺操作制度与高炉运行状态、铁水质量之间的逻辑关系,将大数据、机器学习与冶炼机制、经验知识相结合,建立高效、科学的高炉冶炼智慧模型,有望解决高炉数据难表征、状态难描述、操作难调控的传统难题,是实现高炉炼铁节能减排和智能化冶炼的重要手段。

为了积极推动智能化技术实施,中国已出台多项决策部署,如:《中国制造 2025》提出构建数字化智慧钢厂,钢铁业面临数字化转型升级的迫切需求。宝钢、首钢、武钢、韶钢、攀钢等钢铁企业均制定了智能制造规划,建设工业数据中心与智能化技术研发平台。然而中国现有成果相较于发达国家应用仍有较大差距,尤其是炼铁工序存在基础自动化薄弱、数据采集与管理难度大、冶炼过程是典型黑箱等问题,智能化高炉炼铁技术的研发与应用还有较大提升空间。

1 机器学习算法介绍

随着大数据技术的不断发展,使得支持向量机、随机森林和神经网络等机器学习算法在钢铁行业方面的应用取得了不错的效果。本节对工业数据建模过程中常用到的机器学习算法进行介绍。

(1)支持向量机是在统计学理论的基础上得出的机器学习算法,它在解决小样本、非线性和高维模式识别问题上表现出许多独特的优势。随着支持向量机的不断发展,冶金行业的研究人员把支持向量机应用于各种参数的预测。文献^[1]基于支持向量回归与极限学习机 2 种算法对铁水温度构建预测模型,基于支持向量回归算法构建的预测模型较优,±10℃ 误差范围内的命中率高达 94%,比极限学习机预测模型高了 5.5%。文献^[2]基于支持向量回归建立了高炉煤气利用率预测模型,并预测结果与多层感知器模型进行对比,结果表明,支持向量回归模型在预测 1 和 2 h 后的煤气利用率时精确度更高,达到了更好的预测效果。

(2)梯度提升是一种常用于回归和分类问题的集成学习算法和机器学习技术,以弱预测模型集合的形式产生预测模型。因其强大的学习能力,尤其

是在表格数据中的表现,在高炉参数预测领域同样备受关注。文献^[3]选用 Xgboost 模型对高炉透气性进行预测,结果表明,Xgboost 相较于随机森林和线性回归模型具有较大优势,模型在误差±1.5%范围内的准确率达到 94.27%,能够准确预测下一小时透气性指数。文献^[4]提出一种基于梯度提升决策树算法的焦炭预测模型,结果表明基于梯度提升决策树的焦炭质量预测模型相较于线性回归模型、随机森林模型,决策树模型误差小、准确率高。文献^[5]基于梯度提升决策树(GBDT)算法建立了烧结终点预测模型,采用网格搜索和交叉验证的方法对模型参数进行了优化,取得了良好的性能。

(3)神经网络是机器学习中最重要分支,近年来,深度学习发展得如火如荼,各领域的研究成果都非常丰硕。高炉炼铁是一个动态的时间序列,高炉反应的过程又是渐变的,即当前炉况与历史炉况相互关联,这就要求神经网络能够动态记忆历史信息,并在学习新信息的同时保持历史信息的持久性。因此,将长短期记忆神经网络在高炉参数预测的研究中取得了显著成效。文献^[6]为实现高炉炼铁过程中铁水硅含量的准确预测,引入神经网络时间序列模型实现了高炉铁水硅含量智能预报,经测试在预测结果置信区间 95%以上的条件下达到了 0.2%以下的预测绝对误差。文献^[7]对比了正常工况下长短期记忆模型(LSTM)和季节性差分自回归模型(SARIMA)不同预测步数的高炉煤气发生量预测效果,结果表明 LSTM 模型的预测精度普遍高于 SARIMA 模型。

(4)集成学习通过构建和组合多个学习器来完成学习任务。通过组合多个学习器,通常可以获得比单一学习器更显著的泛化性能,学习器的预测效果是随着数据集的不同而变化的,集成学习可以提高学习系统的泛化性能,并增强学习系统的稳定性^[8]。文献^[9]为提高煤气利用率的预测精度,提出一种基于 CEEMDAN-SVM-LSTM 的组合模型对其进行预测。用长短时间记忆人工神经网络(LSTM)和支持向量机(SVM)分别对分解的高频模态和低频模态进行预测,最后将模型组合建立了煤气利用率的组合预测模型。结果表明该组合模型与单一的 SVM 模型和 LSTM 预测模型对比,组合模型的精度更高。

2 大数据技术在高炉炼铁中的应用

大数据技术在高炉炼铁中的应用主要体现在高炉数据预处理、高炉关键指标预测、高炉炉况状态评

价和高炉关键指标优化 4 个方面,主要研究内容如图 1 所示。

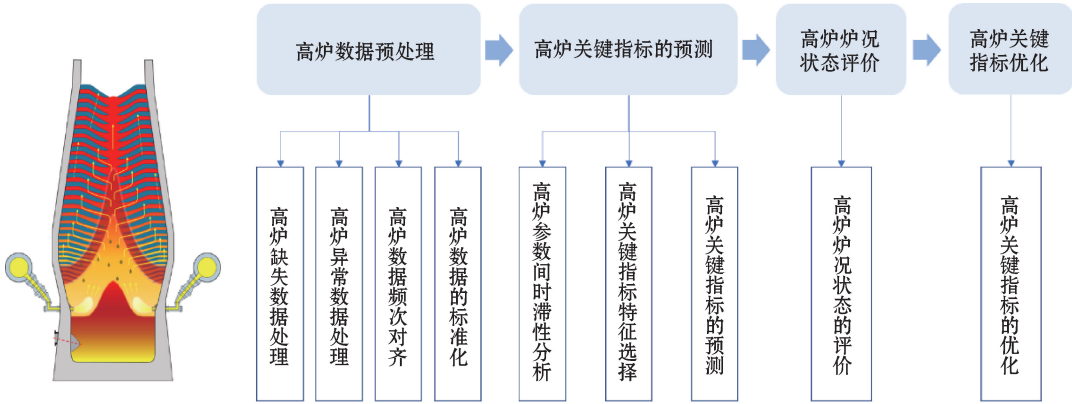


图 1 大数据技术在高炉炼铁中的应用研究内容
Fig. 1 Application of big data technology in blast furnace ironmaking

