

DOI:10.19651/j.cnki.emt.2108019

# 基于集成学习的高炉压差预报模型研究<sup>\*</sup>

刘 颂<sup>1</sup> 赵亚迪<sup>1</sup> 张 振<sup>2</sup> 刘小杰<sup>2</sup> 刘 然<sup>2</sup> 吕 庆<sup>2</sup>

(1. 唐山学院人工智能学院 唐山 063000; 2. 华北理工大学冶金与能源学院 唐山 063009)

**摘要:**为了提升高炉生产的智能化水平,提出了基于集成学习算法的高炉下部压差预报模型,解决了基于在线数据精准预报下部压差的难题。通过对高炉内部机理进行系统分析,全面选取了高炉原料参数、操作参数、状态参数和指标参数作为模型的输入。并采用实际现场数据得到了变量间的相关系数,确定了高炉下部压差相关的重要特征变量。采用极限树集成算法建立了压差预报模型,并结合模型的预报精度,采用向前选择法优化了模型的输入。通过对模型算法超参数的选择,获得了最优超参数集合,该参数集合建立的下部压差预报模型精度  $R^2$  达到了 0.826 4,且 MSE 接近零值。测试结果证明,该模型具有良好的预报精度和泛化能力,对现场操作者提前预测高炉运行状况和调整炉况具有重要的指导意义。

**关键词:**预测模型;极限树算法;非线性相关性分析;参数优化;高炉压差

中图分类号: TF325.61 文献标识码: A 国家标准学科分类代码: 450.3510

## Research on blast furnace pressure difference prediction model with integrated learning

Liu Song<sup>1</sup> Zhao Yadi<sup>1</sup> Zhang Zhen<sup>2</sup> Liu Xiaojie<sup>2</sup> Liu Ran<sup>2</sup> Lyu Qing<sup>2</sup>

(1. College of Artificial Intelligence, Tangshan University, Tangshan 063000, China; 2. College of Metallurgy and Energy, North China University of Science and Technology, Tangshan 063009, China)

**Abstract:** In order to improve the intelligent level of blast furnace production, a prediction model of pressure difference in low part of blast furnace with integrated learning algorithm is proposed, which solves the problem of accurately predicting the lower pressure difference based on online data. Through systematic analysis of the internal mechanism of the blast furnace, the raw material parameters, operating parameters, state parameters and index parameters of the blast furnace are comprehensively selected as the input of the model. The actual field data is used to obtain the correlation coefficient between the variables, and the important characteristic variables related to the pressure difference in the lower part of the blast furnace are determined. The extra tree ensemble algorithm is used to establish the pressure difference prediction model, and combined with the prediction accuracy of the model, the forward selection method is used to optimize the input of the model. By selecting the hyperparameters of the model algorithm, the optimal hyperparameter set is obtained. The accuracy  $R^2$  of the lower pressure difference prediction model established by the parameter set reaches 0.826 4, and the MSE is close to zero. The test results prove that the model has good prediction accuracy and generalization ability, and has important guiding significance for the on-site operators to predict the operating conditions of the blast furnace and adjust the furnace conditions in advance.

**Keywords:** prediction model; extra tree algorithm; non-linear correlation analysis; parameter optimization; blast furnace pressure difference

## 0 引言

高炉炼铁是一个化学反应众多、强耦合、多变量、非线

性的复杂工业过程<sup>[1-2]</sup>。及时掌握高炉运行状况,并根据其进行合理操作是实现高炉炼铁高产、优质、低耗的关键所在。高炉压差是高炉透气性的主要指标,是评判高炉运行

收稿日期:2021-10-07

\*基金项目:河北省教育厅科学技术研究项目(BJ2021099)、河北省自然科学基金高端钢铁冶金联合基金项目(E2019209314, E2020209208)资助

