

DOI:10.16410/j.issn1000-8365.2025.5146

基于贝叶斯优化机器学习的转炉耗氧量预测研究

丁志豪¹, 信自成^{1,2}, 张江山¹, 刘青¹

(1. 北京科技大学 绿色低碳钢铁冶金全国重点实验室, 北京 100083; 2. 北京科技大学 自动化学院, 北京 100083)

摘要: 转炉冶炼过程具有多变量、非线性、强耦合的特点, 冶炼过程吹氧控制对钢液成分和温度具有重要影响。为实现转炉吹氧量的精确预测, 利用箱线图法对实际生产数据进行预处理, 基于反向传播神经网络 (back propagation neural network, BP) 算法和极限学习机 (extreme learning machine, ELM) 算法, 构建了转炉耗氧量预测模型, 运用贝叶斯优化 (bayesian optimization, BO) 算法, 对 BP 神经网络算法和 ELM 算法的超参数进行寻优; 最后, 采用多种评价指标对所建模型性能进行了评估。结果表明, BO-ELM 预测模型性能优于 BO-BP 预测模型, BO-ELM 耗氧量预测模型的 R^2 、RMSE 和 MAE 分别为 0.721、137.176 和 113.622, 且耗氧量在 $\pm 300 \text{ m}^3$ 误差范围内的命中率达 98.10%。

关键词: 转炉; 耗氧量预测; BP 神经网络算法; 极限学习机; 贝叶斯优化

中图分类号: TF713.1

文献标识码: A

文章编号: 1000-8365(2025)10-0948-06

Research on the Prediction of Oxygen Consumption in Converters via Bayesian-optimized Machine Learning

DING Zhihao¹, XIN Zicheng^{1,2}, ZHANG Jiangshan¹, LIU Qing¹

(1. State Key Laboratory of Advanced Metallurgy, University of Science and Technology Beijing, Beijing 100083, China; 2. School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: The converter smelting process is characterized by multivariable, nonlinear, and strongly coupled dynamics, where oxygen blowing control significantly influences the composition and temperature of molten steel. To achieve precise forecasting of the oxygen-blowing volume, actual production data were first preprocessed via the boxplot method. Subsequently, prediction models for converter oxygen consumption were constructed on the basis of the back propagation neural network (BP) algorithm and the extreme learning machine (ELM) algorithm. The Bayesian optimization (BO) algorithm was employed to optimize the hyperparameters of the BP neural network algorithm and ELM algorithm. Finally, model performance was evaluated via multiple metrics. The results demonstrate that the BO-ELM prediction model outperforms the BO-BP model, achieving R^2 , RMSE, and MAE values of 0.721, 137.176, and 113.622, respectively. The hit ratio within the error range of $\pm 300 \text{ m}^3$ of oxygen consumption was 98.10%.

Key words: converter; oxygen consumption prediction; BP neural network algorithm; extreme learning machine; Bayesian optimization

钢铁工业的发展水平对于综合国力具有重要影响, 随着我国钢铁生产的持续发展, 钢铁产量和质量不断提高^[1]。在钢铁生产过程中, 炼钢-连铸区段是决定钢铁质量的关键分段, 其过程涉及多组元之间复杂的物理化学反应, 且存在高动态、非线性、

强不确定性等特性^[2-5]。其中, 转炉工序由于其物理化学反应复杂强烈, 原料条件与工况条件变化频繁, 使其成为对炼钢-连铸区段最常见的生产扰动^[6]。转炉是钢铁生产过程中的关键设备之一, 是铁液向钢液转变的重要环节, 其主要目的是生产出满足成分和

收稿日期: 2025-07-10

基金项目: 国家重点研发计划(2024YFB3713602); 国家自然科学基金(52374321); 绿色低碳钢铁冶金全国重点实验室自主课题(41625030)