2.1 高炉数据预处理

高炉炼铁系统数据具有来源多、范围广、数量大、维度高、频次多、噪声多、质量低等特点,如何完成高炉复杂数据的清洗与整合,是实现高炉炼铁系统智能化的基础。此过程主要包括缺失值和异常值处理、数据标准化以及数据集成。

2.1.1 高炉缺失数据处理

高炉炼铁数据缺失问题主要是由于高炉生产过程中由于传感器失灵、人为操作失误、数据库存储故障等因素造成的部分数据丢失^[10]。处理数据缺失的方法主要有 2 种:一是删掉缺失数据所在的数据项,二是对缺失数据进行填补。填补缺失值可以保证数据信息的完整性,有利于建立完整、系统的数据挖掘模型。

(1)少量缺失或大量缺失。如果缺失数据量占数据集总量的比例低于 5%可采取直接删除法,该种处理办法不会影响数据的有效性,且处理效率高^[10]。如果数据缺失量较大,数据填补难度将十分巨大,当数据的缺失率超过 60%时,无论采用何种办法,其所研究的数据都没有任何使用价值^[11]。直接删除法在特定情况下是一种直接、高效的处理手段,但此种方法会造成一部分数据资源的流失。

(2)间断性数据缺失。间断性数据缺失是指数据间断性的在短时间内出现数据缺失问题。由于缺失时间短,尤其当数据频次较高时,在此范围内数据波动不会发生明显变化,可以通过最近邻值法等对缺失值进行填补;如果是压力、温度等时间序列数据,由于时序性数据在一定范围内的波动是可预估的,因此可以采用插值法^[12-14];如果与其他变量数据存在相关关系的数据(如透气性和压差),可采用

机器学习法建立二者的函数关系完成缺失数据的填补^[15]。

(3)连续性数据缺失。连续性数据缺失是指数据在长时间内连续出现数据缺失问题。由于长时间缺失导致在此范围内数据实际变化趋势无法被估计,插值法填补不能取得理想的效果。但是,如果存在其密切相关的完整变量数据,通过完整数据寻找数据之间的内在规律,即便出现长时缺失也可通过数据间的内在关系采用机器学习法对缺失数据进行预测填补^[16-17]。

2.1.2 高炉异常数据处理

异常数据的处理与分析也是数据治理中的一个重要步骤。工业大数据中往往由于各种原因,导致收集到的数据中有一些偏离正常范围的异常值点,忽略异常数值的存在往往对数据分析结果是不利的^[18-19]。然而,由于高炉正常炉况和异常炉况的数据差异很大,因此在进行异常数据检测时需要根据炉况状态是否异常而有所区别。

(1)超出工艺范围的异常值。可以通过最大最小值判断这个变量的取值是否超过了合理的范围,不合常理的为异常值。例如在正常炉况下,可以依据高炉现场操作方针的参数范围制定数据筛选条件。

(2)算法识别的异常值。通过统计学方法或机器学习的方法判别,目前从数据的统计学性质出发进行高炉异常数据识别的技术手段主要有以下几种:拉依达准则(3σ法)、箱型图等方式^[15,19-23]。此类方法在一定程度上剔除了异常值且效率高,但异常值上下限的确定还是依赖操作人员的经验,例如箱型图上下四分位差的系数。并且 3σ 准则要求数

据近似正太分布,并不是所有的数据都适用。从机器学习的角度出发,目前所采用的主要有聚类算法、孤立森林法等。利用聚类算法进行异常值识别主要是选用合适的算法将数据分为各簇,簇与簇之前的距离大而簇内部的数据间的距离小,因此可以找出包含大部分正常数据的簇,进而识别异常值^[24-25]。而孤立森林所采用的思想是利用二叉树的特点将全部数据遍历,将数据按大小分在二叉树的两侧,根据某点数据被区分出来时所涉及的二叉树的数量进行异常值识别,所涉及的二叉树数量越小则该点数据是异常值的可能性越大^[26-27]。利用机器学习进行异常值识别的识别率高但需要消耗的时间也较多。

(3)异常值的处理。在识别出离群值后还需要观察同时刻其他参数的数据是否也存在异常,以此甄别产生异常数据的原因是高炉炉况异常引起,还是数据本身异常。对于无效异常值(错误值或离群值),一般删除含有异常值的记录,或者将其视为缺失值,然后按照缺失值的处理方法进行填补;对于有效异常值(即在特定炉况条件下属于合理值),一般需要对此类数据进行保留。值得注意的是不同检测方法对数据具有不同的要求,而高炉数据复杂,异常值的种类较多,因此不能仅仅采用单一的异常值识别方法,应综合考虑数据问题和算法自身特点,科学选择数据处理方法。

2.1.3 高炉数据频次对齐

高炉炼铁过程中不同数据源存在数据采集频次不同的问题,大大提升了高炉不同工序数据整合的难度。例如质检数据和监测数据,前者的数据频次一般为 2~4 h,而后者数据频次多为分钟级或秒级。当数据存在不同频率,通常的方法有 2 种,一种是根据低频数据的周期对高频数据做平均或累加,或者根据低频数据的周期选取高频数据的最新值^[28];另外一种是将低频数据映射到高频时间索引上,缺失值用插值补全^[29]。将混频数据转换为相同频率的数据后,使用相同频率的数据进行分析或建模。但是,这种方法由于人为的数据累加或内插会引起的原始数据内含的信息量增加和丢失。相关学者^[30-32]提出直接使用混频数据来构建混频数据模型,这种方式建立的模型充分利用高频数据中的信息,避免了由于数据处理过程中人为处理而导致的数据信息虚增与丢失,在一定程度上可以提高宏观模型估计有效性和预测的准确性。有效解决了不同工序由于数据采集周期不同导致的数据样本不均衡和不同工序数据无法直接匹配的问题。

2.1.4 高炉数据标准化

钢铁工业中流程较多,影响产品质量和性能的因素错综复杂,每个指标的性质、量纲、数量级、可用性等特征均可能存在差异,导致无法直接用其分析研究对象的特征和规律。如果直接用指标原始值进行分析,数值较高的指标在综合分析中的作用就会被放大,相对地,会削弱数值水平较低的指标的作用。以高炉为例,风量的单位是 m^3/min ,燃料比单位是 kg/t ,热负荷的单位是 MJ/h ,且它们的数量级相差较大,不利于模型计算分析,还会降低模型的预测精度。为了消除参数指标之间的量纲和取值范围差异的影响,需要对训练数据进行标准化处理,便于建立有效的机器学习模型。研究中最常用的数据标准化方法主要为 min-max 标准化法和 z-score 标准化法^[33-34]。