状态的重要指标之一。炉内压差高,炉料下降阻力增加,严重时高炉顺行受破坏;压差过低,炉料与煤气流之间的热交换及反应得不到充分发展,高炉能量利用效益差,严重时会引发炉内气流过吹甚至管道气流现象<sup>[3]</sup>。由于全炉压差的变化具有滞后性,一旦其发生剧烈波动,预示着炉况变化已成定局,再采取补救措施,往往为时已晚。

为了避免上述不利影响,文献[4]通过研究高炉操作与料柱透气性、高炉顺行之间的关系,建立了冶金机理模型,预测操作过程中块状带压差的变化趋势。李宏飞等<sup>[5]</sup>根据专家经验建立了高炉炉身压差与炉内状况、气流变化的对应关系,实现了对炉内局部冶炼条件变化的超前判断。杨鑫等<sup>[6]</sup>基于某钢铁厂的实际生产数据,结合 6σ 管理方法,利用 Minitab 软件对高炉压差以及所选取影响压差波动的操作参数,进行了因果矩阵分析、相关性分析和回归分析,确定了影响高炉压差的主要因素。在上述研究中,由于机理模型(简化了高炉生产工艺)、专家经验模型(规则需要不断完善)、传统数学模型(无法获得复杂的非线性关系)固有的局限性,导致此类研究实际应用效果差。

随着计算机处理能力的提高,一些人工智能方法开始应用于炼铁生产过程,例如支持向量机<sup>[7]</sup>、人工神经网络<sup>[8]</sup>等。这类算法具有强大的非线性逼近能力<sup>[9-11]</sup>。通常用于建立观测数据与状态参数之间的关系模型。Zhou 等<sup>[12]</sup>针对现有高炉炼铁过程建模与控制方法的不足,建立基于 LS-SVM 算法的数学驱动非线性状态空间模型。江德文等<sup>[13]</sup>依据最大信息系数确定了模型输入参数,并建立了基于支持向量回归(SVR)算法的高炉煤气利用率预测模型。袁冬芳等<sup>[14]</sup>基于包钢 6 号高炉的在线生产数据,对硅含量的自回归项及影响因素进行了主成分分析,并建立了铁水硅含量的支持向量机回归预测模型,该模型对炉温预测的准确度达到了 88.2%。上述模型对实际生产起到了一定的指导作用。但是,由于建模过程中使用数据量较少,即使训练模型预测精度很高,却仍存在着泛化能力较差的问题。此外,大多数模型的建立多数采用单一算法模型,而炼铁实际生产环境复杂多变,单一算法模型很难捕捉各个工序流程中的系统特性。

随着近几年钢铁工业装备的大型化和现代化,高炉系统自动化水平显著提升,多年来积累了海量的历史数据。以大规模生产数据为基础,通过采用集成学习建立一个能够更加符合现实规律的数据模型已成为当前冶金领域的研究热点<sup>[15-17]</sup>,而且,此类模型能够获得更高的预报精度和更好的泛化能力。因此,为了改善上述压差模型研究存在的不足,开展基于集成学习的高炉压差预测模型研究。

## 1 高炉工艺及其特点

### 1.1 高炉工艺

本文研究涉及一种高炉炼铁生产过程。高炉是一个气固逆流反应容器,炉料至上而下运动,煤气流则自下而上运

动,在炉料与煤气相对流动接触的过程中发生一系列的化学反应。在这个连续的生产过程中,炉料按一定的重量配比及布料方式从炉顶装入炉内,炉料中的焦炭和喷入的煤粉在风口前燃烧,产生大量的高温还原性气体,在炉内上升过程中加热缓慢下降的炉料,并还原其中的氧化物为金属铁。炉料被加热至一定温度后软化,熔融滴落,其未被还原的物质形成熔渣。渣铁聚集于炉缸内,发生诸多反应,最后调整成分和温度达到终点,定期从炉内排放炉渣和铁水。上升的煤气流将能量传给炉料而使温度降低,最终形成高炉煤气从炉顶导出管排出。

