

引用格式:刘鑫,苏彦敏,陈永强,等.底吹炉氧枪的数值模拟计算与快速预测[J].有色设备,2025,39(3):60-68.

LIU Xin, SU Yanmin, CHEN Yongqiang, et al. Numerical simulation calculation and rapid prediction of oxygen injector in bottom blowing furnace[J]. Nonferrous Metallurgical Equipment, 2025, 39(3): 58-66.

底吹炉氧枪的数值模拟计算与快速预测

刘鑫¹, 苏彦敏², 陈永强^{1*}, 王维¹, 蔡笑怡¹, 赵洪亮¹

(1. 北京科技大学 冶金与生态工程学院, 北京 100083;

2. 新疆有色金属工业(集团)有限责任公司, 新疆 乌鲁木齐 830000)

[摘要] 底吹炉内的氧枪为浸没式氧枪,其出口气流状态对底吹炉熔炼过程起决定性作用,但氧枪出口信息无法直接检测。本文利用数值模拟研究方法,并将数值模拟与机器学习相结合,设计正交试验,采用矩阵分析法,对氧枪出口信息进行计算和预测。主要研究气流量、氧枪角度和底吹炉液位对氧枪出口速度、出口压力和出口温度的影响及影响权重。结果表明,气流量对氧枪出口状态的综合影响最大,而氧枪旋转角度影响最小,高流量、高液位和低氧枪倾角的情况下氧枪出口的气流状态最好。同时采用 KNN 算法建立快速预测模型,结果表明预测工况与实际计算工况的各项指标的回归系数 R^2 可达到 0.998,预测精度较高,预测模型准确且可靠。

[关键词] 底吹炉氧枪; 数值模拟; 正交试验; 矩阵分析法; KNN 算法; 铜冶炼

[中图分类号] TF811 **[文献标志码]** A **[文章编号]** 1003-8884(2025)03-0060-68

DOI:10.19611/j.cnki.cn11-2919/tg.2025.03.006

0 前言

底吹炼铜工艺对原料的适应能力强,能源消耗低,余热回收效果好,熔炼效率高,近几年逐渐成熟^[1-4]。大型富氧底吹熔池熔炼炉是一个可转动的卧式圆筒形熔炼炉,其中氧枪作为富氧底吹炉中的重要设备之一,以浸没式安插在底吹炉的底部。通过调整氧枪的参数,可以实现对喷入炉内的富氧气体的状态的控制,从而提高底吹炉的熔炼效率。由于氧枪以浸没式插入炉内,故在底吹炉运行过程中,氧枪的出口信息是无法直接监测的,工作人员通常只能通过理论计算来估算氧枪出口的富氧气体的大致状态。但氧枪内部的单相流流动过程是复杂的,所以理论计算得到的结果通常会有偏差。目前,可使用计算流体动力学(CFD)方法对氧枪流动过程进行模拟计算,通过此方法可直观观察到氧枪出口面的各种信息,同时可以将炉内各参数与炉内各处的流动特性建立关系,从而更好地做出调控。

如今,机器学习已被应用于冶金领域,以提高材料性能,优化生产工艺,提高产品质量和降低成本^[5-9]。Qin 等^[10]收集 8371 组关于成分和相位信息的数据作为训练数据,通过机器学习的方法分析并建立了一个 ML 模型,用于预测多组分镍基高温合金中的成分与有害相之间的关系,发现 K 最邻近(KNN)算法在此研究中预测精度高,可信度较高。Xia 等^[11]利用支持向量回归(SVM)、神经网络和随机森林,通过 32 组数据建立了铜铝复合材料界面强度和工艺参数的预测模型。Gebhardt 等^[12]选取 70 个模拟数据作为训练样本,采用数据驱动的机器学习方法,通过简化残差神经网络预测了疲劳强度。研究表明此方法节省了大量计算成本,预测结果良好。另外,机器学习与 CFD 结合的分析方法也广泛应用于预测多孔介质。Marcato 等^[13]对 CFD 模拟的数据集进行训练,并利用全连接(FCNN)和卷积神经网络(CNN)对多孔介质的渗透率和过滤速率进行预测。训练模型可在多尺度建模、优化问题

[收稿日期] 2025-01-22

[基金项目] 国家重点研发计划(2022YFC2904205);国家重点研发计划(2022YFB3304901)。

[第一作者] 刘鑫(2000—),男,内蒙古兴安盟人,硕士研究生,主要研究方向为铜底吹数值模拟。

[通信作者] 陈永强(1972—),男,山东德州人,博士,教授,主要研究方向为复杂多元有色金属矿产资源综合利用。

和在线控制中得到应用。Yasuda 等^[14]提出了一种材料发现框架,使用了基于 CFD 和 SVM 的多目标遗传算法,进一步优化粒径、颗粒形状等设计变量,从而使多孔材料的最佳渗透率和过滤效率最大化。

目前常用的机器学习方法包括 KNN、SVM、神经网络、随机森林和其他算法^[15]。KNN 算法作为一种惰性学习算法和基于实例的学习算法,主要用分类和非参数统计回归方法,搜索最接近测试样本的 K 个训练样本进行预测,该算法相对简单,也是用于回归和分类的最直接的机器学习算法之一^[16-18]。KNN 算法也在逐渐增强改进。比如,加权 KNN 算法根据采样点之间的距离分配权重,与标准 KNN 相比,引入权重提高了分类性能。使用加权 KNN 算法编辑数据集也可避免过拟合,从而提高训练数据的质量^[19-20]。