2.2 高炉关键指标预测

提前掌握高炉关键指标变化对操作者科学判断、准确调控高炉运行状态至关重要,通过大数据技术实现高炉关键指标的精准预测是高炉操作者科学判断高炉炉况动态变化的有效手段。研究较多的高炉关键预测指标主要有炉热(铁水硅含量和铁水温度)、焦比、煤气利用率、透气性等。由于高炉冶炼的复杂性,不同高炉关键指标的影响因素不同,并且不同冶炼条件下高炉关键指标的影响因素也会有所不同。另外,高炉参数之间存在不同程度的时间滞后性。因此,在建立预测模型之前需要进行时滞性分析和特征选择。

2.2.1 高炉参数间的时滞性分析

在高炉冶炼过程中,当炉长采取某项控制措施时,决策变量需要一段时间后才能起到控制作用,这种现象叫做滞后。现有方法大多是根据相关性系数或者人工经验的方法,得到最大相关性的某一确定的滞后时间。如安剑奇等^[35]采用灰色相对关联度分析方法分析了高炉操作与煤气利用率、铁水硅含量、高炉状态参数的时滞关系;李壮年等^[21]通过人工经验分别对当日、1 天、2 天后的控制参数赋予权重,对数据进行时效处理。但是在实际生产过程中,不同阶段或者不同工况下,参数的滞后时间具有不确定性,在一定范围内变化,且参数在这个范围内会有不同程度的波动。因此,此类方法可能会造成滞后时间不准确以及波动信息缺失,从而导致与实际炉况不符的现象。针对高炉炼铁生产过程数据大时滞现象,王玉涛等^[36]提出了一种时滞不确定信息的高炉参数时滞性分析方法,通过计算参数不同阶段

的滞后时间,得到参数的滞后时间范围,然后将工艺参数对应时滞范围内均值,方差作为模型输入,有效提高了模型预测准确率。

2.2.2 高炉关键指标的特征选择

从众多原燃料参数和操作参数中筛选出与高炉关键指标有显著关系的参数时,最常用的方法是通过特征选择技术实现高炉重要影响因素的筛选。特征选择方法主要分为基于特征排序和基于特征搜索 2 类。

(1)基于特征排序采用具体的评价准则给每个特征打分或设置一个阈值,选择排名前 k 个的特征,选择过程如图 2 所示。基于特征排序的评价准则常用的有 Pearson 相关系数、最大信息系数、主成分分析等。Pearson 相关系数是线性量化关系分析最常用方法之一,反应的是 2 个变量之间变化趋势的方向以及程度,其值范围为 $-1\sim 1$,0 表示 2 个变量不相关,正值表示正相关,负值表示负相关,值越大表示相关性越强。王振阳等^[1]依据 Pearson 相关系数提取了与铁水温度存在强线性相关的高炉参数,但考虑到 Pearson 系数不能有效地对非线性关系的参数进行提取,因此结合 Spearman 系数获取了显著影响铁水温度的特征参量。最大信息系数(MIC)是用来衡量 2 个参数之间的关联程度,线性或非线性关系,相较于 Pearson 相关系数而言有更高的准确度。最大互信息系数度量具有普适性,其

不仅可以发现变量间的线性函数关系,还能发现非线性函数关系。张笑凡^[37]使用 Pearson 相关系数初步挑选出与炉缸活性线性相关性强的特征,然后针对 Pearson 相关系数无法捕捉非线性关系的缺陷,使用了最大信息系数来衡量特征与炉缸活性之间的依赖关系,提取出与炉缸活性依赖性强的特征。这种特征选择方法效率高,因此在处理高维数据时,可在短时间内去除大量的无关特征。但是高炉冶炼过程复杂,高炉参数之间具有强耦合性,通过分析单因素对目标的影响程度选择特征,忽略了特征参数之间的相互作用对高炉经济指标的实际影响关系,因此基于特征排序的方法对高炉预测模型精度的提升是有限的。主成分分析主要思想是将 n 维特征映射到 k 维上,这 k 维是全新的正交特征也被称为主成分,是在原有 n 维特征的基础上重新构造出来的 k 维特征。主成分分析严格来说属于特征提取的一种方法,但也是通过对方差贡献率进行排序,选取排名靠前的主成分。刘代飞^[38]在进行高炉炉况预测建模时,利用主元分析对 108 维的温度场数据进行降维处理,以 86% 的信息提取度为准则,形成 20 维主元特征参数。但是,经过主成分分析构建的新特征物理意义与原始特征相差甚远,提取到的特征可解释性弱,这对指导高炉操作和异常炉况的原因分析等问题是非常不利的。

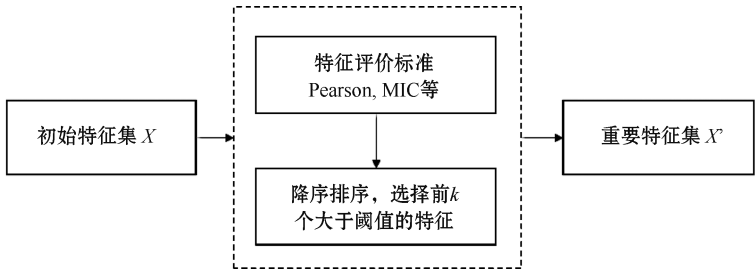


图 2 基于特征排序的特征选择过程

Fig. 2 Feature selection process based on feature ranking

(2)基于特征搜索属于一种特征组合策略,如图 3 所示,此过程中可以直接将模型预测精度或误差作为度量标准衡量特征子集的整体性能,最终获得近似的最优子集,要优于只估计单个特征得分的评价标准。如随机森林算法、XGBoost 和 LightGBM 中的特征贡献度排序是衡量每个特征重要性的有效方法^[39-41]。特征贡献度排序定义为对单个特征值进行随机洗牌时模型分数的下降,是在比较具有和不具有该特征时模型的预测精度,特征贡献度排序

可用于分析特征对输出变量的重要性。赵军等^[3]在建立高炉透气性指数预测模型过程中,以随机森林模型作为基模型,采取交叉验证法确定特征数量寻找最佳特征,筛选出冷风流量、鼓风动能、富氧流量等 14 个特征参数。遗传算法作为一种基于自然选择和群体遗传机制的搜索算法,也是处理特征选取任务最先进的算法之一。张照硕等^[42]基于遗传算法研究了不同的个体选择策略与种群更新策略的结合对监督学习算法预测准确率的影响,结果表明这