作者简介: 丁志豪, 2002年生, 硕士生。研究方向为转炉智能冶炼。Email: m202421551@xs.ustb.edu.cn

通信作者: 刘青, 1967年生, 博士, 教授。研究方向为冶金流程学与智能化、冶金过程建模与优化、连续铸钢等领域。

Email: qliu@ustb.edu.cn

信自成, 1992年生, 博士, 讲师。研究方向为冶金过程解析与智能化。Email: sklzc@163.com

引用格式: 丁志豪, 信自成, 张江山, 刘青. 基于贝叶斯优化机器学习的转炉耗氧量预测研究[J]. 铸造技术, 2025, 46(10): 948-953.

DING Z H, XIN Z C, ZHANG J S, LIU Q. Research on the prediction of oxygen consumption in converters via bayesian-optimized machine learning[J]. Foundry Technology, 2025, 46(10): 948-953.

温度要求的钢液^[7]。转炉冶炼的主要操作是向转炉内添加合理配比的石灰、白云石造渣,用氧气射流搅拌熔池并与钢液中的 C、Si、Mn 等元素反应^[8]。转炉冶炼过程中吹氧控制对钢液成分和温度具有重要影响^[9]。因此,开发高精度转炉耗氧量预测模型,对提高钢液质量和冶炼效率具有重要作用。

转炉冶炼过程具有多变量、非线性、强耦合的特点。针对转炉冶炼特点,当前转炉耗氧量预测主要采用静态模型控制和动态模型控制。其中,静态模型控制主要基于物料平衡和热平衡来计算所需物料的加入量^[10]。同时,根据不同的建模方法,静态模型分为:机理模型、统计模型、增量模型和智能模型^[11]。动态模型控制主要是对在吹炼过程中,会随时间动态变化的吹炼参数,如铁液温度、成分等进行动态调整。随着机器学习的发展,其以强非线性映射能力而得到广泛应用。Shao 等^[8]建立了基于氧平衡机制和深度神经网络融合的转炉吹氧时间预测模型,结果表明,吹氧量误差在 $\pm 300 \text{ m}^3$ 内的命中率达 96.67%。赵辉等^[9]使用极限学习机(extreme learning machine, ELM)建立了耗氧量预测模型,并使用遗传算法对模型进行优化。结果表明,模型对耗氧量的预测值和实际值的均方误差为 2.090 5。Wen 等^[12]提出了改进的灰狼优化算法,并对支持向量机进行优化,建立了耗氧量预测模型。张子阳等^[13]采用灰色 Elman 神经网络预测转炉吹氧量,且该模型预测转炉吹氧量最大误差为 5.36%,最小误差为 0.08%。艾晓礼等^[14]利用 LM 优化算法改进反向传播神经网络(back propagation neural network, BP)算法,并基于此构建了转炉总吹氧量和二次吹氧量预测模型。结果表明,总吹氧量误差小于 800 m^3 命中率达 87.88%,二次吹氧量误差小于 400 m^3 命中率为 91.99%。王红君等^[15]基于灰色模型和遗传算法优化的 BP 神经网络,构建了转炉耗氧量预测模型。He 等^[16]针对转炉的工艺特点,提出基于 BP 神经网络和增量学习(incremental learning, IL)的总吹氧量和二次吹氧量预测模型,并结合实际生产数据对其训练和测试,最后在将其与多元线性回归模型进行比较。结果表明,BPNN-IL 模型在总吹氧量和二次吹氧量上都更为准确,总吹氧量误差在 $\pm 800 \text{ m}^3$ 内的命中率达 84.21%,二次吹氧量误差在 $\pm 400 \text{ m}^3$ 内的命中率为 95.00%。

在分析前人研究的基础上,本研究构建了运用贝叶斯优化的 BP 神经网络与极限学习机转炉耗氧量预测模型。对实际生产中的异常数据进行预处理;基于机器学习算法,构建了转炉耗氧量预测模型,并利用超参数优化算法,对所建 2 个模型超参