综上,机器学习的引入有助于试验分析,但是机器学习中建立数据库需要大量的时间和储存空间,本文采用正交试验建立数据库,用 CFD 与机器学习相结合的方法,构建底吹炉氧枪的预测模型。

1 模型建立与求解

1.1 几何模型与网格模型

以大型富氧底吹熔池熔炼炉的底吹氧枪为原型,利用 SpaceClaim 建立 1:1 几何模型,几何模型如图 1 所示。建模过程中仅对氧枪前端的空气入口通道和氧气入口通道进行适当简化,保留入口面,其余部分均不做简化。利用 ICEM 进行网格划分,均采用六面体网格,对氧枪出口面及附近流体域进行网格加密,以便提高计算的精确性。网格数量最终确定为 270 万左右,质量均为 0.6 以上,网格经过无关性验证,确保在减小计算量的同时,满足计算要求。

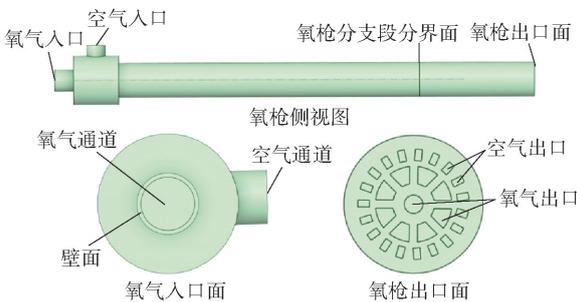


图 1 底吹炉中氧枪几何模型

Fig. 1 Geometry of the oxygen lance in the bottom-blown furnace

1.2 数学模型

1.2.1 控制方程

氧枪内部流动过程属于典型的可压缩流动过程,故采用可压缩流动方程组对流动过程进行描述。对于可压缩流动过程,控制方程的通用形式描述为式(1)。

$$\frac{\partial(\rho\phi)}{\partial t} + \frac{\partial(\rho u_j\phi)}{\partial x_j} = \frac{\partial}{\partial x_j} \left(\Gamma_\phi \frac{\partial\phi}{\partial x_j} \right) + S_\phi \quad (1)$$

式中: ϕ 、 Γ_ϕ 和 S_ϕ 按照表 1 取值。

表 1 流动控制方程

Table 1 Governing equations of flow

项目	ϕ	Γ_ϕ	S_ϕ
连续性方程	1	0	0
x 方向动量方程	u	μ	$\rho f_x - \frac{\partial p}{\partial x}$
y 方向动量方程	v	μ	$\rho f_y - \frac{\partial p}{\partial y}$
z 方向动量方程	w	μ	$\rho f_z - \frac{\partial p}{\partial z}$
能量方程	T	λ/c_p	S_T/c_p

1.2.2 湍流模型

本文中的湍流模型均选用标准 $k-\varepsilon$ 双方程模型。湍动能方程(k 方程)见式(2)。

$$\frac{\partial(\rho k)}{\partial t} + \frac{\partial(\rho k u_i)}{\partial x_i} = \frac{\partial}{\partial x_j} \left[\left(\mu + \frac{\mu_t}{\sigma_k} \right) \frac{\partial k}{\partial x_j} \right] + G_k + G_b - \rho\varepsilon - Y_M + S_k \quad (2)$$

湍流耗散率方程(ε 方程)见式(3)。

$$\frac{\partial(\rho\varepsilon)}{\partial t} + \frac{\partial(\rho\varepsilon u_i)}{\partial x_i} = \frac{\partial}{\partial x_j} \left[\left(\mu + \frac{\mu_t}{\sigma_\varepsilon} \right) \frac{\partial\varepsilon}{\partial x_j} \right] + C_{1\varepsilon} \frac{\varepsilon}{k} (G_k + C_{3\varepsilon} G_b) - C_{2\varepsilon} \rho \frac{\varepsilon^2}{k} + S_\varepsilon \quad (3)$$

式中: $C_{1\varepsilon}$ 、 $C_{2\varepsilon}$ 和 $C_{3\varepsilon}$ 均为经验常数,分别为 1.44、1.92、0.09; σ_k 、 σ_ε 分别为湍动能 k 和湍流耗散率 ε 对应的普朗特数, $\sigma_k = 1.0$, $\sigma_\varepsilon = 1.3$; S_k 为用户自定义湍动能源项, S_ε 为用户自定义湍流耗散率源项; G_b 为浮力引起的湍动能的产生项, G_k 为速度梯度引起的应力源项; Y_M 为可压缩流中脉动的扩张项; μ_t 为湍流涡黏系数。

1.2.3 边界条件设置

氧枪入口设置为质量入口边界条件。内层通道气体为氧气,质量流率为 0.427 kg/s,外层通道气体为空气,质量流率为 0.207 kg/s。内外通道入口压力相同,均为 0.6 MPa。内外通道气体均设置为