在上述生产过程中,对高炉内部区域进行压力检测是十分关键的技术。相比于静压力而言,操作者更重视炉身静压力的上部压差、下部压差及它们的变化趋势。上部压差主要是对炉料快状带透气性的反映,其值受原料的粒级、低温还原粉化率等影响较大。下部压差主要是对软熔带透气性的反映,软熔带区域的压力损失占整个压差比例的 60%~70%,其特性直接影响这高炉煤气流的分布<sup>[18]</sup>。

### 1.2 高炉工艺特点

高炉炼铁工艺过程具有多参数影响、机理复杂和强非线性等特点。

1) 多参数影响:高炉炼铁过程涉及的工艺参数有 4 种,分别为原料参数、操作参数、状态参数和指标参数。

原料参数描述生产过程中各种入炉原料的质量及剂量方案,主要包括烧结矿、球团矿和生矿的比例、转鼓指数、筛分指数、抗压强度、焦炭负荷、矿石批重等变量。操作参数是指高炉冶炼过程中的基本控制回路变量,主要为风温、风压、风量和煤粉喷吹量等。状态参数描述了高炉生产过程中的温度分布、风量和压力变化以及煤气成分等,主要包括炉顶十字测温、顶温、顶压、上部压差、下部压差、全炉压差、实际风速、标准风速和炉顶煤气 CO<sub>2</sub>、O<sub>2</sub>、CO、H<sub>2</sub> 和 N<sub>2</sub> 等。指标参数描述了渣铁成分、铁水温度和铁量等变量。

不同类型的参数以不同的方式影响高炉压差,同一类型的参数对压差也有不同的影响。这使得很难确定哪些参数是压差预测模型最合适的输入。

2) 机理复杂:高炉生产过程涉及焦炭、煤粉的燃烧、碳的气化溶损、铁氧化物的逐级还原等多个化学反应,以及相变、传热、传质等物理变化。

机理的复杂性体现在参数的耦合上。例如,焦炭在风口区域的燃烧,提高了炉腹煤气温度和煤气量,这种改变对于炉腹区域的物理、化学变化是必要的,例如铁氧化物的还原和渗碳有关的变化。这些变化会影响渣铁形成和煤气流分布,从而影响软熔带的透气性,进而影响整个高炉的顺行。

3) 强非线性:高炉冶炼过程中参数间的关系具有强非线性,一个很好的例子是铁氧化物的还原速率与温度、压力之间的非线性关系。工艺参数显著影响高炉冶炼过程中的物理、化学变化和煤气流分布,从而导致炉内压差的波动。

因此,工艺参数与炉内压差的关系是强非线性的。

由于过程的复杂性和非线性,导致很难建立精确、稳定的高炉压差预测模型。

## 2 建模方法

本文研究的主要问题是如何建立一个精确的下部压差预测模型,建立模型涉及的两个重要方面是选择合适的建模方法和确定模型输入。

由于高炉冶炼过程的复杂性和强非线性,使得单一模型无法对其进行描述。因此,选择极限树(extra tree)集成算法<sup>[19]</sup>进行建模,这种集成算法组合既能捕捉炼铁生产各工序间的复杂非线性关系,又能捕捉压差参数时间序列的变化规律。

高炉工艺的特点(多参数影响、机理复杂和强非线性)使得机理分析本身不适用于确定模型输入,因为它只能粗略地阐明输入变量与压差参数之间的关系,从而可能产生大量的输入,使计算成本增大。因此,本研究采用机理分析

和数据分析相结合的方法来寻找一个较小的输入空间,以获得一个简单的、具有高精度的预测模型。

在上述分析的基础上,设计了一个预报下部压差的建模方法与优化过程。

## 3 机理和数据分析

机理分析是对内部物质和能量流动的分析,用于对高炉下部压差影响最大的参数进行初步选择。然后,利用变量间的相关性分析来得到原料参数、操作参数、状态参数和指标参数与下部压差参数之间的关系,这些分析能够有效减少模型的输入。