数进行寻优。最后,利用多种模型评价指标对各模型进行对比分析。本研究有助于实现转炉耗氧量的精准预测,优化生产现场操作工艺。

1 机器学习算法介绍

1.1 反向传播神经网络

BP 神经网络是一种 Werbos 提出,后来经Bumelhart 等^[17]改进的多层前馈神经网络模型,其通过误差逆传播算法调整网络权重,逐步让预测误差最小化。BP 神经网络模型结构主要分为 3 层,分别是输入层、隐含层和输出层,结构如图 1 所示。




图 1 BP 神经网络结构

Fig.1 Structure of the BP neural network

图 1 中的输入、输出和隐含层的节点数分别为 n, m, l ; ω 表示网络神经元之间的连接权值; v_l 和 θ_j 分别表示第 l 个隐含层神经元和第 j 个输出层神经元的阈值; y_j 和 O_j 分别表示输出层第 j 个神经元的实际输出和期望输出, BP 网络算法具体步骤如下。

(1) 权值、阈值初始化

根据要训练的样本,确定输入、输出和隐含层的节点数,初始化连接权值和隐含、输出层阈值,给定学习速率和激励函数。

(2) 隐含层输出通过下式计算获得:

$$v_l = f_1 \left(\sum_{m=1}^M \omega_{ml} x_m - v_l \right) \quad (1)$$

式中, f 为隐含层激励函数; $l=1, 2, \dots, L$ 。

(3) 输出层输出 y_j 通过下式计算获得:

$$y_j = f_2 \left(\sum_{l=1}^L \omega_{jl} v_l - \theta_j \right) \quad (2)$$

式中, f 为输出层激励函数; $j=1, 2, \dots, J$ 。

(4) 误差函数 E 由下式计算获得:

$$E = \frac{1}{2} \sum_{j=1}^J (y_j - O_j)^2 \quad (3)$$

(5) 权值和阈值更新, 如式(4~7)所示。

$$\omega_{ij} = \omega_{ij} + \eta v_l (1 - v_l) x(i) \sum_{k=1}^m \omega_{jk} E \quad (4)$$

$$\omega_{jk} = \omega_{jk} + \eta v_j E \quad (5)$$

$$v_i = v_i + \eta v_i (1 - v_i) \sum_{k=1}^m \omega_{jk} E \quad (6)$$

$$\theta_j = \theta_j + E \quad (7)$$

式中, η 为学习速率; E 为预测误差; $i=1, 2, \dots, n$; $j=1, 2, \dots, l$; $k=1, 2, \dots, l$ 。

判断参数的精度是否达标, 若不符合要求, 返回式(2)重复计算。

1.2 极限学习机原理

极限学习机是 Huang 等^[18]为了解决传统神经网络在训练过程中存在的效率低下和调参复杂问题而提出的一种监督型学习算法。极限学习机作为单隐层前馈神经网络, 通过随机初始化输入层到隐含层的权重和偏置, 计算出相应节点的权重, 从而极大提高训练速度, 保持良好的泛化能力。其网络模型可划分为 3 层, 分别为输入层、隐含层和输出层, 结构如图 2 所示。




图 2 极限学习机结构示意图

Fig.2 Schematic diagram of the ELM architecture

对于有 N 个不同训练样本的集合 (x_i, t_i) , 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 和 $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$, 含有 N 个隐含层节点和激活函数 $g(x)$ 的数学模型^[19]如下式所示:

$$\sum_{i=1}^N \beta_i g(x_j) = \sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = o_j \quad (8)$$