理想可压缩气体。氧枪出口设置为压力出口边界条件,内外通道出口压力相同。

实际工业生产中,氧枪作为浸没式氧枪,浸没深度为 0.1 m,受到周围高温熔体长时间的热量传递,氧枪前端浸没于熔池内的外壁面与熔体温度相近,而氧枪入口持续鼓入常温气体,故两端外壁面形成温度差,近似认为外壁面温度呈直线变化方式分布。氧枪壁面采用标准壁面函数,并利用 udf 设置氧枪外壁面温度如图 2 所示,内部壁面均设置为耦合传热方式。壁面摩擦系数为 0.5。外壁面温度沿轴向方向(y 方向)分布函数见式(4)。

$$T = \begin{cases} 1453, & -0.1 \leq y \leq 0 \\ 1453 - 1573 \times (-0.1 - y), & y < -0.1 \end{cases} \quad (4)$$

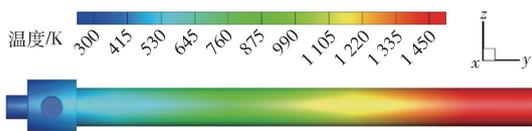


图 2 氧枪外壁面温度分布云图

Fig. 2 Diagram of temperature distribution on the outer wall of the oxygen lance

1.3 正交试验

在对底吹炉中氧枪的正交试验设计中,选取了 3 个对氧枪有不同程度影响的因素,即进气量(Q)、氧枪角度(θ)和液位(h)^[21-23]。建立三因素四水平正交试验方案,因素水平表及正交试验设计表见表 2。通过正交试验设计,采用矩阵分析法^[24],综合分析多个因素与指标,构建模型训练数据集,进而确定各因素的权重。

表 2 正交试验中的因素水平表

Table 2 Table of factor levels in orthogonal experiments

水平	因素		
	进气量 $Q/(m^3 \cdot h^{-1})$	氧枪角度 $\theta/(^\circ)$	液位 h/m
1	47 500(单支流量 1696)	5	1.72
2	50 000(单支流量 1785)	7	1.85
3	52 500(单支流量 1875)	9	1.98
4	55 000(单支流量 1964)	11	2.12

目前计算权重的方法有很多,如主观赋权法、客观赋权法、综合赋权法,矩阵分析法属于主观赋权法的一种,是通过构建矩阵模型来分析复杂问题的方

法。矩阵分析法的优势包括:①直观性,将不同因素通过矩阵的形式展现,可直观地体现不同因素之间的关系;②多维性,可同时考察多个因素,确定不同因素在同一指标上的作用;③系统化和结构化,将复杂问题转化为简单的矩阵运算问题,量化影响权重,使分析过程更有条理;④适用范围广,矩阵分析法可应用于冶金领域,在经济学、管理学等多个领域也发挥着重要的作用。因此,本文使用矩阵分析法计算综合权重。

1.4 试验指标

试验指标可衡量和判断各种因素对结果的影响程度,选取合适的试验指标可提高评判结果的准确性。氧枪出口喷出的富氧气体的状态直接影响着底吹炉吹炼的强度和效率,对氧枪出口的富氧气体的状态可用出口速度、出口压力和出口温度来描述。由于富氧气体的主要作用是向熔体分子传递动量并作为氧化剂参加炉内多相间的化学反应,因此出口速度能够反应氧枪的喷吹强度,当出口速度越大,气体分子携带的动量越多,更多更远的熔体分子也会获更多的动量,因此认为出口速度越大越好。氧枪出口也需要一定的压力保证富氧气体正常的喷出,同时要防止熔体回流至底吹氧枪内,以免造成氧枪堵塞并损坏氧枪,故认为出口压力越大越好。氧枪出口温度通常受氧枪内部流动过程中氧枪壁面温度的影响,氧枪出口温度高可以表明在氧枪内部流动过程中气体带走了氧枪壁面更多的热量,从而达到保护氧枪的效果,同时氧枪出口的富氧气体温度高有利于气体在熔体中的扩散,因此出口温度越大,吹炼效果也会更好。

1.5 KNN 算法与预测模型评估

KNN 算法的核心在于计算目标样本与训练样本之间的距离,通过筛选出与目标样本距离最近的 k 个训练样本,利用这些最近邻样本的加权平均值来预测目标样本的值。该算法通过查找近邻工况和近邻数据点,完成对未知工况的插值计算,进而实现核心算法程序的设计^[25]。在本研究中,距离计算过程综合考虑了不同因素的权重以及每个因素相邻水平间的差值大小,并对工况间的距离 r 进行归一化和加权处理。计算工况间距离 r 见式(5)。

$$r = \frac{W_Q \Delta r_Q}{\Delta N_Q} + \frac{W_\theta \Delta r_\theta}{\Delta N_\theta} + \frac{W_h \Delta r_h}{\Delta N_h} \quad (5)$$