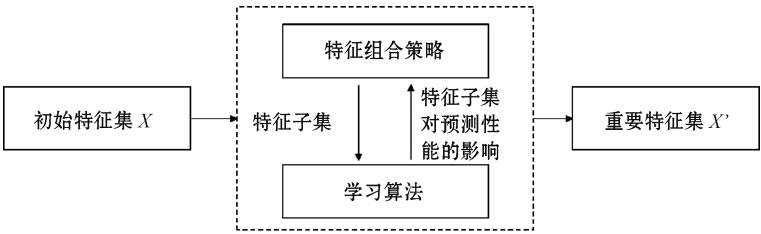


图 3 基于特征组合的特征选择过程

Fig. 3 Feature selection process based on feature combination

种方式比将所有特征用于学习的平均准确率更高。

在实际应用当中,可以将多种特征选择方法结合使用,以提高模型的效率和性能。如图 4 所示先通过基于特征排序去除无关特征,然后再通过基于特征组合选择最优特征集。值得注意的是,完全依赖数据算法有时也会造成重要信息的丢失,当某个重要参数一直被控制在合理范围时,由于数据波动较小,算法很有可能将其判定为无关参数而剔除。文献^[19,43]在基于高炉冶炼机制和专拣经验筛选特征基础上,采用特征选择技术在剩余特征集中进行筛选,通过机制与算法结合的方式完整地选择出了影响铁水质量的重要参数。文献^[44]结合遗传算法与冶金理论提出了一种可解释的特征构造方法,应用于铁水硅含量预测效果良好提高至 93%。更重要的是,通过构造的许多高质量特征中的共同成分揭示了过程变量和预测变量之间的内在关系。这些信息有助于高炉操作者对高炉冶炼过程的理解和控制。因此,应采取高炉工艺机制结合数据驱动算法共同完成影响参数的选取。

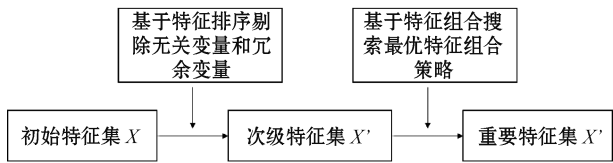


图 4 基于特征排序和特征组合的特征选择过程

Fig. 4 Feature selection process based on feature ranking and feature combination

2.2.3 高炉关键指标的预测

崔桂梅等^[45]通过支持向量机和 K-means 聚类进行结合,建立类别函数确定预测数据的类别,利支持向量机对聚类后的每一类数据进行预测,该方法铁水温度的预测精度较普通支持向量机有所提高。文献^[46]采用径向基函数的最小二乘支持向量机对铁水[Si]进行预测,采用多折交叉验证方法优化核

函数、正则化参数,取得了较好的预测效果。王文慧等^[47]建立了基于随机森林算法的高炉铁水硅质量分数预测模型,该研究结果表明不管是在炉况平稳还是在炉况有较大波动的情形下,随机森林算法都能获得较高的预测精度。张勇等^[48]采用相关分析法确定影响炉温的主要因素,基于时间序列的小波神经网络对铁水测温进行预测,较传统的 BP 神经网络的预测精度有所提高。刘小杰等^[49]通过构建 Adaboost 模型、决策树模型和随机森林模型对 2 h 后的铁水中硅含量进行预测,发现 Adaboost 模型预测的结果相比决策树模型和随机森林模型准确度更高,能够更好地对铁水硅含量进行捕捉预测。岳有军等^[50]采用粒子群算法对最小二乘支持向量机进行优化,用优化后的模型对高炉焦比进行预测,结果表明优化后的方法成功提高了入炉焦比的预测精度。周继程等^[51]利用神经网络预测生铁产量和燃料比,由于数据样本少,模型命中率较低。周洋等^[52]将聚类算法与神经网络进行结合,通过聚类分析将高炉数据分为若干类,然后基于神经网络分别进行训练,实现了高炉焦比预测,模型的预测精度高于传统神经网络。李壮年等^[21]采用了支持向量机、随机森林、梯度提升树等 6 种机器学习算法,并采用特征工程和超参数调优对机器学习预测进行了优化,最后采用集成学习方法对高炉焦比和透气性进行了预测,预测结果不仅精准度高而且具有很好的鲁棒性。

目前已经建立了许多高炉关键参数预测模型,这些模型在高炉实际生产中发挥着重要作用。然而,当前高炉关键变量预测多以纯数据驱动模型为主,大多数模型未能将工艺机制和数据模型进行深度结合,应用效果与实际生产需求仍有一些差距。通过相关的冶金工艺理论建立高炉机制模型,将高炉机制模型的结果作为新的特征。该方法的目的在于通过机制分析实现对高炉内部难以监测指标的理论计算。文献^[53-54]通过建立布料仿真模型,计算得

到炉料径向焦炭负荷和炉料落点等重要特征,并采取高炉布料仿真模型和聚类分析相结合的方法分析了布料制度与炉况的关系。文献^[55]通过高温区碳氧平衡理论、热平衡理论建立渣铁热量指数模型,将其中的渣铁热量指数、直接还原度、燃料比偏差等参数作为新的特征带入炉热预测模型中,有效改善了模型的预测精度。因此,充分利用高炉炼铁的海量数据价值,兼顾冶炼机制在关键变量预测的基础作用,结合大数据技术,建立机制与数据双驱动融合的高炉智慧模型,并在生产实践中不断验证、优化,方能取得良好的应用效果。

2.3 高炉炉况状态评价

在传统高炉操作中,现场作业人员通常依靠对高炉单个或多个指标的观测,凭经验判断炉况,针对原燃料的变化趋势,对操作进行调整,尽量避免炉况失常。随着自动化、信息化不断发展,专家学者不断尝试采用大数据、机器学习对高炉运行状态进行管控。