式中, $j=1, 2, \dots, N$; $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 为第 i 个隐含层节点和输入层节点连接的权值向量; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 为第 i 个隐含层节点和输出层节点连接的权值向量; b_i 为第 i 个隐含层节点的阈值; $w_i \cdot x_j$ 表示两向量间的内积。含有 N 个隐含层节点和激活函数 $g(x)$ 的模型可以零误差逼近这 N 个训练样本, 即

$$\sum_{i=1}^N \|o_j - t_j\| = 0, \text{ 意味着存在 } \beta_i, w_i, b_i \text{ 使得:} \quad (9)$$

$$\sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = t_j$$

式中, $j=1, 2, \dots, N$; 上述方程可表示为:

$$H\beta = T \quad (10)$$

其中,

$$H(w_1, \dots, w_N, b_1, \dots, b_N, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_N \cdot x_1 + b_N) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_N \cdot x_N + b_N) \end{bmatrix}_{N \times N}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}_{N \times m} \quad \text{和} \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

上述权重可通过计算线性方程组的最小范数最小二乘解来获得:

$$\beta = H^+ T \quad (11)$$

式中, H^+ 为 Moore-Penrose 广义逆矩阵。通过以上计算方法可最小化训练误差。

综上, 极限学习机的算法可总结为: ①随机分配和输入权重 w_i 和偏置 b_i ; $i=1, 2, \dots, N$; ②计算隐含层的输出矩阵 H ; ③计算输出权值 β 。

1.3 贝叶斯优化原理

贝叶斯优化是一种高效的全局优化算法^[20], 通过智能采样减少评估次数, 有效找到全局最优解。其在优化算法的过程中使用了贝叶斯定理, 可表述为:

$$p(f|D_{1:t}) = \frac{p(D_{1:t}|f)p(f)}{p(D_{1:t})} \quad (12)$$

式中, f 为未知目标函数; $D_{1:t} = \{(x_1, y_1), (x_2, y_2), \dots, (x_t, y_t)\}$ 为已观测集合, 其中 x 为决策向量; $y_i = f(x_i) + \varepsilon_i$ 为观测值, ε_i 为观测误差; $p(D_{1:t}|f)$ 为 y 的似然分布; $p(f)$ 为 f 的先验概率分布; $p(f|D_{1:t})$ 为目标函数的后验概率分布。

BO 的优化主要通过迭代来完成: ①由采集函数最大化得到最佳评估点 x_i ; ②对目标函数值 $y_i = f(x_i) + \varepsilon_i$ 进行评估; ③对新得到的观测值 $\{x_i, y_i\}$ 整合到历史观测集 $D_{1:t-1}$ 中, 并更新概率代理模型。

2 耗氧量预测模型构建与评估

2.1 模型构建

首先运用箱线图对国内某钢厂的转炉实际生产数据进行处理, 最终得到 1 050 炉有效数据并将其分为两类。其中, 840 炉用于转炉耗氧量预测模型的训练, 210 炉用于转炉耗氧量预测模型的测试。当训练模型的耗氧量预测值和实际值的误差达到最小时, 用 210 组测试数据对耗氧量预测模型进行测试。转炉耗氧量预测模型构建过程如图 3 所示, 模型部署的硬件配置信息见表 1。

2.2 模型评估

采用 R^2 、RMSE、MAE 和命中率(Hit ratio)来对




图3 耗氧量预测模型构建逻辑

Fig.3 Workflow diagram of the oxygen consumption prediction model

表1 模型部署硬件配置信息
Tab.1 Model deployment hardware configuration

硬件项目	配置信息
中央处理器 (central processing unit, CPU)	Intel Core i7-10700F, 8 核, 2.90 GHz
硬盘	SAMSUNG MZALQ256HAJD-000L1, 容量 256 G
主板	LENOVO, 370 A