式中: W_Q 为进气量权重; W_θ 为氧枪角度权重; W_h 为液位权重; Δr_Q 、 Δr_θ 、 Δr_h 分别为邻近工况与目标工

况在进气量、氧枪角度和液位 3 个因素上的间隔大小; ΔN_Q 、 ΔN_θ 、 ΔN_h 分别为正交表中每个因素的相邻水平的间隔。

选用平均绝对误差 (MAE)、均方根误差 (RMSE) 和回归系数 (R^2) 作为预测结果的评价指标,用 MAE 和 RMSE 来衡量预测值与真实值的偏差,用 R^2 来确定模型拟合的程度,接近 1 表示性能优秀。计算公式见式(6)~(8)。

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

式中: n 为样本的数量; \hat{y}_i 为预测值; y_i 为样本真实值; \bar{y} 为样本真实值的平均值。

2 结果与讨论

2.1 结果统计

本研究设计 16 个工况并由其组成训练数据集。氧枪的内部通道分为空气通道和氧气通道 2 个通道,由于实际生产中需要控制氧枪喷出的富氧气体的浓度,所以 2 个通道的流量不同,另外不同的通道的出口面积也有差别,从而导致在不同通道中氧枪的出口速度不同。由于气体在氧枪内部流动过程中,气体分子会与壁面产生摩擦力,也会造成 1 个通道出口处的速度呈中心高、四周较低的规律分布。壁面向气体的传热过程也会造成氧枪出口面的速度、温度等分布不均。故采用面积加权平均的计算方法对氧枪出口速度、出口压力和出口温度进行提取,结果见表 3,再采用矩阵分析法对数据进行分析处理,明确不同因素对氧枪出口信息的影响权重,为后续优化提供理论依据。

表 3 氧枪计算结果统计表

Table 3 Statistical table of the calculation results of the oxygen lance

序号	进气量 $Q/$ ($\text{m}^3 \cdot \text{h}^{-1}$)	氧枪角度 $\theta/(\circ)$	液位 h/m	出口速度/ ($\text{m} \cdot \text{s}^{-1}$)	出口压力/ Pa	出口温度/ K
1	1	1	1	199.1	367 493.5	285.4
2	1	2	2	197.1	372 442.9	285.8
3	1	3	3	194.3	377 503	286.3
4	1	4	4	192.0	382 590.8	286.7
5	2	1	2	204.7	372 805.3	284.3
6	2	2	1	207.7	367 194.5	283.4
7	2	3	4	200.4	383 192.8	285.1
8	2	4	3	202.5	376 901	285.8
9	3	1	3	210.0	378 348	284.1
10	3	2	4	207.5	383 675.3	284.9
11	3	3	1	215.7	366 712	282.8
12	3	4	2	214.5	371 358.3	282.2
13	4	1	4	216.4	384 037.7	281.9
14	4	2	3	219.5	377 985.5	280.8
15	4	3	2	221.6	371 960.4	280.3
16	4	4	1	225.7	366 110	279.3

按照矩阵分析法对正交实验设计进行优化,将其划分为试验评判指标层、因素层、水平层 3 层数据

结构模型见表 4。

1) 试验评判指标层 (M)。作正交试验设计中

表4 三因素四水平的相应评判指标的平均值

(g_{ij} 和 s_i)

Table 4 The average of the corresponding judging indicators at the level of three factors and four levels (g_{ij} 和 s_i)

评判指标	水平	因素		
		进气量 $Q/$ ($m^3 \cdot h^{-1}$)	氧枪角度 $\theta/(^\circ)$	液位 h/m
出口速度	K1	195.6	207.6	212.1
	K2	203.8	208	209.5
	K3	211.9	208	206.6
	K4	220.8	208.7	204.1
	R	25.2	1.1	8
出口压力	K1	375 007.6	375 671.1	366 877.5
	K2	375 023.4	375 324.6	372 141.7
	K3	375 023.4	374 842.1	377 684.4
	K4	375 234.4	374 240	383 374.2
	R	15.8	1 431.1	16 496.7
出口温度	K1	286.1	283.9	282.7
	K2	284.7	283.7	283.2
	K3	283.5	283.6	284.3
	K4	280.6	283.5	284.7
	R	5.5	0.4	2

的第 i 个因素的第 j 个水平上的评判指标的平均值 g_{ij} , 如果评判指标越大越好, 令 $G_{ij} = g_{ij}$, 如果评判指标越小越好, 令 $G_{ij} = 1/g_{ij}$, 用于构建试验指标的矩阵见式(9)。

$$M = \begin{bmatrix} G_{11} & 0 & 0 \\ G_{12} & 0 & 0 \\ G_{13} & 0 & 0 \\ G_{14} & 0 & 0 \\ 0 & G_{21} & 0 \\ 0 & G_{22} & 0 \\ 0 & G_{23} & 0 \\ 0 & G_{24} & 0 \\ 0 & 0 & G_{31} \\ 0 & 0 & G_{32} \\ 0 & 0 & G_{33} \\ 0 & 0 & G_{34} \end{bmatrix} \quad (9)$$

2) 因素层矩阵(T)。令 $T_i = 1 / \sum_{j=1}^3 G_{ij}$, 建立矩阵见式(10)。

$$T = \begin{bmatrix} T1 & 0 & 0 \\ 0 & T2 & 0 \\ 0 & 0 & T3 \end{bmatrix} \quad (10)$$