文献^[43]选取铁水产量、铁水 $[\text{Si}+\text{Ti}]$ 和燃料比表征高炉炉况,通过数据分析和机器学习获得炉况评分规则,为高炉运行状态评价梳理新思路。文献^[56]采用因子分析法提取 19 个状态参数计算高炉综合状态指标,基于集成学习构建模型预测 3 h 后高炉运行状态,由于计算因子得分时存在失效情况,模型准确率不稳定。文献^[57-58]提出用时间序列最小二乘支持向量机方法诊断高炉炉况,该方法实现了对高炉炉况的分类评价。马钢^[59]将诸多高炉各类参数进行分类、对每个指标设置权重、上下限和区间分值,建立了高炉综合顺行指数评价分析模型,采用量化评分的方式对实时参数进行评价。优点在于选取的高炉参数涵盖范围广能够较全面地反映高炉炉况状态,不足之处在于参数的评分规则依赖专家经验,没有充分利用高炉数据中有价值的信息。武钢^[60]基于有限 7 号高炉开发了高炉炉况诊断系统,包括炉顶料面雷达监测、炉身上部料层结构模型、高热负荷区域铜冷却壁热面渣皮监测模型以及高炉过程参数计算、炉况状态的模式识别等内容,系统上线应用后高炉利用系数、煤气利用率、燃料比技术指标有了明显改善,但该系统在对高炉整体内型和内部状态进行解析、丰富案例库、提高知识库准确度等方面还需要进一步完善。

大量的高炉运行数据蕴藏着高炉冶炼过程的深层次特性,但是不充分分析利用高炉的机制知识,仅仅利用常规的数据驱动建模算法构建高炉模型,必

然很难达到理想的效果^[61]。高效融合工业大数据和专家知识,发挥专家经验的规范作用,构建高炉运行状态科学评价机制,实现综合炉况实时监控与准确预测,完成炉况波动科学溯因,是维持高炉稳定顺行的重要创新手段。

2.4 高炉关键指标优化

高炉涉及的原燃料种类多而复杂,各变量间存在强耦合、非线性、大时滞等特点。如何在复杂数据、复杂动态工况条件下,进行高炉多目标自主优化决策和自愈控制,成为高炉智能化炼铁的关注热点。目前,在高炉指标优化控制方面,多采用数据驱动的方式来优化高炉多个目标,取得了初步效果,但普遍存动态炉况适应性不强、优化操作解集现场应用性差、优化过程耗时长等问题。由于高炉冶炼过程的特殊性和复杂性,现阶段高炉稳定生产主要依靠人工操作,还无法实现真正意义上的闭环控制,更有效的方式是通过高炉优化模型为高炉操作者推送优化建议,协助操作者指导高炉稳定生产。

文献^[21,62-64]以焦比、 K 值、热负荷、 CO_2 排放、成本等作为高炉优化目标,采用遗传算法进行高炉操作优化,在降低能耗和稳定炉况方面在理论上具有一定的优化效果,而关于最优解如何在现场合理应用方面还有很大的差距。由于最优操作解集数量多、差异大,只追求优化效果而忽略现场生产条件的约束则会导致最优操作解集应用性变差。对于高炉现场生产而言,保证高炉的稳定顺行才是首要的,高炉操作者最期望的是通过调控数量最少、风险最低、成本最低的操作以达到稳定炉况的目的。因此在反馈优化操作建议时不仅要追求优化效果,还应综合考虑现场操作的可行度和操作成本。以低风险、低经济、高回报作为优化目标,才能推动大数据技术在高炉优化控制应用方面取得更好的成果。

3 结论与展望

(1)在高炉数据预处理方面,对于高炉炼铁生产数据中存在的缺失数据、异常数据和工序间数据匹配难等问题,应综合考虑数据问题和算法自身特点,科学选择数据处理方法,完成高炉复杂数据的清洗与整合,才能多维度提高数据的真实性、准确性和完整性,使高炉数据质量得到有效改善。

(2)在高炉关键指标预测方面,首先需要通过时滞性分析消除或者弱化高炉原燃料条件和操作制度对高炉经济指标时间滞后的影响,提高数据信息的准确性;在此基础上通过高特征选择技术,筛选出有

效的输入特征,才能保证高炉关键指标预测模型的准确率。

(3)在高炉炉况状态评价方面,依赖经验判断炉况走势,难以准确动态掌握高炉状态;以数据驱动的高炉炉况评价方法结果可解释性差,不易追溯炉况扰动原因。因此,需要构建数据信息与工艺机制融合的高炉智慧模型,才能够实现高炉炉况的科学评价。

(4)在高炉参数优化控制方面,不仅要追求优化效果,还应综合考虑现场操作的可行度和操作成本,以低风险、低经济、高回报作为优化目标,才能推动大数据技术在高炉优化控制应用方面取得更好的成果。

(5)应用大数据技术解决高炉炼铁中的“黑箱”问题,优化冶炼工艺具有巨大的潜力。未来的高炉将会是大数据技术与高炉冶炼工艺深度融合的数字化、智能化生产。现阶段研究成果在很大程度上提高了高炉操作者对智能化高炉的认识,然而要实现高炉智能化生产,还需要研究者继续探索和完善。

参考文献:

[1] 王振阳,江德文,王新东,等. 基于支持向量回归与极限学习机的高炉铁水温度预测[J]. 工程科学学报,2021,43(4):569.
(Wang Z Y, Jiang D H, Wang X D, et al. Prediction of blast furnace hot metal temperature based on support vector regression and extreme learning machine[J]. Chinese Journal of Engineering, 2021, 43(4): 569.)

[2] 江德文,王振阳,戴建华,等. 基于支持向量机的高炉煤气利用率预测建模[J]. 中国冶金,2021,31(4):55.
(Jiang D W, Wang Z Y, Dai J H, et al. Forecast modeling of gas utilization rate of blast furnace based on support vector machine[J]. China Metallurgy, 2021, 31(4): 55.)

[3] 赵军,李红玮,刘小杰,等. 基于 Xgboost 的高炉透气性指数预测模型[J]. 中国冶金,2021,31(3):22.
(Zhao J, Li H W, Liu X J, et al. Prediction model of permeability index based on Xgboost[J]. China Metallurgy, 2021, 31(3): 22.)

[4] 程泽凯,闫小利,程旺生,等. 基于梯度提升决策树的焦炭质量预测模型研究[J]. 重庆工商大学学报(自然科学版),2021,38(5):55.
(Cheng Z K, Yan X L, Cheng W S, et al. Study on coke quality prediction model based on gradient lifting decision tree[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2021, 38(5): 55.)

[5] Liu S, Lyu Q, Liu X J, et al. A prediction system of burn through point based on gradient boosting decision tree and decision rules[J]. ISIJ International, 2019, 59(12): 2156.