各模型性能进行评估。其中, 决定系数用于衡量模型拟合优度的统计指标, 记为 R^2 ; 均方根误差是衡量模型耗氧量预测值与实际值之间差异的指标, 记为 RMSE; 平均绝对误差是衡量模型耗氧量预测误差绝对值的平均值, 记为 MAE; 命中率是模型预测值与实际值在一定误差范围内的炉数占总炉数的百分比, 上述指标的计算公式如式(13~16)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (15)$$

$$\text{Hit ratio} = \frac{\eta}{N} \times 100\% \quad (16)$$

式中, y_i 为第 i 个样本的实测值; $\hat{y}_i$ 为第 i 个样本的预测值; $\bar{y}$ 为样本集的平均值; η 为转炉预测耗氧量和实际耗氧量误差的绝对值不超过 150 或 300 m^3 的炉数, N 为测试集的总炉数。

3 实验结果及讨论

3.1 数据预处理

采集了国内某钢厂的 1 534 炉实际生产数据, 并对数据进行归一化处理, 随后将数据缩放至 [0, 1] 范围内, 通过下式计算获得^[21]:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (17)$$

式中, x'_i 为经归一化处理后得到的数据; x_i 为原始数据; $x_{\min}$ 和 $x_{\max}$ 是原始数据中的最小值与最大值。将原始数据归一化后, 绘制箱线(图 4)。对于异常值, 可通过四分位距(IQR)来判定, 判定步骤为: ①计算四分位数。将数据集进行四等分, 得到 3 个数据位点, 分别为下四分位数(Q1), 中位数(Q2), 上四分位数(Q3); 其中, Q1、Q3 分别为数据集的下边缘和上边缘, 四分位距(IQR)为 Q3 和 Q1 的差值。②设定异常边界值。低于下界 ($Q1 - 1.5 \times \text{IQR}$) 或高于上界 ($Q3 +$




图4 基于箱形图的归一化数据离群值检测

Fig.4 Outlier detection of normalized data via boxplots

1.5×IQR)的数据点被判定为异常值,进行剔除。

3.2 模型超参数寻优

箱线图处理后的数据,分别构建了基于BP神经网络和ELM的转炉耗氧量预测模型,并运用贝叶斯优化算法对2个模型超参数进行寻优,BP超参数寻优时长14.08 s,ELM超参数寻优时长1.73 s。BO-BP模型最优超参数组合隐藏节点数选86个,学习率为0.012 4;BO-ELM模型最优超参数组合隐藏节点数选18个,激活函数为linear。所建模型超参数组合与在相同测试集下模型的结果,见表2。

表2 各模型最优超参数

Tab.2 Optimal hyperparameters of each model

Model	Number model	Optimal hyperparameter combination	Test set RMSE/m ³	Hyperparameter optimization duration/s
1	BO-BP model	Number of hidden units:86	146.416	14.08
		Learning rate: 0.012 4		
2	BO-ELM model	Units: 18	137.176	1.73
		Activation function: linear		

3.3 所建模型对比分析

基于相同测试集数据,运用多种评价指标,对

比了各转炉耗氧量预测模型的性能。表3展示了BP神经网络和ELM转炉耗氧量预测模型的性能指标结果。图5展示了不同模型的转炉耗氧量预测值与实际值的散点。由表3可知,BO-ELM转炉耗氧量预测模型在 R^2 、RMSE、MAE均优于BO-BP转炉耗氧量预测模型,且BO-ELM模型的 R^2 、RMSE、MAE分别为0.721、137.176、113.622。与BO-BP神经网络模型相比,BO-ELM模型在预测精度方面表现更佳, R^2 提高了0.039,RMSE和MAE分别降低了9.24和8.836 m³。在转炉耗氧量预测命中率对比方面,由表3和图5可知,BO-ELM转炉耗氧量预测模型优于BO-BP转炉耗氧量预测模型,且耗氧量在±150和±300 m³误差范围以内的命中率分别为70.48%和98.10%。相比于BO-BP神经网络模型,在±150和±300 m³误差范围内BO-ELM模型的命中率分别提高了7.15%和0.96%。