3) 水平层矩阵(S)。令正交试验中第 i 个因素的极差为 s_i , $S_i = s_i / \sum_{i=1}^3 s_i$, 建立矩阵见式(11)。

$$S = \begin{bmatrix} S1 \\ S2 \\ S3 \end{bmatrix} \quad (11)$$

影响评判指标值的权矩阵(ω)。 $\omega = MTS$ 。

分别计算出口速度 ω_1 、出口压力 ω_2 和出口温度 ω_3 。计算结果见式(12)。

$$\omega_1 = \begin{bmatrix} 0.172664 \\ 0.179902 \\ 0.187051 \\ 0.194884 \\ 0.008186 \\ 0.008202 \\ 0.008204 \\ 0.008231 \\ 0.059289 \\ 0.058569 \\ 0.057759 \\ 0.05706 \end{bmatrix} \quad \omega_2 = \begin{bmatrix} 0.000221 \\ 0.000221 \\ 0.000221 \\ 0.000220 \\ 0.019974 \\ 0.019955 \\ 0.019929 \\ 0.019897 \\ 0.22485 \\ 0.228077 \\ 0.231474 \\ 0.234961 \end{bmatrix} \quad \omega_3 = \begin{bmatrix} 0.176373 \\ 0.17551 \\ 0.174801 \\ 0.172997 \\ 0.013589 \\ 0.01358 \\ 0.013575 \\ 0.013569 \\ 0.061292 \\ 0.061384 \\ 0.061622 \\ 0.061709 \end{bmatrix} \quad (12)$$

将不同因素对评判指标的影响权重进行量化统计, 并确定了不同因素的优先级。对式(12)中的3个指标的权重取平均值得到综合权重, 得到式(13)。

$$\omega = \frac{\omega_1 + \omega_2 + \omega_3}{3} = \begin{bmatrix} 0.116419 \\ 0.118544 \\ 0.120691 \\ 0.1227 \\ 0.013916 \\ 0.013912 \\ 0.013903 \\ 0.013899 \\ 0.115144 \\ 0.11601 \\ 0.116952 \\ 0.11791 \end{bmatrix} = \begin{bmatrix} Q_1 \\ Q_2 \\ Q_3 \\ Q_4 \\ \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \\ h_1 \\ h_2 \\ h_3 \\ h_4 \end{bmatrix} \quad (13)$$

对各评判指标取平均值得出综合权重 ω 。氧枪

最佳出口状态的最佳组合为 $Q_4 \theta_1 h_4$, 即流量 $Q = 55\ 000\ \text{m}^3/\text{h}$ 、氧枪角度 $\theta = 5^\circ$ 和液位 $h = 2.12\ \text{m}$ 。图 3 展示了 3 个指标在不同因素水平下的综合权重变化, 可以看出气体流量和液位越大, 对氧枪出口气流状态的改善效果越好, 而氧枪倾角越小, 气流状态越好。其中, Q_4 的影响最大, θ_4 的影响最小。

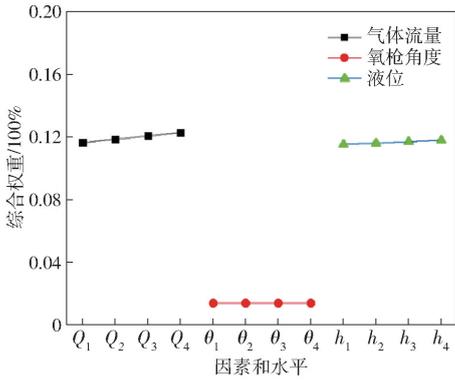


图 3 三因素四水平对氧枪出口状态的综合权重

Fig. 3 The comprehensive weight of three factors and four levels on the export state of the oxygen lance

2.2 预测模型

本研究基于正交分析得到的 16 组工况数据以及矩阵分析法确定的因素权重, 运用 K-最近邻算法 (KNN) 对任意目标工况进行预测分析。该方法不仅充分考虑了预测样本与邻近工况的距离, 还体现了因素与因素、水平与水平之间的内在联系, 进而提升了预测的准确性和可靠性。

本研究中设计 2 个预测工况, 分别为: ①进气量 $52\ 500\ \text{m}^3/\text{h}$ (单支氧枪 $1\ 875\ \text{m}^3/\text{h}$), 氧枪角度 7° , 渣液位 $1.72\ \text{m}$; ②进气量 $51\ 500\ \text{m}^3/\text{h}$ (单支氧枪 $1\ 839.3\ \text{m}^3/\text{h}$), 氧枪角度 8° , 渣液位 $1.98\ \text{m}$ 。将预测结果与 CFD 计算的结果从定性和定量的角度进行分析。

通过对比 2 个预测工况下的 CFD 计算结果和预测模型结果, 可以从氧枪内速度场、温度场等多方面对比观察, 本研究中只对速度场进行对比分析。图 4 和图 5 为工况①在实际工况下和预测结果中的出口速度云图和氧枪内部某一轴向截面的速度云图, 可见同一区域的速度分布规律基本一致, 且工况