[6] 崔泽乾,韩阳,杨爱民,等. 基于神经网络时间序列模型的高炉

铁水硅含量智能预报[J]. 冶金自动化,2021,45(3):51.
(Cui Z Q, Han Y, Yang A M, et al. Intelligent prediction of silicon content in hot metal of blast furnace based on neural network time series model [J]. Metallurgical Industry Automation, 2021, 45(3): 51.)

[7] 包向军,翁思浩,陈光,等. 基于时序模型的高炉煤气发生量多步预测对比[J]. 钢铁,2022,57(9):166.
(Bao X J, Weng S H, Chen G, et al. Comparison on multi-step prediction of blast furnace gas generation based on LSTM/SARIMA time series model [J]. Iron and Steel, 2022, 57(9): 166.)

[8] 朱俊. 选择性集成学习及其应用研究[D]//南昌:华东交通大学,2016.
(Zhu J. Reasearch of Selective Ensemble Learning and Its Appliication [D]/Nanchang: East China JiaoTong University, 2016.)

[9] 石琳,刘文慧,曹富军,等. 基于 CEEMDAN-SVM-LSTM 的高炉煤气利用率组合预测[J/OL]. 中国测试, [2022-10-04]. <https://kns.cnki.net/kcms/detail/51.1714.TB.20220915.1449.004.html>.
(Shi L, Liu W H, Cao F J, et al. Combined forecast of blast furnace gas utilization rate based on CEEMDAN-SVM-LSTM [J/OL]. China Measurement & Test, [2022-10-04]. <https://kns.cnki.net/kcms/detail/51.1714.TB.20220915.1449.004.html>.)

[10] 陈少飞,刘小杰,李宏扬,等. 高炉炼铁数据缺失处理研究初探[J]. 中国冶金,2021,31(2):17.
(Chen S F, Liu X J, Li H Y, et al. Preliminary study on missing data processing of blast furnace ironmaking[J]. China Metallurgy, 2021, 31(2): 17.)

[11] Barzi F, Woodward M. Imputations of missing values in practice: Results from imputations of serum cholesterol in 28 cohort studies[J]. American Journal of Epidemiology, 2004, 160(1): 34.

[12] 党晓晶,石琳,赵娜,等. 基于参数优化 SVR 方法预测高炉煤气利用率[J]. 钢铁研究学报,2021,33(4):279.
(Dang X J, Shi L, Zhao N, et al. Prediction of utilization ratio of blast furnace gas based on parameter optimized by SVR method [J]. Journal of Iron and Steel Research, 2021, 33(4): 279.)

[13] 王坤,刘小杰,刘二浩,等. 基于 AdaBoost 算法的炉芯温度预测模型[J]. 钢铁研究学报,2020,32(5):363.
(Wang K, Liu X J, Liu E H, et al. Core temperature prediction model based on AdaBoost algorithm [J]. Journal of Iron and Steel Research, 2020, 32(5): 363.)

[14] 郑智泉. 不同缺失机制下数据填补算法的比较研究[D]//贵阳:贵州民族大学,2022.
(Zheng Z Q. Comparative Research of Data Filling Algorithms under Different Missing Mechanisms [D]//Guiyang: Guizhou Minzu University, 2022.)

[15] 赵哲,张勇,于楠楠,等. 面向铁水温度的高炉异常数据检测及修补[J]. 自动化与仪表,2015,30(2):63.