### 3.1 物质和能量流动分析

图 1 所示为高炉冶炼过程中的物质和能量流动。焦炭和煤粉燃烧释放的大部分能量驱动炉料的物理和化学变化(涉及金属碳酸盐的分解、氧化物的还原反应和渣铁的形成等),其余部分以物理热的形式被高炉煤气、铁水和炉渣带走。




图 1 高炉炼铁过程中的物质和能量流动示意图

高炉炉料由烧结矿、球团矿、生矿和焦炭组成,在生产过程中,通过布料器将其从炉顶装入。在炉缸上部的风口处鼓入热风和煤粉,使焦炭和煤粉燃烧放热,并产生 CO 和 H<sub>2</sub>。随着两种气体的上升,一方面气体将热量传递给上部炉料,使得金属碳酸盐分解为金属氧化物(MgO、Fe<sub>2</sub>O<sub>3</sub> 和 CaO 等);另一方面,气体通过与金属氧化物发生间接还原和直接还原反应,将铁氧化物还原为铁水,而炉料中的一些杂质则会在此过程中进入炉渣。因此,由炉料混合物的化学成分决定了炉渣的成分,从而决定了炉渣的性质<sup>[20]</sup>。

炉渣黏度大小会影响成渣带以下料柱的透气性,倘若炉渣黏度增加,其在滴落带不能顺利流动,导致焦炭骨架

的空隙度降低,煤气阻力增加,高炉下部压差发生波动,高炉顺行受到影响<sup>[21]</sup>。其次,炉渣黏度大小影响其脱硫能力,黏度低流动性好的炉渣有利于脱硫。而高炉外部对炉渣变化的直观表征为风温、风量、风压、煤量、氧量、顶压、顶温、炉顶煤气成分、冷却壁温度、冷却壁水温差、出铁时长、见渣时长、[S]等操作参数、状态参数以及指标参数的改变。

以上讨论表明,高炉的原料参数、操作参数、状态参数和指标参数均与高炉下部压差存在一定的联系,通过物质和能量流动的分析揭示了下面列出的参数是预测高炉下部压差的关键输入。

原料参数:烧结矿比例、球团矿比例、生矿比例、转鼓指数、筛分指数、抗压强度、矿石批重、焦炭负荷、冶炼周期。

操作参数:风量、净风量、风温、风压、喷煤量、富氧量、进水流量、下部水流量、上部水流量。

状态参数:顶温、顶压、标准风速、实际风速、边缘温度、进水温度、出水温度、下部水温差、上部水温差、炉腹煤气量、冷风温度、净煤气含尘量、荒煤气含尘量、净煤气压力、荒煤气压力、炉喉钢砖平均温度、出铁时长、出渣时长、见渣时长、出铁流速、炉顶煤气成分、炉顶十字测温。

指标参数: $[Si]$ 、 $[S]$ 、 $[Ti]$ 、 $(SiO_2)$ 、 $(CaO)$ 、 $(MgO)$ 、

$(Al_2O_3)$ 、 $(MnO)$ 、 $(FeO)$ 、 $(S)$ 、 $R^2$ 、 $Mg/Al$  和铁水温度。

### 3.2 数据集准备

一座高炉冶炼周期需要 8 h 左右的时间。在炼铁过程开始前首先需要确定一组原料参数,然后,沿着高炉系统的不同位置收集操作参数、状态参数和指标参数。在本研究中考虑了时间延时问题,使用了一种称为时间序列配准的方法来确定参数间的关联关系。图 2 对这个想法进行了说明。假设原料参数在时间  $t_0$  采集,一个操作参数(风量)在时间  $t_1$  采集,状态参数(顶温)在时间  $t_2$  采集,指标(铁水温度)在时间  $t_3$  采集。时间序列配准是将相关数据组合在一起,并同时考虑到不同数据点间延时关系的一种方式。