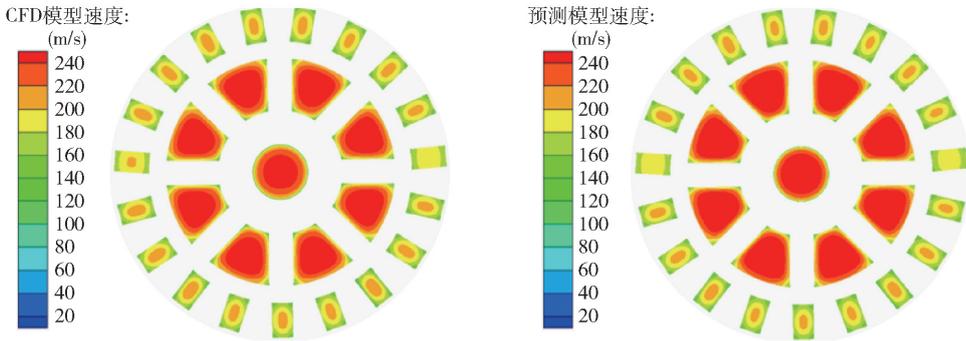


图 4 预测工况①的 CFD 模型 (左) 与预测模型 (右) 氧枪出口速度分布

Fig. 4 CFD model (left) vs. predicted model (right) oxygen lance outlet velocity distribution for predicted operating condition ①

②的预测结果和 CFD 计算结果对比中表明速度分布规律也与此相同, 表明此预测模型可以很好地预测氧枪内部及出口的气体状态和特征。

对 2 个预测工况各选取轴向方向 (y 轴方向) 一条线, 提取线上各点的速度, 并对氧枪内部及出口面进行定量分析。结果表明, 2 个预测工况下的预测结果与实际计算结果中的整体趋势基本相同, 只有靠近出口的速度大小略有不同, 计算得到预测值回归系数分别达到 0.988 和 0.989, 进一步验证了本研究中建立的预测模型的准确性。

另外, 研究中还分析了最邻近数量 (K 值) 对氧枪速度场预测结果的准确性的影响。分别选取最邻近数量为 3 ~ 6, 计算平均绝对误差 MAE 、均方根误差 $RMSE$ 和回归系数 R^2 。由表 5、表 6 可见, 当 K 取值在 3 ~ 6 时, 各项指标均显示预测结果具有较高的准确性, 但是回归系数并不是单纯地随着最邻近数量的增加而增大, 换句话说, 并不是所选最邻近数量越多, 预测结果就越准确, 预测结果的准确性主要是与预测工况和数据集样本的距离有关, 因此为提高预测结果的准确性, 可以通过增加数据集样本和

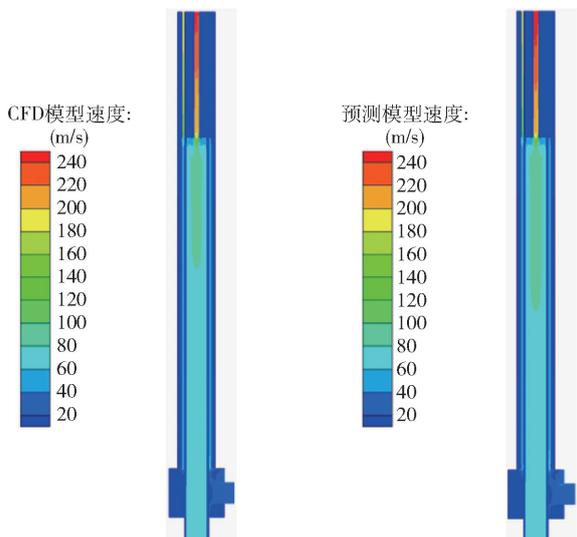


图 5 预测工况①的 CFD 模型(左)与预测模型(右)氧枪内部截面速度分布

Fig. 5 The velocity distribution of the internal section of the oxygen lance in the CFD model (left) and the predictive model (right) of the predicted working condition ①

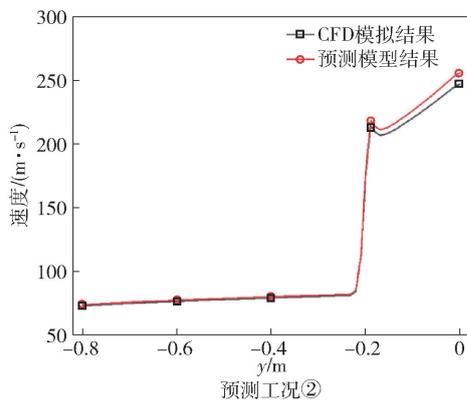
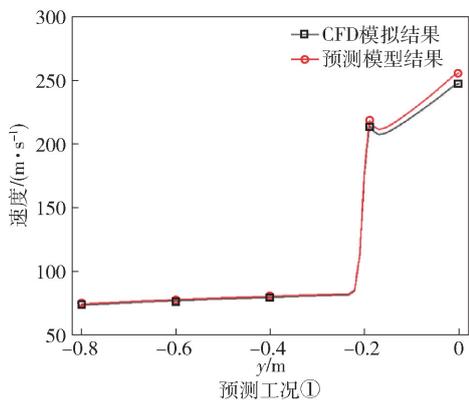


图 6 两个预测工况中 CFD 计算结果和预测模型结果的氧枪轴向速度

Fig. 6 The axial velocity of the oxygen lance for the CFD calculations and the prediction model results for the two prediction cases