- (Zhao Z, Zhang Y, Yu N N, et al. Furnace temperature modelling and data processing for blast furnace object oriented hot metal temperature [J]. Automation & Instrumentation, 2015, 30(2): 63.)
- [16] 刘仕鑫, 尹怡欣, 张森. 高炉透气性指数的核超限学习机预测模型[J/OL]. 控制理论与应用, [2022-10-04]. <http://kns.cnki.net/kcms/detail/44.1240.TP.20220321.1138.004.html>.
- (Liu S X, Yin Y X, Zhang S. Prediction model of kernel extreme learning machine for permeability index of blast furnace[J/OL]. Control Theory & Applications, [2022-10-04]. <http://kns.cnki.net/kcms/detail/44.1240.TP.20220321.1138.004.html>.)
- [17] 吕政. 基于数据的高炉煤气系统建模与调度应用研究[D]//大连: 大连理工大学, 2016.
- (Lü Z. Data-based Modeling and Scheduling for Blast Furnace Gas System[D]//Dalian: Dalian University of Technology, 2016.)
- [18] Zhao J, Chen S, Liu X, et al. Outlier screening for ironmaking data on blast furnaces[J]. International Journal of Minerals, Metallurgy and Materials, 2021, 28(6): 1001.
- [19] 刘馨, 张卫军, 石泉, 等. 基于数据挖掘与清洗的高炉操作参数优化[J]. 东北大学学报(自然科学版), 2020, 41(8): 1153.
- (Liu X, Zhang W J, Shi Q, et al. Operation parameters optimization of blast furnaces based on data mining and cleaning[J]. Journal of Northeastern University (Natural Science), 2020, 41(8): 1153.)
- [20] 吕明远. 基于能量平衡的高炉燃料比协同优化决策研究[D]//包头: 内蒙古科技大学, 2020.
- (Lü M Y. Research on Collaborative Optimization of Blast Furnace Fuel Ratio Based on Energy Balance[D]//Baotou: Inner Mongolia University of Science and Technology, 2020.)
- [21] 李壮年, 储满生, 柳政根, 等. 基于机器学习和遗传算法的高炉参数预测与优化[J]. 东北大学学报(自然科学版), 2020, 41(9): 1262.
- (Li Z N, Chu M S, Liu Z G, et al. Prediction and optimization of blast furnace parameters based on machine learning and genetic algorithm [J]. Journal of Northeastern University (Natural Science Edition), 2020, 41(9): 1262.)
- [22] 毕春宝. 基于数据驱动模型的铁钢界面铁水温度预测研究[D]//包头: 内蒙古科技大学, 2021.
- (Bi C B. Prediction of Hot Metal Temperature on Ironmaking and Steelmaking Interface Based on Data-Driven Model[D]//Baotou: Inner Mongolia University of Science and Technology, 2021.)
- [23] 李泽龙. 基于 ARMAX-LSTM 模型的高炉铁水质量预报研究[D]//杭州: 浙江大学, 2019.
- (Li Z L. Research on Molten Iron Quality Prediction of Blast Furnace Based on ARMAX-LSTM Model[D]//Hangzhou: Zhejiang University, 2019.)
- [24] 刘毅, 李平, 高增梁. 用于高炉铁水质量预报的改进支持向量回归[J]. 浙江大学学报(工学版), 2012, 46(5): 830.
- (Liu Y, Li P, Gao Z L. Quality prediction of hot metal in blast furnace using improved support vector regression[J]. Journal of Zhejiang University (Engineering Edition), 2012, 46(5): 830.)
- [25] 邓春宇, 吴克河, 谈元鹏, 等. 基于多元时间序列分割聚类的异常值检测方法[J]. 计算机工程与设计, 2020, 41(11): 6.
- (Deng C X, Wu K H, Tan Y P, et al. Outlier detection method based on multivariate time series segmentation clustering[J]. Computer Engineering and Design, 2020, 41(11): 6.)
- [26] 赵臣啸, 薛惠锋, 王磊, 等. 基于孤立森林算法的取用水量异常数据检测方法[J]. 中国水利水电科学研究院学报, 2020, 18(1): 9.
- (Zhao C X, Xue H F, Wang L, et al. Detection method of water intake anomaly data based on isolated forest algorithm [J]. Journal of China Institute of Water Resources and Hydropower Research, 2020, 18(1): 9.)
- [27] 张益, 田地. 一种基于孤立森林算法的销量异常值检测方法: 中国, CN110533108A[P]. 2019-09-02.
- (Zhang Y, Tian D. A Sales Outlier Detection Method Based on Isolated Forest Algorithm: China, CN110533108A [P]. 2019-09-02.)
- [28] 李志鹏. 基于混合高斯-朴素贝叶斯的高炉炉况判别系统[D]//杭州: 浙江大学, 2017.
- (Li Z P. An Operation State Identification System of Blast Furnace Based on Gaussian Mixture and Naïve Bayes Model [D]//Hangzhou: Zhejiang University, 2017.)
- [29] 李艳霞, 柴毅, 胡友强, 等. 不平衡数据分类方法综述[J]. 控制与决策, 2019, 34(4): 673.
- (Li Y X, Chai Y, Hu Y Q, et al. Review of imbalanced data classification methods [J]. Control and Decision, 2019, 34(4): 673.)
- [30] 寇鑫. 混频 MIDAS 模型在宏观经济研究领域应用评述[J]. 企业改革与管理, 2020(8): 36.
- (Kou X. A review of the application of MIDAS model in macroeconomic research [J]. Enterprise Reform and Management, 2020(8): 36.)
- [31] 叶光. 基于混频数据的一致指数构建与经济波动分析[J]. 统计研究, 2015, 32(8): 17.
- (Ye G. Research on the coincident index and economic fluctuations in China with mixed-frequency data [J]. Statistical Research, 2015, 32(8): 17.)
- [32] 刘金全, 刘汉, 印重. 中国宏观经济混频数据模型应用——基于 MIDAS 模型的实证研究[J]. 经济科学, 2010(5): 23.
- (Liu J Q, Liu H, Yin Z. Application of mixed data model in China's macro economy --An empirical study based on MIDAS model[J]. Economic Science, 2010(5): 23.)
- [33] 刘盎然. 基于案例分析 MATLAB 课程教学研究——以数据标准化处理为例[J]. 信息与电脑, 2022, 34(4): 223.
- (Liu A R. MATLAB Course Teaching Research Based on Case Analysis --Taking Data Standardization as an Example [J]. China Computer & Communication, 2022, 34(4): 223.)
- [34] 阚鑫禹. 数据治理标准化发展现状与启示[J]. 信息技术

与政策,2022(2):2.

(Kan X Y. Data governance standardization development current situation and enlightenment [J]. Information and Communications Technology and Policy,2022(2):2.)

[35] 安剑奇,陈易斐,吴敏. 基于改进支持向量机的高炉一氧化碳利用率预测方法[J]. 化工学报,2015,66(1):206.

(An J Q,Chen Y F,Wu M. A prediction method for carbon monoxide utilization ratio of blast furnace based on improved support vector regression [J]. CIESC Journal, 2015, 66 (1):206.)

[36] 王玉涛,赵俊哲,宫喜鹏,等. 一种针对时滞不确定信息的高炉铁水硅含量预报方法: 中国, CN110309608A[P]. 2019-10-08.

(Wang Y T,Zhao J Z,Gong X P, et al. A Method for Predicting Silicon Content of Molten Iron in Blast Furnace with Uncertain Information of Time Delay: China, CN110309608A[P]. 2019-10-08.)

[37] 张笑凡. 基于最大信息系数与岭回归的炉缸活性预测[D]// 马鞍山:安徽工业大学,2020.

(Zhang X F. Prediction of Hearth Activity Based on MIC and Ridge Regression [D]//Ma' anshan: Anhui University of Technology,2020.)

[38] 刘代飞,张吉,付强. 基于温度场主元分析的高炉炉况深度学习预测建模[J]. 冶金自动化,2021,45(3):42.

(Liu D F,Zhang J,Fu Q. Deep learning prediction modeling of blast furnace condition based on principal component analysis of temperature field[J]. Metallurgical Industry Automation, 2021,45(3):42.)

[39] Chelgani S C,Matin S S,Hower J C. Explaining relationships between coke quality index and coal properties by random forest method[J]. Fuel,2016,182:754.

[40] Gregorutti B, Michel B, Saint-Pierre P. Grouped variable importance with random forests and application to multiple functional data analysis[J]. Computational Statistics & Data Analysis,2015,90:15.

[41] Hapfelmeier A,Hothorn T,Ulm K, et al. A new variable importance measure for random forests with missing data[J]. Statistics and Computing,2014,24(1):21.

[42] 张照硕,侯能. 基于遗传算法的封装式特征选择研究[J]. 电脑知识与技术,2022,18(19):94.

(Zhang Z S, Hou N. Research on encapsulated feature selection based on genetic algorithm [J]. Computer Knowledge and Technology,2022,18(19):94.)

[43] Yong D,Qing L. Establishment of evaluation and prediction system of comprehensive state based on big data technology in a commercial blast furnace [J]. ISIJ International,2020,60 (5):898.

[44] Li Y, Yang C. Domain knowledge based explainable feature construction method and its application in ironmaking process [J]. Engineering Applications of Artificial Intelligence,2021, 100:104.