图 2 时间序列配准方法的说明

对收集一年多的高炉冶炼过程数据进行如下处理:首先,结合工艺经验删除合理范围之外的异常值;然后,采用取均值、填充等方式获得频次统一的参数数据;最后,根据时间序列配准法对原料参数、操作参数、状态参数以及指标参数进行关联,以确保正确执行参数间的相关性分析。

### 3.3 参数间的相关性分析

预测下部压差的模型采用 MIC 相关性<sup>[22]</sup>来分析输入与输出之间的关系,分析结果被用来减少模型的输入参数。常用的相关分析方法,如 Pearson 相关系数<sup>[23]</sup>、Spearman 相关系数<sup>[24]</sup>和 Kendall 相关系数等,前两种方法(Pearson 相关系数和 Spearman 相关系数)适用于变量间的线性相关性分析,而 Kendall 方法多用于类别数据的计算。但高炉冶炼过程数据大部分为连续型,且参数间关系呈复杂的非线性。因此,本研究采用了 MIC 方法,因为它专门用于大数据集变量间线性或非线性关系的挖掘分析。

MIC 基本原理利用到互信息概念,它将两个变量之间的关系离散在二维空间中,将二维空间在  $x$ 、 $y$  方向分别划分为一定的区间数,然后查看当前的散点在各个方格中落入的情况。MIC 的计算公式如下:

$$MIC(x; y) = \max_{a \times b < B} \frac{I(x; y)}{\log_2 \min(a, b)} \quad (1)$$

式中: $a$ 、 $b$  是在  $x$ 、 $y$  方向上的划分网格的个数,  $B$  是变量,本文设置为数据量的 0.6 次方。

采用 MIC 来分析原料参数、操作参数、状态参数和指

标参数与下部压差之间的关系,如表 1 所示。表 1 汇总了各个参数与下部压差间的 MIC 值以及非线性相关性排名,表中参数间的 MIC 值均  $\geq 0.1$ 。

由表 1 中的计算结果可知,原料参数对下部压差的影响最为显著,在相关系数排名前 10 位的参数集合中,原料参数占比达到 60%。在高炉冶炼过程中,入炉原料配比的改变会使得入炉碱度发生变化,而炉渣的生成和流动性受炉内碱度变化影响较大,进而造成下部压差发生波动。此外,炉料配比和矿石批重的改变对气流分布和料柱阻损也会产生一定的影响,同样也会使下部压差随之发生改变。所以,原料参数的变化将直接影响下部压差。而操作参数、状态参数和指标参数与下部压差间的关系相对较弱,但它们依然能够在一定程度上间接表征下部压差的变化。所以,初步将表 1 中的全部参数作为模型可能的输入,接下来结合压差预报模型的精度以及参数的相关性排名对模型输入进一步筛选。

## 4 压差预报模型的建立与优化

### 4.1 特征筛选

结合极限树集成算法模型的预报精度,采用向前选择法(即根据特征参数的排名顺序逐个引入回归方程)对变量进行筛选,以完成最优输入参数集合的选择。图 3 所示为特征筛选过程中极限树集成算法模型的交叉验证分数( $R^2$ )的变化趋势。