增加最邻近数量的方式实现。在本文的研究中,选择 6 个最近邻工况时,回归系数 R^2 最接近 1,表明此时模型的预测效果最优。这一结果进一步验证了基于 KNN 最近邻算法建立的预测模型的合理性和可靠性。

3 结论

面对难以直接监测的氧枪出口气流状态,本文通过数值模拟对正常运行状态下的氧枪出口进行计算。为了解决数值模拟过程计算时间长、耗费成本大的问题,本研究采用了一种将 CFD 计算与机器学习相结合的方法。文中设计了三因素四水平的正交试验,计算了 16 个训练工况和 2 个验证工况。研究了不同气流量、氧枪角度和液位对氧枪出口速度、出口压力和出口温度的影响,并通过矩阵分析法计算了影响权重,同时利用了 KNN 算法构建了氧枪出口状态信息的快速预测模型。主要结论如下。

1) 基于矩阵分析法,分析了不同因素对不同评判指标的影响,并计算权重。其中,影响氧枪出口速

表 5 预测工况①中不同 K 值下不同预测效果统计

Table 5 Statistics of different prediction effects under different K values in the prediction condition ①

K 取值	MAE	RMSE	R^2
K = 3	0.274 653 83	0.678 368 97	0.998 922 32
K = 4	0.279 856 46	0.734 568 77	0.998 755 62
K = 5	0.276 963 45	0.695 687 89	0.998 804 25
K = 6	0.272 456 87	0.645 876 58	0.998 924 75

表 6 预测工况②中不同 K 值下不同预测效果统计

Table 6 Statistics of different prediction effects under different K values in the prediction condition ②

K 取值	MAE	RMSE	R^2
K = 3	0.274 564 89	0.678 354 68	0.998 376 46
K = 4	0.279 565 35	0.735 674 56	0.998 157 94
K = 5	0.276 896 64	0.695 784 38	0.998 221 69
K = 6	0.272 498 67	0.645 976 54	0.998 382 37

度和出口温度的关键因素是气体流量,影响氧枪出口压力最大的是液位,同时,气流量和液位对氧枪出口状态的综合影响相差不大,而氧枪旋转角度对氧枪出口的气流各项指标的影响均最小。在计算范围内,得出最佳组合 $Q=55\ 000\ \text{m}^3/\text{h}$ 、 $\theta=5^\circ$ 和 $h=2.12\ \text{m}$ 。在高流量、高液位和低氧枪倾角的情况下氧枪出口的气流状态最好。

2)利用 KNN 算法,建立快速预测模型,并对氧枪内部及出口信息进行预测。对比 2 个预测工况和相应的实际计算工况的多处速度场分布,并定量分析得出轴向速度的 R^2 分别为 0.988 和 0.989,对比得出特征信息拟合度较高,证明快速预测模型准确且可靠。同时分析了最邻近数量(K 值)对速度场预测结果的精确性,研究发现,选取 6 个最邻近工况时,回归系数 R^2 值最接近 1,此时预测模型的预测精度较高。

[参考文献]

- [1] 崔志祥,申殿邦,王智,等.富氧底吹熔池炼铜的理论与实践[J].中国有色冶金,2010,39(6):21-26.
- [2] 崔志祥,申殿邦,王智,等.低碳经济与氧气底吹熔池炼铜新工艺[J].有色冶金节能,2011,27(1):17-20.
- [3] Chen L, Hao Z, Yang T, et al. A comparison study of the oxygen-rich side blow furnace and the oxygen-rich bottom blow furnace for liquid high lead slag reduction[J]. JOM, 2015, 67: 1123-1129.
- [4] Wang Q M, Guo X Y, Tian Q H. Copper smelting mechanism in oxygen bottom-blown furnace[J]. Transactions of Nonferrous Metals Society of China, 2017, 27(4): 946-953.
- [5] Gu M, Xu A, Yuan F, et al. An improved CBR model using time-series data for predicting the end-point of a converter[J]. ISIJ International, 2021, 61(10): 2564-2570.
- [6] He F, Zhang L. Prediction model of end-point phosphorus content in BOF steelmaking process based on PCA and BP neural network[J]. Journal of Process Control. 2018. 66: 51-58.
- [7] Feng K, Xu A, He D, et al. An improved CBR model based on mechanistic model similarity for predicting end phosphorus content in dephosphorization converter[J]. Steel Research International, 2018, 89(6): 1800063.
- [8] Zhang R, Yang J. State of the art in applications of machine learning in steelmaking process modeling[J]. International Journal of Minerals, Metallurgy and Materials, 2023, 30(11):2055-2075.
- [9] Pan G F, Wang F Y, Hang C L, et al. Advances in machine learning and artificial intelligence-assisted material design of steels[J]. Int. J. Miner. Metall. Mater., 2023, 30(6): 1003.
- [10] Qin Z, Wang Z, Wang Y, et al. Phase prediction of Ni-base superalloys via high-throughput experiments and machine learning[J]. Materials Research Letters, 2021, 9(1): 32-40.
- [11] Xia Z, Zhao F, Liu X H, et al. Prediction of interface structure and properties of Cu-Al composites assisted by machine learning[J]. Chin. J. Nonferrous Met., 2023, 33(1): 88.
- [12] Gebhardt C, Trimbom T, Weber F, et al. Simplified ResNet approach for data driven prediction of microstructure-fatigue relationship[J]. Mechanics of Materials, 2020, 151: 103625.
- [13] A. Marcato, G. Boccoardo, and D. Marchisio, From computational fluid dynamics to structure interpretation via neural networks: An application to flow and transport in porous media[J]. Ind. Eng. Chem. Res., 2022, 61(24) 8530.
- [14] T. Yasuda, S. Ookawara, S. Yoshikawa, and H. Matsumoto, Materials processing model-driven discovery framework for porous materials using machine learning and genetic algorithm: A focus on optimization of permeability and filtration efficiency[J]. Chem. Eng. J., 453(2023), art. No. 139540.
- [15] F. Modaresi, S. Araghinejad, and K. Ebrahimi, A comparative assessment of artificial neural network, generalized regression neural network, least-square support vector regression, and K-nearest neighbor regression for monthly streamflow forecasting in linear and nonlinear conditions[J]. Water Resour. Manage., 32(2018), No. 1, p. 243.
- [16] Regression N. An Introduction to Kernel and Nearest-Neighbor[J]. The American Statistician, 1992, 46(3): 175-185.
- [17] Panchigar D, Kar K, Shukla S, et al. Machine learning-based CFD simulations: a review, models, open threats, and future tactics[J]. Neural Computing and Applications, 2022, 34(24): 21677-21700.
- [18] Mohammadpour J, Husain S, Salehi F, et al. Machine learning regression-CFD models for the nanofluid heat transfer of a microchannel heat sink with double synthetic jets[J]. International Communications in Heat and Mass