表3 BO-BP模型与BO-ELM模型的性能指标

Tab.3 Performance metrics of the BO-BP model and BO-ELM model

Model	R^2	RMSE/m ³	MAE/m ³	Hit ratio within error range of	Hit ratio within error range of
				±150 m ³ /%	±300 m ³ /%
BO-BP	0.682	146.416	122.458	63.33	97.14
BO-ELM	0.721	137.176	113.622	70.48	98.10





图5 不同耗氧量预测模型预测值与实际值对比:(a) BO-BP模型;(b) BO-ELM模型

Fig.5 Comparison of the predicted values and actual values of different oxygen consumption prediction models: (a) BO-BP model; (b) BO-ELM model

4 结论

(1)BO-BP转炉耗氧量预测模型的最优超参数组合为:隐含层节点数为86,学习率为0.0124。BO-ELM转炉耗氧量预测模型的最优超参数组合为:隐含层节点数为18,激活函数为linear。

(2)BO-ELM转炉耗氧量预测模型性能优于BO-BP模型,且BO-ELM模型的 R^2 为0.721,RMSE为137.176 m³,MAE为113.622 m³,耗氧量在±150 m³和±300 m³误差范围内的命中率分别为70.48%和98.10%,具有较高的预测精度和良好的泛化能力。

参考文献:

- [1] 殷瑞钰.我国炼钢-连铸技术发展和2010年展望[J].炼钢,2008,24(6):1-12.
YIN R Y. Development of steelmaking and continuous casting technology and prospect of this technology in 2010 in China[J]. Steelmaking, 2008, 24(6): 1-12.
- [2] 刘青,王彬.炼钢厂多尺度建模与协同制造[M].北京:冶金工业出版社,2025.
LIU Q, WANG B. Multi-scale modeling and collaborative manufacturing for steelmaking plant[M]. Beijing: Metallurgical Industry Press, 2025.
- [3] 刘青,兰模,信自成,张江山.炼钢-连铸区段的协同智造[J].工程科学学报,2025,47(4):654-667.