表 1 压差相关参数的非线性分析

参数类别	参数	MIC	排名	参数类别	参数	MIC	排名
原料参数	烧结矿比例	0.430	1	状态参数	净煤气压力	0.291	17
	冶炼周期	0.429	28		边缘温度	0.288	18
	转鼓指数	0.411	3		炉顶西北温度 3	0.285	19
	抗压强度	0.399	4		炉顶东北温度 4	0.279	20
	筛分指数	0.372	5		炉顶西南温度 1	0.262	21
	矿石批重	0.363	6		炉顶西北温度 1	0.255	22
	焦炭负荷	0.333	10		炉顶西北温度 4	0.252	23
	富氧量	0.327	12		炉顶东南温度 2	0.248	24
操作参数	净风量	0.208	2		炉顶东北温度 1	0.246	25
	上部水流量	0.188	31		炉顶东南温度 1	0.242	26
	进水流量	0.160	35		炉顶东北温度 2	0.210	27
	风压	0.159	36		冷风温度	0.202	29
	下部流量	0.151	37		炉顶东南温度 7	0.189	30
	风温	0.110	40		炉顶东北温度 5	0.169	32
	炉顶东南温度 6	0.352	7		炉顶西北温度 2	0.166	33
	炉喉钢砖	0.350	8		炉顶西南温度 5	0.166	34
状态参数	净煤气含尘量	0.337	9		炉顶煤气 H <sub>2</sub> 含量	0.126	38
	炉顶西南温度 4	0.331	11		炉顶西南温度 2	0.115	39
	炉顶西南温度 3	0.321	13		炉顶东南温度 3	0.109	41
	荒煤气压力	0.298	14		荒煤气含尘量	0.106	42
	顶压	0.297	15		指标参数	Mg/Al	0.103
	炉顶东北温度 3	0.292	16		—	—	43




图 3 特征参数数量与模型预报精度间的关系

由图 3(a)可知,模型交叉验证分数( $R^2$ )随特征参数数量的增加总体上呈上升趋势,而在局部区域(虚线方框标注区域)出现了下降的现象。为了验证虚线方框标注特征参数对于模型性能的影响程度,开展了对照组实验。将此部分特征参数删除后,测试了筛选过程中极限树集成算法模型的精度变化,如图 3(b)所示。由图 3(b)可知,将标注区域的参数剔除后,模型性能不但未降低,反而得到了一定的提升,这可能是由于标注区域参数使模型发生过拟合导致的。因此,为了消耗更少的计算资源并获得更高的模型精度,将图 3(b)中参与筛选的变量作为模型的输入,这些参数分别对应表 1 中排名第 1~20 和 33~43。

#### 4.2 模型建立与超参数优化


基于确定的模型输入参数,采用极限树集成算法建立了压差预报模型,模型的构建包括 3 部分:数据集的划分、模型超参数的优化以及模型的评价。

1) 采用随机取样的方式,将数据集中的样本按 8:2 的比例划分为训练集和测试集。为了便于管理,创建了两个数据表来管理输入和输出数据,且它们具有 1 对 1 的对应关系。


2) 本文研究使用 Python 的 sklearn 机器学习算法库建立了高炉下部压差预测模型。并采用网格搜索与交叉验证相结合的方式,依次对模型的决策树个数

(n\_estimators)、树的最大深度(max\_depth)、节点可分的最少样本数(min\_samples\_split)、叶子节点最少样本数


(min\_samples\_leaf)、最大特征数(max\_features)等超参数进行了优化,优化结果如图4所示。




(a) n\_estimators优化结果



(b) max\_depth与min\_samples\_split联合优化结果



(c) min\_samples\_split与min\_samples\_leaf联合优化结果



(d) max\_features优化结果

图4 极限树算法超参数优化结果


由图4可知,在对图(a)~(d)中的超参数优化过程中,当n\_estimators为10,max\_depth为7,min\_samples\_leaf为1,min\_samples\_split为3和max\_features为26时,基于训练集的下部压差预报模型性能( $R^2$ )达到最大。为此,基于上述确定的最优超参数集合建立了下部压差预报模型。

3)为了更准确地判断模型性能以及实际应用的泛化能

力,使用测试集样本对建立的下部压差预测模型进行了测试,并采用拟合优度( $R^2$ )、均方误差(MSE)和平均绝对误差(MAE)对模型进行评价,模型性能如表2和图5所示。