[45] 崔桂梅,孙彤,张勇. 支持向量机在高炉铁水温度预测中的应

用[J]. 控制工程,2013,20(50):809.

(Cui G M,Sun T,Zhang Y. Application of support vector machine(SVM)in prediction of molten iron temperature in blast Furnace [J]. Control Engineering of China, 2013, 20 (50):809.)

[46] Jian L, Gao C H, Li L, et al. Application of least squares support vector machines to predict the silicon content in blast furnace hot metal[J]. ISIJ International,2008,48(11):1659.

[47] 王文慧,刘祥官,刘学艺. 基于随机森林算法的高炉铁水硅质量分数预测模型[J]. 冶金自动化,2014,38(5):33.

(Wang W H,Liu X G,Liu X Y. Prediction model of silicon content in blast furnace hot metal based on random forests algorithm[J]. Metallurgical Industry Automation, 2014, 38 (5):33.)

[48] 张勇,李静,崔桂梅. 小波神经网络在高炉铁水温度预测中的建模研究[J]. 计算机应用化学,2013,30(10):1173.

(Zhang Y,Li J,Cui G M. Modeling research of wavelet neural network in temperature prediction of hot metal in blast furnace[J]. Computers and Applied Chemistry,2013,30(10): 1173.)

[49] 刘小杰,邓勇,李欣,等. 基于大数据技术的高炉铁水硅含量预测[J]. 中国冶金,2021,31(2):10.

(Liu X J,Den Y,Li X, et al. Prediction of silicon content in hot molten of blast furnace based on bid data technology[J]. China Metallurgy,2021,31(2):10.)

[50] 岳有军,董安,赵辉,等. 高炉炼铁工序入炉焦比预测的研究 [J]. 计算机仿真,2017,34(2):362.

(Yue Y J,Dong A,Zhao H, et al. Prediction of coke ratio in iron and steel enterprises[J]. Computer Simulation, 2017, 34 (2):362.)

[51] 周继程,张春霞,丁毅,等. 马钢高炉炼铁工序能耗预测模型 [J]. 钢铁研究学报,2011,23(2):30.

(Zhou J C,Zhang C X,Ding Y, et al. Study on prediction model of BF procedure energy consumption for Ma' anshan Steel [J]. Journal of Iron and Steel Research, 2011, 23 (2):30.)

[52] 周洋,余文武,董相娟,等. 基于聚类分析和神经网络的高炉焦比预测模型[J]. 辽宁科技大学学报,2010,33(3):245.

(Zhou Y,Yu W W,Dong X J, et al. A prediction model for blast furnace coke ratio with clustering analysis and neural network[J]. Journal of University of Science and Technology Liaoning,2010,33(3):245.)

[53] 李壮年,阮根基,李宝峰,等. 大型高炉装料制度与炉况参数的数据挖掘[C]//. 第十一届中国钢铁年会论文集. 北京:中国金属学会,2017:767.

(Li Z N,Ruan G J,Li B F, et al. Data mining of lager BF charging system and furnace condition parameters [C]// Proceedings of the 11th China Iron and Steel Annual Conference--S01. Ironmaking and Raw Materials. Beijing:The Chinese Society for Metals,2017:767.)

[54] 李壮年,储满生,柳政根,等. 大型高炉布料参数对煤气流的影响[J]. 材料与冶金学报,2019,18(1):7.

(Li Z N, Chu M S, Liu Z G, et al. Effect of the large blast furnace charging parameters on gas flow [J]. Journal of Materials and Metallurgy, 2019, 18(1): 7.)

[55] 李壮年. 基于大数据挖掘的大型高炉关键工艺参数预测和优化[D]//沈阳: 东北大学, 2020.
(Li Z N. Prediction and Optimization of Key Process Parameters of Large Blast Furnace Based on Big Data Mining [D]//Shenyang: Northeastern University, 2020.)

[56] Hong L, Xiang B, Xiao L, et al. Evaluation and prediction of blast furnace status based on big data platform of ironmaking and data mining; ironmaking[J]. ISIJ International, 2021, 61(1): 108.

[57] Wang A, Zhang L, Nan G, et al. Fault diagnosis of blast furnace based on DAGSVM [C]//Proceeding of 2006 6th World Congress on Intelligent Control and Automation. London: IEEE, 2006: 561.

[58] Liu L, Wang A, Mo SHA, et al. Multi class classification methods of cost-conscious LSSVM for fault diagnosis of blast furnace [J]. Journal of Iron and Steel Research International, 2011, 18(10): 17.

[59] 黄发元, 黄龙, 伏明, 等. 一种新型高炉顺行评价的方法[P]. CN201810936108. X, 2018. [2018-08-16].
(Huang F Y, Huang L, Fu M, et al. A new antegrade evaluation method for blast furnace[P]. CN201810936108. X, 2018. [2018-08-16].)

[60] 刘栋梁, 陈令坤. 武钢有限 7 号高炉炉况诊断系统的开发和应用[J]. 冶金自动化, 2021, 45(3): 263.
(Liu D L, Chen L K. Development and application of No. 7 BF condition diagnosis system in WISCO [J]. Metallurgical Industry Automation, 2021, 45(3): 263.)

[61] 李军朋, 华长春, 关新平. 基于机理、数据和知识的大型高炉冶炼过程建模研究 [J]. 上海交通大学学报, 2018, 52(10): 1142.
(Li J P, Hua C C, Guan X P. Modeling research for smelting mechanism blast furnace smelting process based on operation data and expert knowledge [J]. Journal of Shanghai Jiaotong University, 2018, 52(10): 1142.)

[62] Pettersson F, Saxen H, Kalyanmoy D. Genetic algorithm-based multicriteria optimization of ironmaking in the blast furnace [J]. Materials and Manufacturing Processes, 2009, 24(3): 343.

[63] 张宗旺, 车晓锐, 张宏博, 等. 高炉多目标优化模型的建立及验证[J]. 过程工程学报, 2017, 17(1): 178.
(Zhang Z W, Che X R, Zhang H B, et al. Establishment and validation of multi-objective optimization model of blast furnace[J]. The Chinese Journal of Process Engineering, 2017, 17(1): 178.)

[64] Zhou H, Zhang H, Yang C. Hybrid-model-based intelligent optimization of ironmaking process [J]. IEEE Transactions on Industrial Electronics, 2020, 67(3): 2469.