- Transfer, 2022, 130: 105808.
- [19] Kamarol S K A, Jaward M H, Kälviäinen H, et al. Joint facial expression recognition and intensity estimation based on weighted votes of image sequences[J]. Pattern Recognition Letters, 2017, 92: 25 – 32.
- [20] Gao Y, Gao F. Edited AdaBoost by weighted KNN[J]. Neurocomputing, 2010, 73(16 – 18): 3079 – 3088.
- [21] 段景堂, 李小兵, 夏振荣. 富氧底吹熔炼中氧枪角度的新技术探讨[C]//中国有色金属学会重冶学委会. 中国首届熔池熔炼技术及装备专题研讨会论文集. 万洋冶炼(集团)有限公司; 万洋冶炼(集团)有限公司; 万洋冶炼(集团)有限公司; ,2007:186 – 189.
- [22] 穆亮照, 赵洪亮, 王正, 等. 大型富氧底吹铜熔炼炉气- 铕-渣多相流模拟及澄清区优化研究[J]. 有色金属(冶炼部分), 2021(1): 1 – 9.
- [23] 余跃. 气体流量对底吹炼铜炉吹炼过程的影响[J]. 有色金属(冶炼部分), 2020(8): 1 – 8.
- [24] 魏效玲, 薛冰军, 赵强. 基于正交试验设计的多指标优化方法研究 [J]. 河北工程大学学报(自然科学版), 2010, 27(3): 95 – 99.
- [25] Lu T, Li K, Zhao H, et al. Rapid prediction of flow and concentration fields in solid-liquid suspensions of slurry electrolysis tanks [J]. International Journal of Minerals, Metallurgy and Materials 31.9 (2024): 2006 – 2016.

Numerical simulation calculation and rapid prediction of oxygen injector in bottom blowing furnace

LIU Xin¹, SU Yanmin², CHENG Yongqiang^{1*}, WANG Wei¹, CAI Xiaoyi¹, ZHAO Hongliang¹

(1. School of Metallurgy and Ecological Engineering, University of Science and Technology Beijing, Beijing 100083, China;

2. Xinjiang Nonferrous Metals Industry (Group) Co., Ltd., Urumqi 830000, China)

Abstract: The oxygen injector in the bottom blowing furnace is an immersion oxygen injector, and its gas state of outlet plays a decisive role in the melting process of the bottom blowing furnace, but the outlet information of the oxygen injector cannot be directly detected. In this paper, the numerical simulation research method is used, and the numerical simulation is combined with machine learning, the orthogonal experiment is designed, and the matrix analysis method is used to calculate and predict the outlet information of the oxygen injector. The effects and weights of the gas flow, the angle of the oxygen injector and the liquid level of the bottom blowing furnace on the outlet velocity, outlet pressure and outlet temperature of the oxygen injector were studied. The results show that the gas flow rate has the greatest comprehensive influence on the outlet state of the oxygen injector, while the inclination angle of the oxygen injector has the least effect, and the gas flow state of the outlet of the oxygen injector is the best under the conditions of high flow rate, high liquid level and low inclination angle of the oxygen injector. At the same time, the KNN algorithm is used to establish a fast prediction model, and the results show that the regression coefficient R^2 of the indicators of the predicted working conditions and the actual calculated working conditions can reach 0.998, and the prediction accuracy is high, and the prediction model is accurate and reliable.

Keywords: oxygen injector in bottom blowing furnace; numerical simulation; orthogonal test; matrix analysis; KNN algorithm; copper smelting