表2 下部压差预报模型的测试性能

评价指标	拟合优度	均方误差	平均绝对误差
测试性能	0.826 4	0.005 3	0.050 2



(a) 全部测试样本




图 5 预报模型测试结果的可视化

由图 5 可知, 测试集共包含数据 2 175 组, 为了更加直观地观察模型预测效果, 截取了分布于 1 250~1 750 的数据样本进行局部绘图展示, 如图 5(b) 所示。结合表 2 中给出的测试指标和图 5 展示的测试效果可知, 预测模型在提前预报下一小时的下部压差时, 具有良好的稳定性和较高的预报精度, 预报结果与实际值拟合效果  $R^2$  达到 0.826 4。因此, 通过上述建立的下部压差预测模型可以提前预判高炉运行状况, 对现场操作者及时调整布料方式和操作参数




图 6 模型预测值与实际值的误差分析

由图 6 可知, 与支持向量机和神经网络算法相比, 基于极限树集成学习算法建立的下部压差预报模型获得了更小的误差以及更优异的性能。因此, 该算法更适宜于针对高炉这种复杂、非线性系统的参数间规律挖掘与建模分析。

## 6 结 论


针对我高炉下部压差检测不及时容易导致高炉炉况波动的问题, 提出了基于集成学习极限树算法的高炉压差预报模型。解决了基于高炉系统在线采集数据建立预报模型提前预判下部压差的难题。

通过对高炉内部物质和能量流动的系统分析, 全面选取高炉原料参数、操作参数、状态参数和指标参数作为模型输入, 将下一小时的高炉下部压差为输出。采用变量相关性计算和向前特征选择法确定了模型的输入参数集合,

具有重要的指导意义。

## 5 模型比较

将采用集成学习算法建立的下部压差预报模型与传统算法(神经网络和支持向量)建立的模型进行了比较, 同样采用网格搜索和交叉验证的方法将传统算法模型的性能调整至最优。对比了 3 种模型预测值与实际值的误差, 结果如图 6 所示。



(b) 神经网络与极限树模型误差对比

通过对极限树集成算法超参数的迭代优化, 获得了模型的最优超参数集合, 使用该参数集合建立的下部压差预报模型精度  $R^2$  达到了 0.826 4, 且 MSE 接近零值。

与传统建模方法相比, 该研究方法构建的下部压差预报模型, 其预报精度和泛化能力进一步得到了提升。此模型的应用能够更加精准的指导现场操作者提前预判高炉运行状况, 对操作工长及时调整布料方式和操作参数具有重要的意义。

## 参考文献

- [1] TUNCKAYA Y. Performance assessment of permeability index prediction in an ironmaking process via soft computing techniques [J]. Journal of Engineering, 2017, 231(6): 1101-1113.
- [2] 周平, 张丽, 李温鹏, 等. 集成自编码与 PCA 的高炉多元铁水质量随机权神经网络建模[J]. 自动化学报,