- LIU Q, LAN M, XIN Z C, ZHANG J S. Cooperative manufacturing in the steelmaking-continuous casting section using intelligent technologies[J]. Chinese Journal of Engineering, 2025, 47(4): 654-667.
- [4] 刘青, 刘倩, 杨建平, 张江山, 高山, 李强笃, 王宝, 王柏琳, 李铁克. 炼钢-连铸生产调度的研究进展[J]. 工程科学学报, 2020, 42(2): 144-153.
- LIU Q, LIU Q, YANG J P, ZHANG J S, GAO S, LI Q D, WANG B, WANG B L, LI T K. Progress of reserch on steelmaking-continuous casting production scheduling[J]. Chinese Journal of Engineering, 2020, 42(2): 144-153.
- [5] 唐嘉励, 信自成, 张江山, 谯明亮, 李权辉, 刘青. 炼钢-连铸流程协同制造的典型技术[J]. 冶金自动化, 2025, 49(3): 89-97.
- TANG J L, XIN Z C, ZHANG J S, QIAO M L, LI Q H, LIU Q. Typical technologies in collaborative manufacturing of steelmaking-continuous casting process[J]. Metallurgical Industry Automation, 2025, 49(3): 89-97.
- [6] 邵鑫. 基于转炉吹氧扰动解析的炼钢-连铸区段协同调度研究[D]. 北京: 北京科技大学, 2025.
- SHAO X. Study on collaborative scheduling for steelmaking-continuous casting section based on disturbance analysis of BOF oxygen blowing[D]. Beijing: University of Science and Technology Beijing, 2025.
- [7] 陶钧, 柴天佑, 李小平, 郑万, 刘万善, 黎军保. 转炉炼钢智能控制方法及应用[J]. 控制理论与应用, 2001(S1): 129-133.
- TAO J, CHAI T Y, LI X P, ZHENG W, LIU W S, LI J B. Intelligent control methods and application for BOF steelmaking process[J]. Control Theory and Applications, 2001(S1): 129-133.
- [8] SHAO X, LIU Q, XIN Z C, ZHANG J S, TAO Z, LI S S. Hybrid model for BOF oxygen blowing time prediction based on oxygen balance mechanism and deep neural network[J]. International Journal of Minerals, Metallurgy and Materials, 2024, 31(1): 106-117.
- [9] 赵辉, 易晓敏, 王红君, 岳有军. 转炉炼钢耗氧量预测模型研究[J]. 计算机仿真, 2017, 34(1): 380-383, 422.
- ZHAO H, YI X M, WANG H J, YUE Y J. Prediction model research of oxygen consumption in BOF[J]. Computer Simulation, 2017, 34(1): 380-383, 422.
- [10] 黄祖祝. 转炉自动炼钢技术的研究与应用[D]. 沈阳: 东北大学, 2013.
- HUANG Z Z. Application and research on converter automatic steelmaking technology [D]. Shenyang: Northeastern University, 2013.
- [11] 付佳. 基于 BP 神经网络的转炉供氧模型的研究与应用开发[D]. 北京: 冶金自动化研究设计院, 2014.
- FU J. Research and application development on BOF oxygen model based on BP neural net[D]. Beijing: Automation Research and Design Institute of Metallurgical Industry, 2014.
- [12] WEN D, ZHU Y. Research on prediction of oxygen consumption in converter steelmaking based on IGWO-SVM model[C]. Journal of Physics: Conference Series, 2021, 2010(1): 012138.
- [13] 张子阳, 孙彦广. 基于灰色 Elman 神经网络转炉吹氧量的预测[J]. 计算机应用与软件, 2018, 35(11): 103-107.
- ZHANG Z Y, SUN Y G. Prediction of oxygen amount in converter based on grey Elman neural network[J]. Computer Applications and Software, 2018, 35(11): 103-107.
- [14] 艾晓礼, 王玉生, 唐文明. 基于 BP 神经网络的转炉炼钢吹氧量预测[J]. 炼钢, 2013, 29(2): 34-37, 41.
- AI X L, WANG Y S, TANG W M. Prediction of oxygen blow rate in BP neural network based converter refining [J]. Steelmaking, 2013, 29(2): 34-37, 41.
- [15] 王红君, 蒋伟杰, 赵辉, 岳有军. 钢铁企业转炉炼钢耗氧量预测模型研究[J]. 计算机仿真, 2017, 34(4): 410-414.
- WANG H J, JIANG W J, ZHAO H, YUE Y J. The research of converter steelmaking oxygen consumption forecast model in steel enterprises[J]. Computer Simulation, 2017, 34(4): 410-414.
- [16] HE F, CHAI X, ZHU Z. Prediction of oxygen-blowing volume in BOF steelmaking process based on BP neural network and incremental learning[J]. High Temperature Materials and Processes, 2022, 41(1): 403-416.
- [17] 刘奕君, 赵强, 郝文利. 基于遗传算法优化 BP 神经网络的瓦斯浓度预测研究[J]. 矿业安全与环保, 2015, 42(2): 56-60.
- LIU Y J, ZHAO Q, HAO W L. Study of gas concentration prediction based on genetic algorithm and optimizing BP neural network [J]. Mining Safety & Environmental Protection, 2015, 42(2): 56-60.
- [18] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: A new learning scheme of feedforward neural networks[J]. IEEE, 2004, 2: 985-990.
- [19] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [20] 崔佳旭, 杨博. 贝叶斯优化方法和应用综述[J]. 软件学报, 2018, 29(10): 3068-3090.
- CUI J X, YANG B. Survey on bayesian optimization methodology and applications[J]. Journal of Software, 2018, 29(10): 3068-3090.
- [21] PATRO S, SAHU K K. Normalization: A preprocessing stage [EB/OL]. [2025-09-30], <https://arxiv.org/abs/1503.06462>.

(责任编辑: 李亚敏)