- 2018, 44(10): 1799-1811.
- [3] 滕召杰, 陈建, 郭宏烈, 等. 首钢京唐1号高炉降低压差的措施[J]. 炼铁, 2019, 38(5): 38-41.
- [4] NISHIMURA T, HIGUCHI K, NAITO M, et al. Evaluation of softening, shrinking and melting reduction behavior of raw materials for blast furnace [J]. ISIJ International, 2011, 51(8): 1316-1321.
- [5] 李宏飞, 崔金丽. 静压差预判炉况技术在3 200 m<sup>3</sup>高炉上的应用[J]. 天津冶金, 2016(S1): 7-9, 12.
- [6] 杨鑫, 张军红, 金永龙, 等.  $6\sigma$ 方法在高炉炼铁压差分析中的应用[J]. 冶金能源, 2014, 33(1): 7-9, 22.
- [7] LI X L, LIU D X, JIA C, et al. Multi-model control of blast furnace burden surface based on fuzzy SVM[J]. Neurocomputing, 2015, 148: 209-215.
- [8] ADESANYA E, ALADEJARE A, ADEDIRAN A, et al. Predicting shrinkage of alkali-activated blast furnace-fly ash mortars using artificial neural network (ANN)[J]. Cement and Concrete Composites, 2021, 124: 104265.
- [9] 杨晓敏. 改进灰狼算法优化支持向量机的网络流量预测[J]. 电子测量与仪器学报, 2021, 35(3): 211-217.
- [10] 张淑清, 杨振宁, 张立国, 等. 基于弹性网降维及花授粉算法优化BP神经网络的短期电力负荷预测[J]. 仪器仪表学报, 2019, 40(7): 47-54.
- [11] 王帅哲, 王金梅, 王永奇, 等. 基于改进遗传算法的BP神经网络短期电力负荷预测[J]. 国外电子测量技术, 2019, 38(1): 15-18.
- [12] ZHOU P, SONG H, WANG H, et al. Data-driven nonlinear subspace modeling for prediction and control of molten iron quality indices in blast furnace ironmaking [J]. IEEE Transactions on Control Systems Technology, 2017, 25(5): 1761-1774.
- [13] 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): 55-63, 67.
- [14] 袁冬芳, 赵丽, 石琳, 等. 高炉铁水硅含量序列的支持向量机预测模型[J]. 太原理工大学学报, 2014, 45(5): 684-688.
- [15] 崔桂梅, 程史. 基于分布式神经网络模型的高炉炉温预测建模[J]. 钢铁研究学报, 2014, 26(6): 27-30.
- [16] LIU S, LYU Q, LIU X J, et al. Synthetically predicting the quality index of sinter using machine learning model[J]. Ironmaking & Steelmaking, 2020, 47(7): 828-836.
- [17] 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): 363-369.
- [18] 赵永龙. 无钟高炉布料优化控制的研究[D]. 秦皇岛: 燕山大学, 2018.
- [19] AHMAD M W, REYNOLDS J, REZGUI Y. Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees[J]. Journal of Cleaner Production, 2018, 203: 810-821.
- [20] 严照照, 张淑会, 董晓旭, 等. 高炉渣的化学成分对其微观结构影响的研究现状[J]. 矿产综合利用, 2019(1): 22-27.
- [21] 张强, 高斌, 丁建坤, 等. 软熔带形状参数对高炉下部压力场的影响[J]. 钢铁研究, 2012, 40(4): 21-24.
- [22] RESHEF D N, RESHEF Y A, FINUCANE H K, et al. Detecting novel associations in large data sets [J]. Science, 2011, 334(6062): 1518-1524.
- [23] MU Y S, LIU X D, WANG L D. A Pearson's correlation coefficient based decision tree and its parallel implementation [J]. Information Sciences, 2018, 435: 40-58.
- [24] PUTH M T, NEUHAUSER M, RUXTON G D. Effective use of Spearman's and Kendall's correlation coefficients for association between two measured traits[J]. Animal Behaviour, 2015, 102: 77-84.

### 作者简介

- 刘颂, 博士, 讲师, 主要研究方向为铁前大数据分析、冶金智能化等。  
E-mail: neversettle0722@163.com
- 赵亚迪, 硕士, 助教, 主要研究方向为机器视觉、机器学习算法。  
E-mail: didis911229@163.com
- 张振, 硕士, 主要研究方向为机器学习和深度学习算法。  
E-mail: 1973054200@qq.com
- 刘小杰, 博士, 副教授, 主要研究方向为炼铁理论与工艺、冶金智能化。  
E-mail: 315173781@qq.com
- 刘然, 博士, 教授, 主要研究方向为炼铁原料及工艺优化、冶金资源综合利用。  
E-mail: lr819@163.com
- 吕庆, 博士, 教授, 主要研究方向为炼铁理论与工艺、冶金智能化。  
E-mail: luqingts@163.com